



**Politecnico
di Torino**

Politecnico di Torino

Corso di Laurea Magistrale in Ingegneria Gestionale

Anno accademico: 2025/2026

Sessione di Laurea: Marzo 2026

Mappatura delle tecniche di Intelligenza Artificiale nella progettazione di prodotto

Framework teorico e validazione empirica multi-dominio con la
Matrice degli Orientamenti Progettuali

Relatrice:

Prof.ssa Francesca Montagna

Candidata:

Patrizia Fiorenza

Abstract italiano

La tesi analizza il ruolo dell'Intelligenza Artificiale (AI) nei processi di progettazione nell'ambito dello sviluppo prodotto (New Product Development, NPD), con l'obiettivo di chiarire quali paradigmi e tecniche risultino maggiormente compatibili con le diverse fasi e sottofasi in cui si articolano. L'elaborato adotta un'impostazione sequenziale orientata a rispondere ai quesiti di ricerca, integrando una revisione della letteratura sull'AI, la formalizzazione di un framework teorico che mette in relazione le sottofasi della progettazione con gli strumenti di AI e una mappatura empirica di casi di studio aziendali.

In primo luogo, la trattazione si sviluppa intorno alla costruzione di una tassonomia volta a ricomporre la frammentazione della letteratura sull'AI, spesso caratterizzata da impostazioni classificatorie che, pur riferendosi a costrutti concettualmente distinti, risultano in alcuni casi ambigue per effetto delle sovrapposizioni e della non ortogonalità che contraddistinguono i piani di categorizzazione adottati. Partendo da un'analisi di un corpus di 107 contributi, la tesi articola una tassonomia per tecniche, divise per paradigmi di Intelligenza Artificiale (AI simbolica, evolutiva, machine learning, deep learning, AI ibrida) e, dove necessario, integra piani di classificazione complementari, al fine di offrire una rappresentazione complessiva che preservi la distinguibilità dei concetti. A supporto, una tabella comparativa propone un confronto tra le tecniche selezionate in termini di caratteristiche, task tipici, tipologia di input, interpretabilità, domini applicativi, scalabilità, risorse computazionali richieste e tempi di addestramento.

Successivamente, la trattazione procede con la costruzione del framework teorico, concepito per risultare trasversale ai domini disciplinari e trasferibile ai diversi livelli della progettazione (concettuale, architetturale e di dettaglio). La formulazione si articola intorno a due dimensioni di collegamento: la tipologia di attività, descritta attraverso il Context of Action (Identification, Structuring, Development, Control, Communication); e il ruolo operativo dello strumento, inteso sia come modalità di intervento e di interazione nel processo progettuale, sia come grado di autonomia (Support, Augmentation, Automation), modulato in funzione della criticità della fase e del conseguente livello di supervisione richiesto.

Infine, il precedente framework teorico viene validato attraverso una mappatura empirica di casi studio aziendali. A questo scopo è stata ingegnerizzata la Matrice degli Orientamenti Progettuali, che consente il posizionamento multi-dominio dei casi lungo due assi, volti a quantificare lo sforzo cognitivo richiesto al progettista, distinguendo tra orientamento user-oriented e rigore scientifico-ingegneristico. La mappatura evidenzia pattern empirici di associazione tra fasi, strumenti e ruoli operativi, con particolare attenzione alle fasi divergenti e ai potenziali applicativi della Generative AI.

Abstract inglese

The thesis examines the role of Artificial Intelligence (AI) in design processes within New Product Development (NPD), with the aim of clarifying which paradigms and techniques are most compatible with the different phases and sub-phases comprising these processes. The work follows a sequential approach designed to address the research questions, integrating a review of AI literature, the formalization of a theoretical framework linking design sub-phases to AI tools, and an empirical mapping of business case studies.

Initially, the discussion focuses on the construction of a taxonomy intended to reconcile the fragmentation of AI literature, which is often characterized by classificatory approaches that, while referring to conceptually distinct constructs, can be ambiguous due to overlaps and the non-orthogonality of the categorization dimensions adopted.

Leveraging on the analysis of a corpus of 107 contributions, the thesis develops a technique-based taxonomy organized by AI paradigms (symbolic AI, evolutionary AI, machine learning, deep learning, and hybrid AI) and, where necessary, it integrates complementary classification dimensions in order to provide an overarching representation that preserves conceptual distinguishability. In support of this, a comparative table contrasts the selected techniques in terms of characteristics, typical tasks, input typologies, interpretability, application domains, scalability, required computational resources and training time.

The discussion then proceeds with the construction of a theoretical framework designed to be cross-disciplinary and transferable across different levels of design (conceptual, architectural, and detailed). The framework is articulated around two linking dimensions: the type of activity, described through the Context of Action (Identification, Structuring, Development, Control, Communication); and the operational role of the tool, understood both as a mode of intervention and interaction within the design process and as a degree of autonomy (Support, Augmentation, Automation), modulated according to the criticality of the phase and the resulting level of supervision required.

Finally, the theoretical framework is validated through an empirical mapping of business case studies. To this end, a Design Orientation Matrix was engineered to enable multi-domain positioning of cases along two oriented axes intended to quantify the cognitive effort required of the designer, distinguishing between a user-centred orientation and scientific-engineering rigor. The mapping highlights empirical association patterns across phases, tools and operational roles, with particular attention to divergent phases and the application potential of Generative AI.

Indice

1. Introduzione	9
2. Esplorazione dei principali strumenti di Intelligenza Artificiale	13
2.1. Introduzione: obiettivo del capitolo	13
2.2. Analisi della letteratura: approccio metodologico e risultati sulla diffusione dell'Intelligenza Artificiale	13
2.3. Evoluzione storica e paradigmi fondamentali dell'intelligenza artificiale: dalle origini simboliche all'apprendimento statistico fino all'AI agentiva	17
2.3.1. Inquadramento generale e definizione	17
2.3.2. Evoluzione dei paradigmi di intelligenza artificiale	17
2.3.3. Framework concettuale	17
2.4. Classificazione delle principali famiglie di AI	19
2.4.1. Piani di classificazione	19
2.4.2. AI simbolica	21
2.4.3. AI evolutiva e bio-ispirata	22
2.4.4. Machine Learning	24
2.4.5. Deep Learning	27
2.4.6. AI Ibrida	37
2.4.7. Tabella riassuntiva della tassonomia per tecniche di Intelligenza Artificiale	39
2.4.8. Agent, Agentic AI e architetture multi-agentiche	42
2.5. Confronto e Valutazione delle tecniche di Intelligenza artificiale	44
2.5.1. Scelta dei paradigmi e delle tecniche da confrontare	44
2.5.2. Dimensioni caratteristiche di confronto	44
2.5.3. Tabelle di confronto	45
3. Dai modelli decisionali al framework teorico per l'applicazione dell'AI ai processi di progettazione	55
3.1. Il ruolo dei processi decisionali all'interno dei processi di progettazione	56
3.2. Il processo di progettazione: modelli teorici	58
3.2.1. Un modello unificato: Stage-Based Design Process	60
3.3. Applicazione delle categorie di collegamento e compatibilità alle fasi progettuali e agli strumenti di Intelligenza Artificiale	62
3.3.1. Categorie di collegamento e compatibilità	62
3.3.2. Applicazione delle categorie di collegamento alle fasi del processo progettuale	67
3.3.3. Applicazione delle categorie di collegamento agli strumenti di Intelligenza Artificiale	73
3.4. Mappatura finale tra fasi progettuali e strumenti di IA	77
3.4.1. Planning	78
3.4.2. Processo di progettazione	84
4. Applicazione empirica del framework: analisi dei casi studio attraverso la Matrice degli Orientamenti Progettuali (U-oD/S&E-oD)	111

4.1. Matrice degli Orientamenti Progettuali (U-oD/S&E-oD)	111
4.1.1. User-oriented Design (U-oD).....	115
4.1.2. Science & Engineering-oriented Design (S&D-oD).....	116
4.2. Analisi dei casi studio aziendali e posizionamento sulla Matrice degli Orientamenti Progettuali	119
4.2.1. Quadrante A e B	120
4.2.2. Quadrante C	121
4.2.3. Quadrante D.....	129
4.2.4. Quadrante E	134
4.2.5. Quadrante F.....	135
4.2.6. Quadrante G.....	143
4.2.7. Quadrante H.....	150
4.2.8. Quadrante I	152
4.3. Riflessioni sui risultati del posizionamento dei casi sulla Matrice degli Orientamenti Progettuali.....	157
4.4. Conclusioni del capitolo.....	173
5. Conclusioni.....	177
Indice delle tabelle	188
Indice delle figure	190
Bibliografia	192
Appendici.....	206
Appendice A.....	206
Appendice B	207
Appendice C	208
Appendice D.....	209
Ringraziamenti.....	216

1. Introduzione

Negli ultimi anni l'Intelligenza Artificiale ha conosciuto una rapida espansione sia sul piano tecnico sia su quello applicativo, evolvendo da soluzioni puntuali e prevalentemente specialistiche verso architetture più articolate, costituite da layers eterogenei e da combinazioni di tecniche che cooperano all'interno di uno stesso sistema. Questa evoluzione ha abilitato, da un lato, task strettamente mirati per specifiche funzioni aziendali e, dall'altro, attività ricorrenti adattate per un impiego trasversale tra funzioni diverse, introducendo un crescente grado di generalizzabilità in continuità con la traiettoria avviata dall'AI generativa.

La rapidità di tale evoluzione e la complessità conseguente si riflettono nella letteratura, spesso frammentata per l'elevata diversificazione delle tecniche, spesso ambigua per l'adozione di schemi di classificazione che rischiano di collocare sul medesimo livello concetti riconducibili a piani di rappresentazione differenti.

In questo contesto, la sfida per le imprese non si esaurisce nelle difficoltà di integrazione dell'AI nei processi aziendali, ma include la necessità di comprenderne i meccanismi e i requisiti d'impiego, così da valutarne la compatibilità con le proprie attività e l'opportunità di soluzioni mirate che costituiscano una fonte di valore effettiva, dipendente dal dominio di riferimento.

Inoltre, la compatibilità teorica tra attività e strumenti, intesa in termini di task potenzialmente implementabili, deve essere verificata alla luce di condizioni operative e vincoli reali, unitamente alla disponibilità di evidenze quantificabili circa la capacità degli strumenti di generare miglioramenti misurabili.

In particolare, le più recenti prospettive sull'Intelligenza Artificiale evidenziano come i benefici conseguibili in ambito aziendale non si esauriscano in un incremento di efficienza nello svolgimento di compiti codificabili e ripetitivi, coerentemente con le tradizionali modalità di interazione uomo-macchina, ma includano anche il potenziamento di abilità che, fino a tempi recenti, venivano considerate prerogativa esclusiva delle capacità cognitive umane. Con l'affermazione della Generative AI, l'AI si configura infatti anche come strumento di supporto creativo, organizzativo e collaborativo: abilita attività di brainstorming e di esplorazione concettuale, favorisce la strutturazione delle informazioni e facilita la comunicazione tra soggetti umani e tra attori umani e artificiali. Ne deriva un cambio di prospettiva rispetto all'interpretazione tradizionale delle tecnologie digitali come meri amplificatori di produttività, introducendo un paradigma in cui l'AI interviene nei processi di lavoro anche come leva di augmentazione cognitiva e creativa.

In tale prospettiva, i processi di progettazione, se inquadrati nell'ambito dello sviluppo prodotto (New Product Development, NPD), e in particolare nei contesti orientati all'innovazione, configurano un ambito di analisi di primaria rilevanza. La progettazione integra, infatti, attività ad alta intensità cognitiva, difficilmente riconducibili a routine ripetitive e standardizzabili. Le decisioni sono spesso solo parzialmente formalizzabili e si svolgono in contesti destrutturati, richiedendo programmazione, ingegno e un continuo bilanciamento tra vincoli tecnici, obiettivi di prestazione, esigenze di mercato e dimensioni legate all'esperienza d'uso, in coerenza con preferenze dei consumatori dinamiche e mutevoli.

A questo proposito, anche alla luce delle evoluzioni più avanzate della Generative AI e, più recentemente, dei sistemi agentivi, emergono nuove opportunità di esecuzione dei task, potenzialmente radicali rispetto agli impieghi tradizionali dell'AI nei processi di lavoro, e capaci di estendere il supporto anche ad attività progettuali complesse e multidimensionali. Tuttavia, sebbene la Generative AI abbia evidenziato potenzialità e versatilità nel gestire compiti eterogenei e nel trattare modalità rappresentazionali diverse, come testo, immagini e dati strutturati, considerarla come soluzione unica rischia di risultare riduttivo.

In un contesto articolato come quello della progettazione per lo sviluppo prodotto, sono spesso necessari supporti altamente specifici, capaci di intervenire su particolari sfere cognitive del progettista attivate nella definizione di determinate caratteristiche, un requisito difficilmente perseguibile esclusivamente tramite approcci generalisti. Modelli statistici e di machine learning, metodi di ottimizzazione, tecniche simboliche, soluzioni ibride e, in alcuni casi, metodi generativi sviluppati con addestramenti e formulazioni ad hoc, presentano proprietà specializzanti che possono risultare più efficaci per particolari tipologie di task e in determinate condizioni

operative. Ne consegue che, per comprendere in modo rigoroso il ruolo dell'AI nella progettazione, è necessario adottare una prospettiva complessiva sulle principali tecniche riconducibili ai diversi paradigmi, analizzandone capacità, ruoli operativi e compatibilità con le attività progettuali.

In questo senso, la tesi non si concentra sulla risoluzione di un singolo problema circoscritto, ma adotta un approccio esplorativo volto a organizzare sistematicamente le potenzialità applicative dell'AI nella progettazione, facendo emergere bisogni latenti e ambiti d'impiego ancora poco esplicitati.

Le domande di ricerca che guidano l'elaborato sono le seguenti:

- **RQ1.** Quali paradigmi e tecniche di AI risultano rilevanti per analizzare le applicazioni nei processi di progettazione e quale schema di classificazione consente di ricomporre la frammentazione della letteratura in una tassonomia utilizzabile a fini applicativi?
- **RQ2.** Come possono essere distinte e rilette le fasi e sottofasi del processo di progettazione nel contesto NPD in modo compatibile con un'analisi di associazione con strumenti AI e in una prospettiva trasferibile tra livelli progettuali (concettuale, architetturale e di dettaglio) e domini disciplinari?
- **RQ3.** Quali sono le categorie di collegamento più idonee a rendere le associazioni tra strumenti di AI e sottofasi della progettazione più coerenti e quali sono le principali associazioni compatibili?
- **RQ4.** Quali evidenze empiriche multi-dominio documentano applicazioni correnti dell'AI in ambito progettazione e in che misura tali evidenze confermano, precisano o ridimensionano le associazioni teoriche, alla luce dei vincoli reali e dello sforzo cognitivo richiesto al progettista, all'interno del dominio applicativo specifico considerato?

Sul piano metodologico, la tesi è articolata in tre sezioni principali, orientate a rispondere alle quattro domande di ricerca sopracitate. Coerentemente con l'obiettivo di esplorare bisogni latenti, l'impostazione parte dalla tecnologia e successivamente ne indaga le potenzialità applicative, sia sul piano teorico sia su quello empirico.

La prima domanda di ricerca affronta alcune criticità emerse dalla letteratura, caratterizzata da frammentazione e rapida evoluzione delle tecniche. Molti contributi propongono adattamenti incrementali di approcci preesistenti, spesso focalizzati su problemi altamente circoscritti, con una conseguente riduzione del livello di astrazione e della possibilità di ricondurre i risultati a classi più ampie di task, oltre i confini di uno specifico dominio. Inoltre, la complessità della tecnologia rende spesso insufficiente l'adozione di un unico criterio di classificazione, poiché prospettive diverse mettono in luce aspetti differenti degli strumenti.

La parziale sovrapposizione tra prospettive tassonomiche diverse conduce talvolta a collocare sullo stesso livello approcci riferibili a piani di rappresentazione distinti, generando ambiguità. Per queste ragioni, la prima sezione è dedicata alla costruzione di una tassonomia volta a interpretare il funzionamento e, di conseguenza, le potenzialità applicative degli strumenti di AI, individuando piani di classificazione in grado di descrivere in modo completo un panorama diversificato di opportunità. La selezione privilegia piani che, pur talvolta complementari, restano distinguibili, riducendo il rischio di sovrapposizioni concettuali.

La seconda sezione, finalizzata a rispondere alla seconda e alla terza domanda di ricerca, sviluppa un framework teorico che associa gli strumenti alle sottofasi del processo progettuale, in modo da rendere le relazioni generalizzabili e trasferibili tra domini e tra livelli della progettazione. A questo scopo, le fasi vengono organizzate secondo un modello unificato e vengono introdotte categorie di collegamento che esplicitano le associazioni, garantendone la compatibilità sia dal lato dello strumento sia dal lato della fase.

Infine, la terza sezione si concentra sulla validazione empirica mediante una mappatura di casi aziendali, che include iniziative, collaborazioni e tools di AI applicati alla progettazione. L'obiettivo diventa quello di individuare pattern di adozione e condizioni di applicabilità, evidenziando vincoli e contingenze operative che la sola analisi teorica non è in grado di catturare. Pur con un'attenzione specifica alle applicazioni di natura divergente e alle soluzioni basate su AI generativa, l'analisi mantiene una prospettiva ampia, includendo anche altri strumenti e altre fasi del processo, così da restituire una prospettiva complessiva.

La mappatura adotta un approccio multi-dominio, utile a mettere in evidenza come la natura dello sforzo cognitivo richiesto vari in funzione della disciplina e del contesto, più user-oriented oppure più tecnico-ingegneristico, e come ciò influenzi il ruolo operativo e il grado di autonomia effettivamente raggiungibile dagli strumenti impiegati. Il riferimento a casi aziendali reali consente inoltre di documentare impatti e vincoli concreti introdotti dall'implementazione, riportando i risultati tramite KPI quantificabili e confrontabili, così da offrire evidenze utili a orientare decisioni di adozione delle imprese e a valutare la trasferibilità delle soluzioni in contesti affini.

Nel complesso, la tesi mira a mappare e sistematizzare possibilità applicative, teoriche ed empiriche ancora frammentate, costruendo un ponte tra sottofasce della progettazione e paradigmi e strumenti di AI, integrato da una validazione empirica multi-dominio. Il contributo atteso è duplice. Sul piano teorico e metodologico, la tesi propone una sistematizzazione che includa sia approcci consolidati sia tecniche più recenti e innovative, anche quando non ancora ampiamente adottate, in relazione alle potenziali applicazioni nelle diverse fasi della progettazione. Sul piano empirico e manageriale, offre una lettura delle applicazioni sperimentate in contesti aziendali, evidenziando elementi di trasferibilità tra casi simili, vincoli e limitazioni che incidono sull'effettiva operatività degli strumenti, nonché metriche utili a quantificare il valore atteso dell'adozione e a orientare le decisioni di implementazione.

2. Esplorazione dei principali strumenti di Intelligenza Artificiale

2.1. *Introduzione: obiettivo del capitolo*

Il presente capitolo si propone di descrivere i principali metodi e le logiche di funzionamento alla base degli strumenti di intelligenza artificiale oggi diffusi nel panorama tecnologico e industriale. L'obiettivo è esplorare e organizzare la conoscenza disponibile, offrendo una visione complessiva e al tempo stesso strutturata dei diversi paradigmi, principi e tecniche sviluppati nel corso del tempo.

La prima parte del capitolo adotta un approccio deduttivo finalizzato alla costruzione di un quadro tassonomico di riferimento. A partire dall'evoluzione storica dei principali algoritmi di intelligenza artificiale, la trattazione procede con una rassegna delle tecniche, delle architetture e degli algoritmi appartenenti alle differenti famiglie. La classificazione si basa principalmente su un piano concettuale centrale, che definisce la struttura principale della tassonomia. Quando necessario, vengono introdotte ulteriori prospettive classificatorie al fine di approfondire aspetti che rimarrebbero altrimenti inesplorati, evitando incoerenze nella classificazione. Questo approccio permette di costruire una base di conoscenza utile a comprendere le applicazioni presentate nei casi studio che saranno analizzati nei capitoli successivi.

Nella seconda parte, vengono confrontati i metodi, le tecniche e gli algoritmi ritenuti più significativi per ciascun paradigma. Le dimensioni considerate riguardano elementi caratterizzanti quali: la tipologia di input richiesto, la scalabilità, l'interpretabilità, il tipo di task affrontabile, i domini applicativi, le risorse computazionali necessarie e i tempi di addestramento, con l'obiettivo di cogliere anche l'aspetto pratico e implementativo dei metodi, oltre a quello teorico.

L'insieme di queste analisi consente in ultima istanza di delineare chiaramente le alternative disponibili e i vincoli associati ai diversi metodi, che costituiscono la base per individuare gli strumenti di intelligenza artificiale più adeguati a supportare le attività progettuali nei vari ambiti industriali.

2.2. *Analisi della letteratura: approccio metodologico e risultati sulla diffusione dell'Intelligenza Artificiale*

Questo paragrafo si propone, in primo luogo, di illustrare la metodologia adottata per strutturare l'analisi della letteratura, finalizzata all'avvio di un'analisi tassonomica delle principali tecniche e dei metodi di Intelligenza Artificiale. Successivamente, vengono presentati i principali risultati della ricerca, relativi al grado di diffusione e alla diversificazione, sia implementativa sia geografica, che tali tecnologie hanno raggiunto allo stato attuale, sulla base della produzione accademica esistente.

Dal punto di vista metodologico, la ricerca è stata condotta secondo un approccio deduttivo, che procede dal generale al particolare. Tale impostazione si riflette anche nella struttura del capitolo, in cui gli argomenti e il livello di dettaglio della tassonomia vengono progressivamente approfonditi.

Di seguito si procede illustrando il processo di ricerca che ha condotto all'individuazione di 107 studi, alcuni dei quali selezionati attraverso l'applicazione di approcci consolidati, quali il metodo PRISMA e Snowballing.

Lo schema riportato in Figura 2.1 sintetizza il processo metodologico impiegato per l'identificazione, la selezione e il consolidamento del corpus bibliografico utilizzato nella presente revisione, attraverso i due approcci di ricerca. I dettagli relativi alle keywords, alle query complete e ai filtri utilizzati sono riportati in Appendice A.




Figura 2.1: Schematizzazione del processo di ricerca: metodo PRISMA, Snowballing e ricerca mirata dei temi specifici.

Nella parte sinistra dello schema è illustrato il percorso derivante dall'applicazione del metodo PRISMA, adottato all'interno del database Scopus. La fase di identificazione iniziale ha restituito 95.739 studi, ottenuti mediante la costruzione di una query, composta da combinazioni di parole chiave la cui versione completa è riportata in Appendice A (Figura A.1). Successivamente, questo insieme di risultati è stato sottoposto a una prima fase di screening attraverso l'applicazione di filtri automatici relativi al periodo temporale, alle aree disciplinari di riferimento, alla tipologia documentaria e alla lingua. Sono stati inoltre esclusi i contributi provenienti da settori applicativi specifici che trattavano soluzioni tecniche mirate, piuttosto di affrontare il tema in modo esplorativo e trasversale ai diversi domini come richiesto dagli obiettivi della ricerca. L'applicazione di tali filtri ha ridotto il corpus iniziale a 31.057 studi, in seguito ulteriormente ristretto a 1.781 mediante l'impiego di keywords tematiche più specifiche, tra cui "state of the art" e "benchmarking". Nello step successivo è stato effettuato uno screening manuale, basato sulla lettura del titolo e dell'abstract degli studi individuati nella fase precedente. Tale valutazione ha consentito di ridurre il numero dei contributi da analizzare a 31.

Parallelamente al metodo PRISMA, la parte destra dello schema illustra la procedura adottata per l'applicazione dello Snowballing tramite Google Scholar, dalla quale sono emersi 32 articoli. Questi comprendono sia i contributi identificati come potenzialmente rilevanti attraverso ricerche basate su diverse parole chiave, sia gli articoli individuati dall'analisi delle bibliografie dei lavori selezionati. Anche in questo caso, i dettagli della ricerca sono riportati in Appendice A (Figura A.2).

Le due raccolte così ottenute sono state successivamente integrate, generando un totale di 63 articoli sottoposti alla fase di eligible screening, condotta tramite lettura integrale dei testi. Tale revisione approfondita ha consentito di distinguere gli articoli pienamente coerenti con gli obiettivi del capitolo da quelli caratterizzati da sovrapposizioni e ridotta pertinenza tematica, portando all'esclusione di 45 articoli e alla selezione di 18 contributi considerati centrali per creare le basi della trattazione.

Per concludere, è stata condotta una fase di ricerca tematica mirata, finalizzata a integrare quei concetti che, sebbene emersi dal quadro generale delineato dai 18 articoli di base, richiedevano un maggiore approfondimento. In linea con l'approccio deduttivo adottato, questa fase ha consentito di passare dall'analisi generale alla trattazione più specifica dei temi. Grazie a tale integrazione sono stati individuati ulteriori 89 articoli rilevanti che, combinati

ai risultati delle fasi metodologiche precedenti, hanno portato alla costruzione di un corpus bibliografico finale composto da 107 contributi totali.

Al fine di analizzare l'evoluzione temporale e la distribuzione della ricerca scientifica sull'Intelligenza Artificiale, nonché di individuare le principali tendenze della sua traiettoria evolutiva, gli ambiti disciplinari e i contesti geografici in cui tale tecnologia ha registrato il maggiore sviluppo, è stata formulata una query esplorativa orientata a un'analisi ad ampio spettro della tecnologia. In questa fase, l'impiego di filtri è stato deliberatamente limitato, in modo da evitare vincoli che potessero distorcere la rappresentatività dei risultati.

La query, la cui versione estesa è riportata in Appendice B, è stata implementata utilizzando il database Scopus dove ha restituito un corpus documentale di 3.449.014 contributi, a partire dal quale sono stati ricavati indicatori statistici aggregati.

Tra le statistiche risultanti, l'andamento temporale delle pubblicazioni mostra una crescita graduale fino al 2012, seguita da un incremento esponenziale a partire dal 2015 (Figura 2.2, sinistra). Tale tendenza riflette l'impatto delle innovazioni introdotte nel campo del Deep Learning, in particolare del modello AlexNet, sviluppato da Krizhevsky, Sutskever e Hinton nel 2012 [1], che ha segnato una svolta storica nell'elaborazione automatica delle immagini e nell'intero panorama dell'AI. A partire da quel momento, la ricerca ha continuato a espandersi, alimentata da una successione continua di scoperte e miglioramenti tecnici fino ad arrivare negli anni più recenti dove, l'emergere dei foundation models, e più in generale dell'AI generativa, ha segnato una nuova fase di espansione della ricerca. Invece, a livello geografico (Figura 2.2, destra), la produzione scientifica risulta dominata da Cina e Stati Uniti, seguiti da India, Regno Unito, Germania, Giappone e Italia, evidenziando un panorama globalizzato.




Figura 2.2: A sinistra è mostrata l'evoluzione nel tempo, a destra la distribuzione geografica dei documenti sulla letteratura dell'intelligenza artificiale indicizzati in Scopus.

L'analisi per area disciplinare (Figura 2.3) evidenzia la predominanza delle applicazioni nelle aree di Computer Science (35,9 %) ed Engineering (26,4 %), seguite da Mathematics (10,8 %), Physics and Astronomy (4,9 %), Decision Sciences (3,3 %) e Health Sciences (2,9 %). Oltre a questi ambiti tradizionalmente associati allo sviluppo tecnico, spesso di carattere algoritmico e ripetibile, quindi automatizzabile, si osserva una crescente presenza di contributi provenienti da discipline quali Social Sciences, Business and Management, Energy ed Environmental Science, di natura più sociale, organizzativa e talvolta creativa.

Questa distribuzione riflette l'impiego dell'Intelligenza Artificiale come tecnologia trasversale, applicabile a contesti eterogenei. Tale espansione conferma l'aumento del carattere interdisciplinare che l'AI ha registrato negli ultimi anni, in particolare a seguito della diffusione dell'AI generativa e degli agenti intelligenti. Questi strumenti risultano infatti in grado di svolgere compiti fortemente diversificati, che spaziano dalle procedure tecniche proprie di discipline specifiche al supporto di attività creative, fino a includere compiti di natura organizzativa e gestionale.

Inoltre, la distribuzione illustrata in Figura 2.3 suggerisce che l'Intelligenza Artificiale, pur mantenendo una forte componente di ricerca tecnologica ancora attiva, si collochi oggi in una fase di piena diffusione applicativa

lungo la propria curva di adozione. I modelli e gli strumenti sviluppati in ambito accademico trovano infatti un impiego sempre più esteso in contesti concreti e in domini industriali applicativi, superando progressivamente i confini della ricerca.

In particolare, emerge un ambito di applicazione rilevante legato alla collaborazione con il soggetto umano nelle diverse fasi dei processi di progettazione delle aziende orientate allo sviluppo prodotto. In tali contesti, l'AI interviene lungo l'intero processo, dalla definizione e strutturazione del problema, alla generazione di idee e soluzioni, fino alle attività di ottimizzazione e controllo dei risultati.




Figura 2.3: Distribuzione dei documenti sulla letteratura dell'intelligenza artificiale presenti nel database Scopus suddivisi per aree disciplinari.

2.3. *Evoluzione storica e paradigmi fondamentali dell'intelligenza artificiale: dalle origini simboliche all'apprendimento statistico fino all'AI agentiva*

In questa fase preliminare, l'obiettivo è fornire un inquadramento teorico generale della tecnologia, in linea con l'approccio deduttivo adottato per l'analisi. Il presente paragrafo si propone quindi di identificare e classificare i principali paradigmi che, nel tempo, hanno segnato tappe significative nello sviluppo dell'intelligenza artificiale, seguendo un framework concettuale gerarchico che rispecchia l'evoluzione cronologica di tali paradigmi.

2.3.1. Inquadramento generale e definizione

Fin dagli anni '50, quando Alan Turing si è chiesto se le macchine potessero pensare, l'obiettivo dell'intelligenza artificiale è stato sviluppare sistemi capaci di riprodurre comportamenti cognitivi simili a quelli degli esseri umani [2]. Nel tempo sono state sviluppate architetture, algoritmi, tecniche e metodi molto diversi: dal ragionamento programmato esplicitamente all'apprendimento dai dati, fino alle reti neurali ispirate al funzionamento del cervello umano, portando a definizioni e interpretazioni differenti del concetto di AI, ad oggi inteso come una famiglia di metodi differenti [3].

Secondo IBM [4], l'AI è una "tecnologia che consente a computer e macchine di simulare capacità tipicamente umane come l'apprendimento, la comprensione, la risoluzione di problemi, il processo decisionale, la creatività e l'autonomia". Questa definizione, che rispecchia una visione moderna di tale tecnologia, suggerisce che gli attuali sistemi di intelligenza artificiale consentono di analizzare l'ambiente, apprendere dall'esperienza e dai dati, generare contenuti e supportare decisioni, assistendo e in alcuni casi automatizzando attività tipicamente svolte dall'uomo.

2.3.2. Evoluzione dei paradigmi di intelligenza artificiale

L'evoluzione dei paradigmi di intelligenza artificiale è stata analizzata secondo due prospettive complementari:

- Concettuale: che organizza i diversi paradigmi dell'IA in modo gerarchico, mostrando quali caratteristiche condividono e in cosa differiscono.
- Tecnologica: in cui si ripercorrono le fasi storiche relative ad algoritmi, dati e potenza computazionale, mostrando come l'attenzione verso questi elementi sia cambiata nel corso del tempo.

Le due prospettive procedono in parallelo attraverso i vari periodi storici e mostrano come ogni fase abbia reso possibile la successiva, sia all'interno di ciascuna dimensione sia tra una dimensione e l'altra.

2.3.3. Framework concettuale

L'intelligenza artificiale può essere considerata, secondo una visione di alto livello, come un insieme di paradigmi annidabili, che nel corso del tempo hanno segnato dei momenti decisivi per consentire il supporto di alcune attività che in precedenza erano svolte manualmente o non era possibile svolgere. Questo livello non descrive soltanto un'evoluzione temporale, ma una relazione di inclusione tra paradigmi. Infatti, ciascun livello eredita alcuni principi del precedente e ne amplifica le potenzialità mostrando un grado di autonomia delle funzionalità sempre crescente. In particolare, il diagramma di Venn proposto nella Figura 2.4 rappresenta l'annidamento di questi concetti, identificandone il posizionamento nel tempo. Lo schema di Figura 2.4 identifica diverse ere di paradigmi nell'AI [4], [5], [2].




Figura 2.4: Relazione gerarchica tra Intelligenza Artificiale, Machine Learning, Deep Learning e Generative AI, con esempi rappresentativi e principi distintivi, posizionati nel tempo (rielaborazione da IBM, 2024 [4] e Abou Ali et al., 2025 [5]).

Nell'era pre-ML, l'intelligenza artificiale comprendeva tecniche eterogenee che miravano a riprodurre capacità cognitive tramite procedure formalizzate. Si distinguevano tra queste gli approcci simbolici (Symbolic Era, anni '50–'80), basati su regole logiche e motori inferenziali, di cui un caso esemplare è rappresentato dai sistemi esperti. Lo stesso periodo è caratterizzato anche da altri approcci, di carattere più numerico, come le logiche Fuzzy, spesso integrate nei sistemi esperti per gestire l'incertezza in modo più rigoroso, e tecniche ispirate ai principi evolutivi, come gli algoritmi genetici, utilizzate per l'ottimizzazione iterativa di soluzioni complesse.

Con l'arrivo del Machine Learning ('80–2010) si assiste a un cambio di paradigma: si passa dalla programmazione esplicita per compiti specifici dell'era precedente, all'addestramento di un algoritmo che deve prendere decisioni o fare previsioni a partire dai dati, dando il via all'era del data driven e degli approcci statistici.

Dal 2010 si afferma il Deep Learning (DL), una sottocategoria del ML basata su reti neurali profonde capaci di apprendere autonomamente strutture e pattern complessi anche da dati non strutturati [6], un progresso reso possibile dall'aumento della potenza di calcolo e dalla disponibilità di grandi dataset. Dalle architetture di deep learning nascono i modelli generativi, dai primi GAN per la generazione di immagini ai modelli di grandi dimensioni (LLM) basati su architettura Transformer, progettati per produrre contenuti originali come testo e codice. Questi sviluppi pongono le basi per i sistemi ad agenti moderni (Agentic AI Era dal 2022 a oggi), collocati da Gartner sul picco delle aspettative nell'Hype Cycle 2025 [7].

L'Agentic AI non rientra nel diagramma di Venn tradizionale, poiché non costituisce un nuovo paradigma di apprendimento, bensì un livello architetturale superiore e trasversale, che consente compiti di pianificazione, azione e controllo, e che arriva, nei sistemi Multi-Agent, a coordinare autonomamente agenti specializzati.

Una nota importante riguarda il cosiddetto “conceptual retrofitting” [5]. A tal proposito, Abou Ali et al. (2025) evidenziano che l'era dell'Agentic AI moderna non è una prosecuzione lineare dell'intelligenza artificiale classica, ma una discontinuità architetturale fondata su basi interamente neurali, in cui la pianificazione non dipende da regole e strutture simboliche, ma dai processi stocastici di generazione e integrazione dei modelli linguistici di grandi dimensioni (LLM).

2.3.3.1. Evoluzione delle fasi tecnologiche

L'evoluzione dell'intelligenza artificiale può essere letta non solo sul piano concettuale, ma anche attraverso una prospettiva tecnologica che si è sviluppata in parallelo ed è stata abilitante alla nascita dei diversi paradigmi. Questa evoluzione può essere interpretata come un progressivo riequilibrio tra tre componenti fondamentali: algoritmi, potenza di calcolo e dati [8].

Inizialmente, negli anni '50, il fattore centrale erano gli algoritmi, poiché i sistemi simbolici si basavano su regole logiche esplicite per risolvere problemi specifici, mentre dati e capacità di calcolo svolgevano un ruolo di

supporto, sebbene la memoria limitata e le CPU esistenti si mostravano elementi vincolanti per l'elaborazione efficiente. Negli anni '80 l'attenzione verso le reti neurali riemergeva con l'algoritmo di backpropagation, ma la scarsità di dataset e l'assenza di hardware specializzato ne limitavano l'applicazione.

Il modello AlexNet del 2012 segna un cambiamento radicale, poiché la crescente capacità computazionale cominciò a superare l'innovazione algoritmica come principale motore di progresso, grazie alle GPU, in grado di accelerare calcoli massivi tramite migliaia di core paralleli, eseguendo operazioni numeriche simultanee non realizzabili con le CPU single-thread. Da quel momento, gran parte dei progressi dipendeva dall'uso di hardware specializzato: prima le GPU, poi le TPU e altri acceleratori personalizzati, capaci di elaborare enormi dataset in tempi molto brevi.

Con le leggi di scaling di Kaplan [9] si riesce a dimostrare che aumentando le dimensioni dei modelli e dei dataset di addestramento è possibile far emergere capacità nuove e qualitativamente superiori, come dimostrato dai primi GPT, che hanno evidenziato notevoli abilità nella generazione di testo, una volta raggiunti livelli sufficientemente elevati di parametri e di dati di addestramento.

L'importanza dei dati, già evidente nei primi modelli di machine learning che richiedevano dataset etichettati e ben strutturati, diventa ancora più decisiva con i modelli di grandi dimensioni, che necessitano di tante informazioni diversificate e di qualità. A partire dal 2021 è stato formalizzato il concetto di data-centric AI (Andrew Ng, 2021), definita come "la disciplina di ingegnerizzare sistematicamente i dati necessari per costruire un sistema di intelligenza artificiale di successo". A differenza dell'approccio tradizionale model-centric, la data-centric AI mantiene fisso il modello e interviene sui dati, puntando sulla qualità oltre che la quantità, diventando così la base per il funzionamento degli attuali foundation models e dei sistemi agentivi.

2.4. *Classificazione delle principali famiglie di AI*

2.4.1. Piani di classificazione

Dopo aver presentato i principali paradigmi dell'intelligenza artificiale e lo sviluppo tecnologico che ne ha abilitato la diffusione, l'analisi procede verso un livello di dettaglio superiore adottando una prospettiva tassonomica. In letteratura esistono numerose proposte di classificazione, ma trovare un equilibrio tra completezza e coerenza è complesso, poiché le categorie tendono a sovrapporsi e risultano spesso interdipendenti, rendendo le dimensioni di categorizzazione non pienamente ortogonali.

In questa tesi si propone un tentativo di classificazione basato su un piano principale, selezionato per offrire un'analisi ampia e organica del panorama, integrando di volta in volta altri assi classificatori per evidenziare concetti rilevanti ai capitoli successivi e costruire un quadro coerente con la letteratura esistente. Tra le diverse proposte di classificazione, emerge quella di Liang, Wang e Tong [2], che propone una tassonomia tridimensionale basata su tipo di rappresentazione, struttura del compito inferenziale e contesto applicativo.

- **Tipo di rappresentazione:** descrive come la conoscenza è utilizzata nel ragionamento, distinguendo tra ragionamento simbolico, statistico, neurale e ibrido. Mentre quello simbolico è caratterizzato da rappresentazioni discrete e interpretabili con processi deduttivi, il ragionamento statistico modella l'incertezza e consente di apprendere dai dati attraverso modelli probabilistici o inferenza statistica. Nel ragionamento neurale invece, le inferenze emergono da trasformazioni multilivello e schemi latenti. Infine, l'approccio neuro-simbolico, di natura ibrida, unisce l'abilità delle reti neurali nei compiti percettivi con la trasparenza e l'interpretabilità dei modelli simbolici.
- **Struttura del compito inferenziale:** riguarda la logica del ragionamento sottostante, e si legge in termini di ragionamento deduttivo, induttivo, abduttivo e analogico. Quello deduttivo, che parte da regole generali per arrivare a conclusioni specifiche, è alla base della logica classica e dei sistemi simbolici. Il ragionamento induttivo invece, generalizza a partire da esempi specifici e caratterizza tipicamente i metodi di apprendimento automatico. Nel ragionamento abduttivo, l'obiettivo è risalire alla causa di

un fenomeno osservato formulando ipotesi in condizioni di incertezza. Infine, in quello analogico, si trasferisce conoscenza da un dominio noto a uno nuovo sulla base delle somiglianze individuate. Quest'ultimo approccio è particolarmente utilizzato nel visual reasoning, per riconoscere strutture o pattern simili in immagini diverse, e nel question answering, dove permette di adattare conoscenze pregresse a situazioni nuove in modo creativo.

- Contesto applicativo: rappresenta la differenza tra domini chiusi, strutturati e stabili dove regole e dati sono noti; e domini aperti, dinamici e incerti in cui il sistema deve gestire l'incertezza e adattarsi alle nuove informazioni ricevute.

Un'altra possibile classificazione è quella proposta da Dutta [3], che identifica diversi piani categoriali per organizzare l'AI, tra cui quelli basati su: capabilities, functionality, tecniche e purpose.

- Capabilities: definisce l'ampiezza dei compiti che un sistema di AI è in grado di svolgere. La Narrow AI, attualmente predominante, è progettata per compiti specifici, con elevata efficienza ma limitata capacità di generalizzazione al di fuori del proprio dominio. Forme più avanzate, ancora in parte teoriche come AGI e Super intelligent AI, mirano a eguagliare o superare le capacità cognitive umane. La trattazione può essere estesa anche in termini di livelli [8]: Weak–Narrow, per sistemi che eseguono compiti specifici senza comprensione, Weak–Strong e Narrow–Broad che identifica un livello intermedio e Strong–General, per AI in grado di comprensione reale e generalizzata, capace di affrontare molteplici compiti.
- Functionality: classifica l'AI in base alla complessità funzionale e al grado di autonomia, distinguendo tra Reactive e Limited memory Machines, Theory of Mind e Self-Aware Systems. Le Reactive Machines rappresentano la forma più semplice, prive di memoria e di capacità di apprendimento, reagiscono in modo deterministico agli stessi stimoli. Le Limited Memory Machines invece, si avvalgono di dati storici per orientare le decisioni. Esempi attuali includono sistemi come ChatGPT, che utilizza memoria a breve termine durante la sessione di conversazione e memoria a lungo termine durante l'addestramento. Pur migliorando nel tempo tramite feedback, questi sistemi non possiedono una comprensione effettiva e riescono ad adattarsi a nuovi contesti solo tramite addestramento specifico. Infine, le Theory of Mind e le Self-Aware Systems costituiscono categorie ancora teoriche. La prima mira a consentire all'AI di comprendere emozioni e stati mentali umani, mentre la seconda ipotizza sistemi dotati di autocoscienza.
- Purpose: analizza come l'AI interagisce con le decisioni e le attività umane, distinguendo due principali modalità operative. Da una parte l'Assistive AI (o Augmentative AI), che supporta l'uomo nell'analisi dei dati, nella proposta di soluzioni o nell'automazione parziale di compiti, lasciando però la decisione finale e la supervisione al controllo umano; dall'altra, i sistemi Autonomous, che ricevono un obiettivo e lo perseguono in completa autonomia, gestendo processi o interazioni nel mondo reale senza richiedere una guida costante.
- Techniques: questo piano riprende in parte quello proposto da Liang, Wang e Tong, basato sul tipo di rappresentazione. Infatti, le dimensioni di apprendimento simbolico, statistico, neurale e ibrido vengono lette in questo caso dal punto di vista delle tecniche, metodi, algoritmi e architetture che nella pratica hanno diversificato i principi di funzionamento alla base dei vari paradigmi: simbolico, evolutivo e bio-ispirato, Machine Learning, Deep Learning e AI ibrida.

Il piano di classificazione basato sulle tecniche sarà adottato come principio guida per la tassonomia di dettaglio. Questa impostazione consente da un lato, di esplorare in modo più approfondito rispetto ad altre prospettive la varietà degli approcci che compongono il funzionamento degli strumenti di Intelligenza Artificiale [3], adattandosi a una comprensione di carattere accademico; dall'altro, si rivela particolarmente utile per i professionisti del settore nella selezione del metodo, o della combinazione di approcci, più adatti a rispondere ai bisogni concreti di specifiche applicazioni, come quelle legate ai processi di progettazione. Lo schema ad albero

in Figura 2.5 rappresenta il primo livello della categorizzazione, successivamente sviluppato attraverso la rassegna delle tecniche corrispondenti a ciascun paradigma. Le sezioni che richiedono approfondimenti specifici, utili agli scopi della tesi, potranno discostarsi da questo piano di classificazione per tecniche, integrando nuovi elementi di supporto per garantire una trattazione completa e di riferimento per i capitoli successivi.




Figura 2.5: Classificazione per tecniche.

2.4.2. AI simbolica

L’intelligenza artificiale simbolica costituisce la fase fondativa dell’AI, basata sulla manipolazione esplicita di simboli e regole logiche per riprodurre ragionamento e processi decisionali umani. Questo paradigma presuppone che la conoscenza possa essere formalizzata in proposizioni, regole e concetti, e che il ragionamento derivi dall’applicazione di inferenze logiche, adottando un approccio top-down. Pur essendo stata in gran parte superata dai metodi data-driven, resta utile in domini strutturati e regolati, come la pianificazione strutturata, la configurazione logica o il ragionamento giuridico, e sopravvive oggi in forma ibrida all’interno di sistemi moderni, ad esempio nelle basi di conoscenza e nei knowledge graph [10]. Lo schema riportato in Figura 2.6, tratto da Taxonomy of Artificial Intelligence (Dutta, 2025) [3], riporta i principali algoritmi e modelli.




Figura 2.6: Tassonomia dell’AI simbolica con metodi e algoritmi più noti, schema rielaborato da tabella di Taxonomy of Artificial Intelligence [3].

Durante l'era simbolica emersero diverse linee metodologiche, ciascuna capace di versare un contributo specifico allo sviluppo del campo [2]. Il Logicismo, basato sull'idea che il ragionamento possa essere modellato tramite sistemi di logica formale [10], portò ai primi dimostratori automatici di teoremi e formalismi per la pianificazione logica. Gli algoritmi di risoluzione e unificazione permisero di automatizzare la prova logica, mentre la programmazione logica trovò la sua espressione in Prolog (Kowalski, R., & Colmerauer, A. 1972), che integrava un motore di inferenza basato su backward chaining, conservando un approccio di carattere deduttivo.

Un'applicazione nota del ragionamento logico furono proprio i sistemi esperti, che utilizzavano regole if-then codificate manualmente per replicare il processo decisionale umano [2]. Tali motori operavano attraverso due modalità principali: il forward chaining, che a partire da fatti noti deriva nuove conclusioni e il backward chaining, che parte da un obiettivo per risalire alle premesse necessarie. Inoltre, si servivano di un meccanismo di pattern matching per confrontare le condizioni espresse dalle regole con i fatti presenti nella base di conoscenza. Sistemi esperti come MYCIN e DENDRAL (Shortliffe, E.H.; Buchanan, B.G. 1975, Buchanan, B.G.; Feigenbaum 1978) dimostrarono la capacità del ragionamento simbolico di supportare il decision making, pur evidenziando il limite del cosiddetto knowledge acquisition bottleneck, ovvero il rallentamento dovuto alla traduzione manuale del sapere umano in regole formali esplicite [11]. Lungo questa linea si collocano anche i production systems (Newell & Simon, 1972, Forgy 1982), motori a regole come CLIPS e OPS5 (Giarratano, J.C 1989, Forgy 1989), oltre ai primi risolutori di vincoli (Mackworth, 1977, Dechter 2003) impiegati per problemi di configurazione e schedulazione.

Per superare i limiti della logica classica caratterizzata da monotonicità, nacquero formalismi di logica non monotona e del default (Reiter, 1980), che permisero di ritrattare le inferenze alla luce di nuove informazioni, avvicinando la Symbolic AI al ragionamento di senso comune. Sviluppi correlati, come i Truth Maintenance Systems (TMS) (Doyle 1979, McAllester 1980) e i framework di revisione delle credenze, furono introdotti per mantenere la coerenza dinamica delle basi di conoscenza in presenza di nuove informazioni [12].

Inoltre, la ricerca sulle rappresentazioni concettuali della conoscenza portò alla nascita delle reti semantiche e dei frame-based systems (Quillian, M. R. 1966 Minsky, M. 1974), che formalizzavano relazioni gerarchiche tra concetti, mentre la logica descrittiva (Description Logic) (Baader. 2003) offrì una base rigorosa e trattabile dal punto di vista computazionale per la rappresentazione ontologica, divenendo il fondamento dei knowledge graph e del Web Semantico (Brachman, 1985, McGuinness 2004).

La rappresentazione simbolica della conoscenza trovò applicazione anche in domini pratici come la schedulazione e l'allocazione di risorse, nei quali i problemi venivano formalizzati come insiemi di vincoli logici su oggetti, attributi e relazioni. Queste attività, pur strettamente connesse ai sistemi esperti e ai motori di regole, rientrano nell'ambito della Knowledge Representation (Minsky 1974), poiché richiedono modelli ontologici capaci di esprimere in modo esplicito le dipendenze tra componenti e risorse. Infine, le logiche modali e temporali, introdussero operatori per esprimere necessità, possibilità, credenze e conoscenze (Hintikka, 1962), tramite cui fu reso possibile modellare il ragionamento su stati mentali e sull'evoluzione temporale dei sistemi (es. logiche LTL e CTL), costituendo la base per la verifica di programmi, la pianificazione sotto incertezza e il ragionamento multi-agente [2].

2.4.3. AI evolutiva e bio-ispirata

L'approccio basato sul calcolo bio-ispirato riguarda quelle tecniche che traggono ispirazione sia dai meccanismi evolutivi sia dai comportamenti collettivi osservati in natura. In particolare, si distinguono due dimensioni appartenenti a questa categoria: il calcolo evolutivo e la Swarm intelligence.

Il calcolo evolutivo include algoritmi di ottimizzazione che mantengono una popolazione di soluzioni candidate e la fanno evolvere nel tempo applicando iterativamente operatori di selezione, mutazione e ricombinazione, valutando ogni individuo attraverso una funzione di fitness, che rappresenta il criterio prestabilito utilizzato per guidare la selezione [13] [3]. Questi metodi sono efficaci per problemi complessi e con spazi di ricerca ampi o non lineari, riuscendo spesso a fornire buone soluzioni di compromesso tra più variabili da bilanciare [14] [15]. Tuttavia, possono essere computazionalmente onerosi, in quanto richiedono la valutazione ripetuta delle soluzioni candidate, e convergere lentamente [16].

La swarm intelligence invece, riguarda quelle tecniche basate sul comportamento collettivo di agenti semplici che, tramite interazioni locali e auto-organizzazione, generano soluzioni globali efficaci [17]. Ne sono esempio gli algoritmi delle colonie di formiche e gli algoritmi a sciame di particelle, entrambi ispirati ai meccanismi naturali di cooperazione e adattamento per la risoluzione di problemi complessi [18] [19]. La schematizzazione di Figura 2.7 riporta le principali tecniche appartenenti al paradigma in questione.




Figura 2.7: Tassonomia dell'AI evolutiva e bio-ispirata con metodi e algoritmi più noti, schema rielaborato da tabella di Taxonomy of Artificial Intelligence [3].

A partire dal calcolo evolutivo, è possibile individuare un sottoinsieme di tecniche specificatamente orientate all'ottimizzazione, tra cui: Evolution Strategies, Genetic Algorithms e Differential Evolution.

Le Evolution Strategies svolgono l'ottimizzazione di funzioni reali senza richiedere derivata, mediante mutazione adattativa e selezione dei parametri nel tempo [13]. Presentano una variante più moderna, la Covariance Matrix Adaptation Evolution Strategy (CMA-ES), in cui la matrice di covarianza, che rappresenta la distribuzione di mutazione, è aggiornata automaticamente per catturare le correlazioni tra le dimensioni del problema, permettendo di raggiungere più facilmente la convergenza [20]. Questi metodi, che rientrano nella famiglia dei Derivative-Free Optimization, sono particolarmente adatti a problemi black-box caratterizzati da modelli complessi o non differenziabili, in cui l'ottimizzazione avviene solo tramite valutazioni dirette della funzione di fitness [21], senza necessità di derivazioni e di calcolo del gradiente.

I Genetic Algorithms invece, sono algoritmi ispirati ai processi genetici e rappresentano le soluzioni come cromosomi. A questi applicano crossover, mutazione e selezione, operando su spazi discreti o misti. Infine, il Differential Evolution, un algoritmo semplice e robusto per spazi continui non differenziabili [22], che genera nuovi candidati combinando vettori della popolazione con un fattore di scaling. Tutti questi metodi appartengono alle Population-Based Metaheuristics, che costituiscono la base comune anche degli algoritmi e i metodi di swarm intelligence. Questa famiglia comprende algoritmi fondati su popolazioni di soluzioni candidate che evolvono e interagiscono nel tempo mediante meccanismi di competizione e cooperazione [23], con l'obiettivo di preservare le soluzioni migliori. Sono particolarmente usati per risolvere problemi multi-obiettivo, dove è cruciale mantenere

diversità e parallelismo nella ricerca per ottimizzare contemporaneamente dimensioni eterogenee, come nella progettazione ingegneristica, nel parameter tuning o nell’allocazione delle risorse.

Allo stesso modo, anche nella swarm intelligence rientrano diversi algoritmi di ottimizzazione. Tra questi la Particle Swarm Optimization è un algoritmo di sciame in cui ogni particella esplora lo spazio di ricerca aggiornando la propria velocità in base alle migliori posizioni personali e globali, utile per il tuning di parametri e l’ottimizzazione di funzioni complesse [24]. A seguire l’Ant Colony Optimization, ispirato al deposito di feromoni delle formiche per individuare percorsi ottimali [25] e per concludere l’ Artificial Bee Colony, basato sul comportamento collettivo delle api nella ricerca del cibo, dove si sviluppano dei meccanismi di cooperazione per individuare il massimo o minimo di una funzione obiettivo [26], che trova applicazioni in casi d’uso come la Resource Allocation e il Clustering.

2.4.4. Machine Learning

Il machine learning si basa su un approccio bottom-up, nel quale i modelli apprendono direttamente dai dati senza richiedere la definizione esplicita di regole. A partire dai dati di training, costruiscono una rappresentazione del problema e la utilizzano per prevedere o decidere, distinguendosi per la capacità di gestire incertezza, rumore e di migliorare con l’esperienza. Questo paradigma risulta estremamente versatile, poiché gli stessi algoritmi possono essere impiegati in ambiti molto diversi, a differenza dei metodi simbolici che necessitano di una riprogettazione specifica per ogni compito. Rimangono tuttavia limiti noti, come la scarsa interpretabilità e la dipendenza da grandi quantità di dati, con la possibilità di apprendere correlazioni spurie [3].

Il ML comprende diverse modalità di apprendimento, tra cui le principali sono: supervisionato, non supervisionato e per rinforzo, sebbene spesso vengano considerate anche varianti derivate come il semi-supervisionato e l’auto supervisionato. Tali modalità si distinguono in base al tipo di problema e alla natura dei dati in ingresso [27] [28], come rappresentato schematicamente in Figura 2.8.




Figura 2.8: Tecniche di apprendimento nel ML, figura tratta da “Machine Learning and Deep Learning Paradigms: From Techniques to Practical Applications and Research Frontiers” [28].

L’apprendimento supervisionato si basa su dataset etichettati, dai quali i modelli apprendono le relazioni tra dati ed etichette per generalizzare su nuovi esempi. Il training avviene mediante la minimizzazione di una funzione di loss, che misura l’errore tra la previsione del modello e l’etichetta corretta, guidando l’ottimizzazione dei parametri. Consente di affrontare compiti di classificazione per output discreti o categorici, e di regressione per output numerici o continui.

Al contrario, l’apprendimento non supervisionato permette di individuare strutture, schemi o raggruppamenti nei dati senza etichette, tramite tecniche come clustering e association, che raggruppano o collegano gli elementi in base a somiglianze, correlazioni o dipendenze, senza una funzione obiettivo diretta.

Inoltre, la terza modalità corrisponde all'apprendimento per rinforzo, in cui un agente interagisce con un ambiente e mediante meccanismi di ricompensa e penalità, apprende a ottimizzare il proprio comportamento al fine di massimizzare il reward cumulativo.

Infine, le varianti semi-supervisionata e auto-supervisionata estendono le modalità principali, con la prima che combina dati etichettati e non etichettati per migliorare accuratezza e generalizzazione, e la seconda che sfrutta grandi quantità di dati non etichettati per predire porzioni di dati, riducendo la necessità di annotazioni manuali e costituendo la base dei moderni modelli di linguaggio e visione artificiale.

Seguendo la classificazione per tecniche adottata anche per gli altri approcci, viene presentata la tassonomia dei principali algoritmi e metodi di machine learning, con l'indicazione delle rispettive famiglie e delle applicazioni di riferimento (Figura 2.9).




Figura 2.9: Tassonomia del ML con metodi e algoritmi più noti, schema rielaborato da tabella di Taxonomy of Artificial Intelligence [3].

La prima tecnica a cui lo schema si riferisce cita una famiglia di modelli, i Generalized Linear Models (GLM), una base teorica del Machine Learning tradizionale in quanto introducono il concetto di relazione probabilistica tra input e output. Questi modelli statistici sono detti generalizzati perché estendono la regressione lineare classica per gestire variabili dipendenti non necessariamente rappresentabili mediante una distribuzione normale, come dati categorici, binari o di conteggio, mediante l'uso di una funzione di collegamento che, in funzione del problema, adatta il modello al tipo di dato e alla distribuzione dell'output. Per esempio, la regressione lineare utilizza la distribuzione normale con funzione identità, mentre la regressione logistica adotta una distribuzione binomiale con funzione logit, rispettivamente per predizione continua e classificazione binaria o multiclasse [29] [30].

I Decision Trees, invece, sono modelli di apprendimento supervisionato che rappresentano il processo decisionale tramite una struttura ad albero: i nodi interni definiscono condizioni basate sui dati, i rami rappresentano i risultati della verifica di tali condizioni e i nodi foglia forniscono la previsione di classificazione o

regressione. Durante l'apprendimento il modello elabora i dati di training e sceglie le condizioni di suddivisione, condizioni if- then che consentono di realizzare l'obiettivo di previsione in modo interpretabile.

La Random Forest estende questo approccio mediante un ensemble di alberi indipendenti addestrati su sottoinsiemi casuali di dati e variabili, aggregando le predizioni tramite voto o media. È un metodo noto per ridurre i limiti dei singoli alberi, come l'overfitting e il miglioramento dell'accuratezza, anche se richiede maggiore complessità computazionale [31] [32].

Inoltre, un'altra tecnica supervisionata è rappresentata dalle Support Vector Machines (SVM), algoritmi utilizzati per problemi di classificazione binaria o multiclasse [33]. Il principio di funzionamento consiste nel trovare una linea o un iperpiano che separi al meglio due gruppi di dati, massimizzando la distanza tra le classi [31]. Mediante l'uso di funzioni kernel, possono gestire dati non linearmente separabili proiettandoli in spazi di dimensione superiore [28].

Un'altra tecnica menzionata è quella del Gradient Boosting, nota come metodo ensemble basato sull'ottimizzazione matematica, capace di modellare relazioni complesse nei dati per eseguire previsioni con grande precisione. A partire da un modello iniziale che definisce una previsione grezza, costruisce iterativamente nuovi modelli, tipicamente alberi decisionali, per correggere gli errori del precedente, seguendo la direzione del gradiente della funzione di perdita. Il modello finale è costituito da numerosi alberi in sequenza, ciascuno addestrato sugli errori residui dei precedenti, in cui l'accuratezza complessiva risulta migliorata. Tale metodo trova ampio impiego in compiti di classificazione, regressione, ranking e previsione di serie temporali [34].

Per concludere la rassegna delle metodologie in cui emerge come principio chiave la natura statistica, la PCA è una tecnica che riduce il numero di variabili di un dataset combinandole in nuove componenti principali, tramite le quali è possibile spiegare la varianza dei dati in modo più compatto e non correlato.

La tassonomia di riferimento include inoltre il K-Nearest Neighbors (KNN), un algoritmo supervisionato definito "lazy" perché memorizza tutte le istanze del dataset invece di costruire un modello sottostante. Pur trovando ampio impiego nei sistemi di raccomandazione, l'insieme delle sue caratteristiche lo rende computazionalmente oneroso, poiché, oltre a memorizzare tutti i dati, per predire un output confronta ogni punto con i k punti vicini più simili tramite calcolo ripetuto delle distanze [31].

Nel modello Naive Bayes invece, trova rappresentazione un classificatore probabilistico che assume l'indipendenza condizionale tra effetti riconducibili a una singola causa, ipotesi che seppur spesso irrealistica, rende il modello contemporaneamente semplice, efficace e leggero dal punto di vista computazionale. Trova applicazione in compiti il cui output viene generato con una certa probabilità, come riconoscimento del linguaggio, il filtraggio antispam e classificazione di testi. Quando invece si necessita di probabilistiche più precise, ad esempio in ambito medico, si ricorre a modelli bayesiani più complessi [10] [33].

Infine, tra i metodi di apprendimento non supervisionato, il K-Means ricopre un ruolo centrale ed è ampiamente utilizzato in compiti di clustering come la customer segmentation. L'algoritmo raggruppa i dati in k cluster minimizzando la distanza quadratica tra punti e centroidi [28] [33]; dopo una selezione casuale dei centroidi iniziali, assegna iterativamente ciascun punto al centro più vicino e aggiorna le posizioni finché non si raggiunge la convergenza, che tuttavia non è sempre garantita. Esistono alcune varianti e ottimizzazioni come il k-means gerarchico che itera il clustering creando una struttura multilivello di gruppi e il fuzzy k-means, che assegna a ciascun campione diverse probabilità di appartenenza ai cluster, rendendo la descrizione dei dati più realistica.

Classificazione in base al principio di apprendimento

Come già evidenziato, lo schema di Figura 2.9 propone una tassonomia volta a illustrare le tecniche e gli algoritmi più rappresentativi, evidenziando le famiglie metodologiche o i principi matematici alla base dei modelli. Per questo motivo, gli esempi riportati non mirano a fornire una rappresentazione esaustiva dei vari approcci di apprendimento. Per garantire una visione più completa, in Appendice C è presente una tabella riassuntiva (Tabella C.1, rielaborazione tratta dalle fonti [27], [33], [35]) che organizza gli algoritmi secondo i principi di apprendimento, includendo anche alcuni approcci non citati nello schema principale a causa della diversa finalità di rappresentazione.

La tipologia di dati

Un aspetto fondamentale nel Machine Learning è la tipologia dei dati su cui i modelli vengono addestrati. In particolare, si distinguono dati strutturati, semi-strutturati e non strutturati, dove ciascun tipo di dato si presta meglio a specifiche categorie di apprendimento [28].

- **Dati strutturati:** sono organizzati secondo schemi predefiniti come tabelle di database relazionali e sono adatti soprattutto a metodi supervisionati per analisi numeriche e predizioni. Tra questi, le serie temporali costituiscono un caso particolare, in quanto registrano valori osservati in momenti successivi e regolari nel tempo, permettendo di analizzare evoluzioni o variazioni di comportamenti dinamici e di prevedere valori futuri sulla base di dati storici, come nella stima della domanda o nell'ottimizzazione delle risorse.
- **Dati non strutturati:** non seguono alcun formato regolare e comprendono testi, immagini, file audio e video. Sono maggiormente adatti a tecniche di Deep Learning e di apprendimento non supervisionato. Ad esempio, il Natural Language Processing (NLP) è lo strumento principale per analizzare testi e ricavarne conoscenza.
- **Dati semi-strutturati:** presentano un'organizzazione parziale senza struttura rigida e includono formati come: XML, JSON e database NoSQL. Trovano impiego in applicazioni di Machine Learning quali i sistemi di raccomandazione, che combinano informazioni eterogenee per suggerire contenuti personalizzati.

2.4.5. Deep Learning

Il Deep Learning costituisce un sottoinsieme del machine learning e si sviluppa intorno al concetto di reti neurali artificiali (Artificial neural Networks ANN). Si tratta di strutture di neuroni che si ispirano al cervello umano, organizzati in diversi strati: uno strato iniziale che riceve l'input; strati intermedi nascosti che servono a estrarre e trasformare progressivamente le caratteristiche dei dati; e il livello di output che restituisce il risultato dell'elaborazione. Le reti shallow sono le versioni più elementari: possiedono pochi strati nascosti e sono adatte a compiti semplici o dataset piccoli. Mentre le Deep Neural Network (DNN), presentano molti strati intermedi e apprendono rappresentazioni gerarchiche e pattern complessi. L'addestramento delle reti neurali si basa sulla backpropagation [36], un algoritmo che calcola l'errore tra output prodotto e desiderato (loss) e lo retropropaga dalla fine all'inizio della rete. I pesi vengono aggiornati tramite gradient descent, modificandoli nella direzione che riduce la loss per migliorare progressivamente le prestazioni del modello [37]. Queste reti apprendono automaticamente le caratteristiche dai dati grezzi, gestendo relazioni non lineari e dati non strutturati come immagini, testo e audio, eliminando la feature engineering manuale, tipica del ML tradizionale. Tuttavia, richiedono grandi quantità di dati e risorse computazionali e presentano limiti in termini di interpretabilità e bias [3]. A seguire, la tassonomia per tecniche relativa a tale paradigma (Figura 2.10).




Figura 2.10: Tassonomia del DL con metodi e algoritmi più noti, schema rielaborato da tabella di Taxonomy of Artificial Intelligence [3].

Una precisazione da chiarire in riferimento alla classificazione di Figura 2.10, è che predilige una trattazione basata sul principio di funzionamento o sulla modalità di rappresentazione delle informazioni, piuttosto che su aspetti puramente strutturali e architetturali. Per questo motivo, alcuni approcci citati, come le Deep Belief Networks, i modelli autoregressivi neurali e il Deep Reinforcement Learning, pur essendo di tipo connessionista nella struttura, vengono collocate in categorie che evidenziano la chiave interpretativa del loro funzionamento, ad esempio la natura probabilistica o statistica, oppure l'uso di un particolare metodo di apprendimento.

In maniera complementare, si è ritenuto opportuno affiancare alla classificazione per tecniche una tassonomia alternativa (Figura 2.11), proposta da Sarker (2021) [36], la quale adotta una prospettiva fondata sul tipo di apprendimento e sulla natura probabilistica dei modelli, distinguendo le tecniche in discriminative (supervisionate), generative (non supervisionate) e ibride.




Figura 2.11: Classificazione delle tecniche DL in base alla modalità di apprendimento e alla formulazione probabilistica [36].

Lo schema proposto in Figura 2.11 deve essere inteso come una rappresentazione delle associazioni più comuni e ricorrenti tra architetture, formulazioni probabilistiche, modalità di apprendimento e contesti di utilizzo, piuttosto che come una tassonomia teorica rigorosa. Le relazioni evidenziate riflettono infatti configurazioni tipiche e pratiche applicative consolidate, ma non esauriscono la molteplicità di combinazioni possibili né implicano legami univoci tra i diversi livelli considerati. Ciononostante, lo schema risulta funzionale all'introduzione di ulteriori piani classificatori che permettono di separare e chiarire alcuni concetti rilevanti ai fini della tesi.

Un primo passaggio importante è quello che punta a distinguere tra architettura neurale, formulazione probabilistica del modello e funzione di apprendimento. L'architettura definisce la struttura computazionale attraverso cui viene approssimata una funzione e resta trasversale a diverse formulazioni probabilistiche, consentendo quindi implementazioni di modelli sia discriminativi sia generativi.

La funzione di apprendimento rappresenta il criterio di ottimizzazione, ad esempio massimizzazione di verosimiglianza, minimizzazione di una loss discriminativa, training avversario o denoising, e può essere vista come il mezzo operativo con cui viene implementato l'obiettivo di apprendimento, in modo coerente con le assunzioni probabilistiche.

Infine, la formulazione probabilistica stabilisce quale distribuzione viene stimata e con quali assunzioni. In particolare, la distinzione tra modelli generativi e discriminativi è riconducibile a questo livello e può essere formalmente espressa attraverso la regola di Bayes che stabilisce la relazione tra la distribuzione congiunta dei dati e quella condizionata, descritta in F1:

$$p(x|y) = \frac{p(y|x)p(x)}{p(y)} \quad \text{[F1]}$$

(tratta da Argouarc'h, Desbouvries, Barat & Kawasaki, 2024 [38])

Nei modelli generativi, l'obiettivo è descrivere il processo che genera le osservazioni, in modo da poter creare nuovi esempi plausibili. Questo si traduce nel modellare la probabilità congiunta tra variabili osservate y e variabili latenti o classi x , a seconda se la modalità di apprendimento è supervisionata o non supervisionata.

Denotando con $\pi(x) = p(x)$ il prior di x , cioè la probabilità di osservare x prima di vedere y , si può esprimere il modello generativo come F2:

$$pG(x|y, \theta) = \frac{p\theta(y|x)\pi(x)}{\int p\theta(y|x)\pi(x)dx} \quad [F2]$$

(tratta da Argouarc'h, Desbouvries, Barat & Kawasaki, 2024 [38])

Dove $p\theta(x|y)$ è il modello parametrico (parametri θ) che descrive come i dati y vengono generati a partire dalla variabile latente o dalla classe x , mentre il denominatore normalizza la distribuzione.

Al contrario, un modello discriminativo mira a stimare direttamente la probabilità condizionata della classe dato l'input, senza modellare esplicitamente il processo di generazione né includere un prior, come emerge dall'espressione F3:

$$pD(x|y, \theta) = p\theta(x|y) \quad [F3]$$

(tratta da Argouarc'h, Desbouvries, Barat & Kawasaki, 2024 [38])

Dove y è l'osservazione, x la classe o etichetta del dato e $p\theta(x|y)$ modella la probabilità che il dato appartenga alla classe x dato che è stato osservato y , parametrizzata da θ . In altri termini questo significa che i modelli discriminativi imparano a distinguere focalizzandosi sulla separazione tra categorie piuttosto che sulla riproduzione dei dati.

Complessivamente, la distinzione principale tra modelli discriminativi e generativi riguarda la distribuzione appresa: i discriminativi stimano direttamente la probabilità condizionata $P(y/x)$, quelli generativi calcolano la probabilità congiunta $P(x,y)$ o la semplice distribuzione dei dati $P(x)$, consentendo anche la generazione di nuovi campioni appartenenti alla stessa distribuzione dei dati osservati.

Dopo aver specificato la differenza tra questi concetti, si possono formulare alcune considerazioni utili alla corretta interpretazione dello schema di Figura 2.11.

Innanzitutto, è opportuno chiarire che l'associazione tra modelli generativi e apprendimento non supervisionato, così come quella tra modelli discriminativi e apprendimento supervisionato, non deve essere interpretata come un vincolo teorico rigido, bensì come una ricorrenza applicativa. La distinzione tra modelli generativi e discriminativi è infatti fondata sulla diversa formulazione probabilistica dell'obiettivo di apprendimento, e non sulla presenza o assenza di etichette nel processo di addestramento.

Tuttavia, i modelli discriminativi risultano naturalmente più compatibili con contesti supervisionati, poiché sono progettati per apprendere una funzione di decisione o una distribuzione condizionata $p(y|x)$, facendo tipicamente uso di informazioni etichettate. I modelli generativi, invece, mirano a modellare la distribuzione dei dati (o una sua versione condizionata), apprendendo rappresentazioni e strutture latenti, e risultano pertanto frequentemente addestrati in modalità non supervisionata o self-supervised rispetto alle classi. Infatti, diversi modelli generativi, quali i Conditional GAN, i Conditional VAE e i modelli di diffusione condizionati, introducono variabili di condizionamento che possono includere informazioni supervisionate, come etichette o attributi. In tali casi, l'apprendimento risulta supervisionato rispetto alla variabile di condizionamento, senza che ciò modifichi la natura generativa della formulazione probabilistica.

Un'ulteriore precisazione riguarda il fatto che le architetture neurali riportate nello schema di Figura 2.11 (ad esempio CNN, RNN, LSTM o MLP) devono essere intese come schemi computazionali generali, formalmente neutri rispetto alla distinzione tra modelli generativi e discriminativi. Sebbene nella rappresentazione tali architetture compaiano associate a specifici modelli, questa associazione riflette prevalentemente il loro impiego applicativo più ricorrente, storicamente legato a una determinata formulazione probabilistica del problema, e non una proprietà intrinseca dell'architettura stessa.

Un'architettura, infatti, non determina né la natura probabilistica del modello né il tipo di distribuzione appresa, né il task svolgibile in senso univoco; essa definisce piuttosto un insieme di vincoli strutturali e computazionali entro cui viene specificata la funzione di apprendimento e che determinano la compatibilità rispetto allo svolgimento di alcuni task. La medesima architettura può pertanto essere impiegata sia in contesti generativi sia discriminativi, in funzione della formulazione del problema, della funzione obiettivo e delle assunzioni probabilistiche adottate.

Una CNN, ad esempio, è comunemente associata a modelli discriminativi, ma può essere resa generativa quando viene inserita in una formulazione autoregressiva, in cui l'architettura convoluzionale è vincolata da una fattorizzazione causale ed è addestrata per massimizzare la verosimiglianza dei dati, come nel caso di PixelCNN.

Allo stesso modo, molte implementazioni dei Diffusion Models adottano una struttura di tipo U-Net (convoluzionale) e risultano generative non per l'architettura in sé, ma per l'obiettivo di denoising, che implementa una procedura di campionamento da una distribuzione appresa.

In modo analogo, architetture ricorrenti (RNN/LSTM) possono essere utilizzate sia per la predizione discriminativa di etichette sia per la generazione di sequenze, mentre architetture come i Transformer possono essere impiegate sia come modelli autoregressivi di linguaggio sia come encoder discriminativi.

Infine, una distinzione più sottile riguarda la separazione tra due piani concettuali differenti di classificazione: da un lato quello basato sulla formulazione probabilistica del modello, dall'altro quello di natura operativa, legato alla tipologia di task svolto dal sistema. Ne consegue che la distinzione tra modelli generativi e discriminativi non coincide necessariamente con la tipologia di task operativo effettivamente eseguito.

Sebbene la modalità con cui i modelli generativi apprendono le rappresentazioni dei dati li renda naturalmente adatti alla generazione di nuovi campioni, essi possono essere impiegati anche in task operativi di classificazione, valutazione o supporto decisionale. In particolare, la modellazione generativa può essere utilizzata come fase di pre-processing o di apprendimento delle rappresentazioni per compiti di apprendimento supervisionato, contribuendo a migliorare l'accuratezza dei modelli discriminativi [36].

Allo stesso modo, componenti discriminative possono intervenire operativamente in processi di generazione o di ricerca di soluzioni, ad esempio come moduli di guida, valutazione o selezione di candidati all'interno di pipeline o architetture più ampie. Nei GAN, in particolare, il discriminatore costituisce una componente discriminativa interna al training avversario, che orienta l'aggiornamento del generatore.

Emerge dunque che, sebbene in alcuni casi i due piani possano sovrapporsi, essi restano concettualmente distinti. A tal proposito il termine "generativo", se considerato in senso probabilistico, implica la possibilità di campionare nuovi dati a partire da una distribuzione appresa; in senso operativo invece, assume un significato più ampio, non riducibile esclusivamente alla formulazione probabilistica del modello, ma dipendente dalla configurazione applicativa del problema e dal ruolo che il componente di AI svolge all'interno del framework complessivo progettato per uno specifico task.

Si noti inoltre che alcune tecniche spesso collocate, per tradizione, nel filone "generative/unsupervised" (ad esempio Autoencoder e SOM) non sono necessariamente generative in senso probabilistico stretto, poiché non sempre definiscono una densità esplicita da cui campionare nuovi dati, esse risultano tuttavia centrali come metodi di apprendimento di rappresentazioni.

Infine, a ulteriore conferma del fatto che tali confini non risultano mai completamente rigidi, esistono modelli ibridi che combinano architetture o paradigmi differenti per ottimizzare capacità rappresentazionali e predittive, accoppiando componenti generative e discriminative (ad esempio GAN+CNN o AE+SVM), oppure integrando più modelli discriminativi all'interno di un'unica architettura (ad esempio CNN+LSTM).

Modelli Discriminativi

Secondo la classificazione proposta dallo schema di Figura 2.11, tra i modelli discriminativi rientrano: il Multi-Layer Perceptron (MLP), le Convolutional Neural Networks (CNN) e le Recurrent Neural Networks (RNN).

I MLP sono modelli discriminativi supervisionati appartenenti alla famiglia delle Feedforward Neural Networks (FNN), caratterizzate dalla propagazione unidirezionale dell'informazione di input, che attraversa tutti

gli strati fino all'uscita, senza retroazioni. Ogni nodo è connesso a tutti quelli degli strati adiacenti [31], e lo strato finale produce una previsione o una decisione a partire dai dati in ingresso. La loro configurazione richiede la regolazione di numerosi iperparametri, rendendo l'addestramento computazionalmente oneroso [36]. I MLP si adattano bene ai dati tabellari, trattati come vettori di variabili indipendenti, ma risultano inadatti all'elaborazione di immagini o sequenze temporali, per le quali sono state sviluppate architetture specializzate.

Tra le altre architetture, assumono particolare rilievo le Convolutional Neural Networks (CNN), specificatamente progettate per l'elaborazione di dati con struttura a griglia attraverso l'apprendimento di gerarchie spaziali di caratteristiche (feature) [39], [40]. Tipicamente elaborano immagini e, nel caso di dipendenze temporali di breve periodo, anche le serie temporali, in cui risultano efficaci nell'estrazione di pattern locali. Devono la loro capacità di apprendere gerarchicamente le caratteristiche alla struttura interna composta da connessioni tra strati nascosti, che in questo caso risultano legati esclusivamente a sottoinsiemi di neuroni dello strato precedente [37].

La struttura si compone principalmente di : strati convoluzionali, che usano filtri (kernel) per estrarre caratteristiche producendo mappe di attivazione; strati di pooling, alternati a quelli convoluzionali, che riducono la dimensione delle mappe di attivazione e il numero di parametri, limitando complessità computazionale e rischio di overfitting; e strati fully-connected, che trasformano le caratteristiche apprese in una previsione finale, tipicamente una probabilità di appartenenza a una classe [33].

Un'altra architettura, tradizionalmente associabile alla dimensione discriminativa e successivamente adattata anche a compiti generativi tramite specifica funzione obiettivo e training, è rappresentata dalle Reti Neurali Ricorrenti (RNN). Queste reti sono progettate per elaborare dati sequenziali grazie alla condivisione dei parametri nel tempo, che consente di applicare a ogni passo della sequenza la stessa funzione di aggiornamento. Questa funzione (f) combina l'input corrente (x_t) con l'informazione accumulata fino al passo precedente (h_{t-1}), producendo così il nuovo stato nascosto (h_t). Il nuovo stato nascosto coincide con la rappresentazione interna che sintetizza le informazioni della sequenza fino al passo t , come descritto dalla relazione F4:

$$h_t = f(h_{t-1}, x_t, \theta) \quad [F4]$$

(come riportato in Goodfellow et al., *Deep Learning* (2016) [40])

Con θ che rappresenta l'insieme dei parametri della rete. Pertanto, la RNN aggiorna progressivamente uno stato ricorrente che costituisce una forma di memoria in grado di propagare informazioni nel tempo e catturare le dipendenze presenti nelle sequenze. Inoltre, è capace di identificare elementi rilevanti indipendentemente dalla loro posizione durante l'addestramento, anche in sequenze di lunghezza variabile, dimostrando capacità di generalizzazione [40], [37]. Recentemente, queste reti hanno mostrato prestazioni promettenti nel trattare serie temporali e segnali vocali [3], e nell'elaborazione del linguaggio naturale, ottenendo risultati soprattutto in applicazioni quali classificazione del sentiment, generazione di didascalie per immagini e traduzione automatica [37].

Tuttavia, le RNN tradizionali soffrono principalmente di due problemi: il vanishing e l'exploding gradient. Il primo, impedisce loro di apprendere dipendenze a lungo termine, riducendo l'accuratezza nei compiti che richiedono informazioni contestuali estese; il secondo, causa instabilità numerica e divergenza del modello. In questa prospettiva nascono delle varianti, LSTM e GRU, che introducono meccanismi di gating, componenti che gestiscono il flusso dell'informazione decidendo cosa memorizzare, aggiornare, dimenticare o restituire, grazie a cui è possibile mantenere la memoria più a lungo, migliorando significativamente le prestazioni [37] [41].

- Gli LSTM introducono una struttura interna composta da tre gate principali: Forget, Input e Output, che regolano rispettivamente quali informazioni eliminare dalla memoria, quali aggiungere e quali rendere disponibili nell'output corrente.
- Le BiLSTM, invece, sono una versione alternativa utile catturare dipendenze bidirezionali, considerando sia il contesto passato sia quello futuro della sequenza, anche se più lentamente e a un costo computazionale superiore.
- Infine, le GRU mantengono la logica dei gate, ma ne utilizzano solo due tipi: l'Update Gate e il Reset Gate. Questi consentono di controllare quanta parte della vecchia memoria deve essere mantenuta

quando si integra il nuovo input. La presenza di soli due gate rende le GRU più rapide da addestrare e computazionalmente meno onerose rispetto alle LSTM.

In sostanza, mentre le LSTM sono utilizzate per modellare sequenze lunghe per le capacità di conservare informazioni distanti nel tempo, le GRU sono predilette per sequenze brevi ma in cui è richiesta maggiore efficienza del modello.

Modelli generativi

Tra i modelli generativi riportati in Figura 2.11, l'analisi che segue si concentra su un sottoinsieme di quelli maggiormente rappresentativi: i Generative Adversarial Networks (GAN), Restricted Boltzmann Machines (RBM), Deep Belief Networks (DBN), Autoencoder e Variational Autoencoder (AE e VAE). Si considerano inoltre i Diffusion Models, non presenti nella distinzione proposta dallo schema, ma rilevanti per le applicazioni discusse nei capitoli successivi.

Le Generative Adversarial Networks (GAN) sono reti neurali progettate per generare nuovi dati simulando la distribuzione di probabilità dei dati di addestramento, producendo nuovi campioni con una certa variabilità [42]. Il loro nome deriva dal metodo di addestramento avversariale sul quale si basano, in cui competono un generatore e un discriminatore in un gioco a somma zero non cooperativo, in cui il guadagno di una rete corrisponde alla perdita dell'altra [37]. In pratica, il generatore crea nuovi campioni sintetici sulla base del modello probabilistico dei dati forniti; mentre il discriminatore misura la probabilità che un campione generato provenga dai dati reali di addestramento, rilevando le incongruenze. Le due reti vengono addestrate simultaneamente fino a raggiungere uno stato stabile in cui il generatore ha appreso bene la distribuzione dei dati e il discriminatore non riesce più a distinguere tra le due distribuzioni di campioni reali e generati [42], [43]. Le GAN trovano applicazione in molti ambiti, tra cui la generazione realistica di immagini, la super-risoluzione, il trasferimento di stile, l'image-to-image translation e la generazione text-to-image [3], [37].

La Restricted Boltzmann Machine (RBM) è un modello neurale generativo e stocastico che rientra tra i probabilistic graphical models. Apprende la distribuzione dei dati assegnando una probabilità alle diverse configurazioni possibili degli input ed è composta da uno strato visibile e uno strato nascosto, in cui il primo riceve i dati e il secondo ne apprende le caratteristiche latenti. Il funzionamento si basa su una funzione di energia che assegna un valore a ogni coppia visibile-nascosto dove alle configurazioni migliori corrispondono livelli di energia più bassa e quindi probabilità più alta.

Tuttavia, se considerate singolarmente, non sono in grado di modellare dati complessi, motivo per il quale nascono le Deep Belief Networks. Le DBN sono rappresentabili come strutture ibride in quanto contengono due sezioni: nella parte superiore, sono formate da diversi strati di RBM che consentono alla rete di apprendere rappresentazioni sempre più astratte e potenti, dove ogni RBM impara rappresentazioni latenti dei dati e le trasmette al livello successivo; mentre gli strati inferiori, utilizzano connessioni feedforward che rendono possibile l'impiego supervisionato per la classificazione. Dunque, l'addestramento si articola in una fase non supervisionata per addestrare le RBM e una fase supervisionata in cui la rete è ottimizzata per compiti discriminativi. Sebbene ad oggi trovino impiego limitato, vengono riconosciute per l'importante contributo nello sviluppo dei Deep Generative Models [43], [37], [36], [40].

Tra i modelli generativi, un ruolo di rilievo è svolto dagli Autoencoder, considerabili come un caso speciale di rete feedforward [40] addestrate per tentare di copiare l'input nel proprio output, apprendendo rappresentazioni dei dati [36]. La rete impara a copiare solo una rappresentazione approssimativa degli input simili a quelli di addestramento, costringendola a prioritizzare e preservare solo le caratteristiche più rilevanti, rendendola così capace di comprendere la struttura dei dati invece di memorizzare una copia perfetta. Internamente può essere vista come composta da tre parti [36]: encoder, codice (o bottleneck) e decoder. L'encoder comprime l'input e produce un codice, calcolando una rappresentazione nascosta $h=f(x)$, che il decoder usa per produrre una ricostruzione $r=g(h)$ [40].

Con lo scopo di migliorare la qualità e la generalizzazione delle rappresentazioni apprese, sono state introdotte versioni regolarizzate che aggiungono proprietà aggiuntive oltre alla mera copia. Gli Autoencoder, tradizionalmente impiegati in compiti non supervisionati come riduzione della dimensionalità, estrazione di

caratteristiche, denoising e rilevamento di anomalie, possono produrre rappresentazioni dei dati che poi vengono utilizzate come input per modelli supervisionati. Varianti regolarizzate, come SAE, DAE e CAE, sono particolarmente efficaci a questo scopo [36]. Recentemente, le connessioni tra Autoencoder e modelli a variabili latenti hanno reso gli Autoencoder centrali nel generative modeling, in particolare nei Variational Autoencoder (VAE) e nelle Generative Stochastic Networks.

I Variational Autoencoder (VAE) sono modelli non supervisionati derivati dagli Autoencoder, ma con un approccio probabilistico. Infatti, negli Autoencoder classici, l'encoder comprimeva l'input in un unico vettore latente deterministico e successivamente il decoder tentava di ricostruire l'input a partire da tale rappresentazione [42]. Al contrario, il VAE apprende una distribuzione latente: l'encoder stima per ogni input media e varianza, definendo una distribuzione da cui viene campionato il vettore latente utilizzato dal decoder. In questo modo il modello rappresenta esplicitamente la probabilità dei dati e permette di generare nuovi campioni [36]. Inoltre, imponendo che le distribuzioni apprese si avvicinino a una Gaussiana standard, regolarizza lo spazio latente rendendolo continuo e ben strutturato, il che permette interpolazioni fluide e la generazione coerente di nuovi dati [43]. I VAE trovano applicazione in anomaly detection, classificazione e clustering, oltre che nella generazione di dati diversi come: immagini, audio, testo, modelli 3D, persino molecole. Infatti, sono largamente utilizzati in ambito medico, in particolare nell'imaging e nell'R&D per la sintesi di nuove sostanze [44] [45].

Per concludere la rassegna delle tecniche generative, i Diffusion Models si distinguono per costituire una famiglia di modelli probabilistici basati su reti di denoising. Funzionano secondo un processo in cui i dati vengono progressivamente degradati aggiungendo rumore, mentre il modello impara a invertire questo processo, rimuovendolo passo dopo passo fino a ricostruire dati realistici [46]. Sono molto stabili e producono campioni di alta qualità, sebbene il processo di generazione risulti lento. Trovano applicazione in molti compiti, tra questi quelli generativi come text-to-image, text-to-video, text-to-3D, text-to-motion, text-to-audio, passando anche per classici compiti di computer vision come anomaly detection, image editing e image restoration. Vengono inoltre utilizzati nell'elaborazione di dati temporali, ad esempio per imputazione e forecasting, e in ambiti scientifici come l'imaging medico e la generazione di molecole per il drug design, ma il settore in cui hanno raggiunto maggiore maturità rimane la generazione di immagini.

Altri modelli e metodi di apprendimento

Nel contesto dei modelli di deep learning, assume una nota di rilievo il Deep Reinforcement Learning (DRL) [36], che a differenza degli altri modelli analizzati non rientra nella dicotomia discriminativo-generativo, piuttosto esprime la finalità di ottimizzare le decisioni prese nel tempo attraverso l'interazione con l'ambiente. Per questo motivo, viene collocato tra i metodi value-based, che stimano il valore atteso delle azioni, e policy-based, che apprendono direttamente la strategia ottimale, basando in entrambi i casi l'apprendimento sull'esperienza. Il DRL, dunque, integra il meccanismo di esplorazione e ricompensa tipico dell'apprendimento per rinforzo con la capacità delle reti neurali profonde di elaborare input complessi, consentendo ai sistemi di interpretare dati quali immagini o segnali sensoriali senza necessità di un'estrazione manuale preliminare delle caratteristiche. I principali approcci per descrivere le possibili interazioni con l'ambiente si distinguono in due categorie: i metodi model-free, in cui il sistema apprende tramite tentativi di azioni massimizzano la ricompensa (ad esempio Q-learning e Deep Q-Network), e i metodi model-based, nei quali viene costruita una rappresentazione esplicita del funzionamento dell'ambiente per prevederne le conseguenze, ottenendo maggiore efficienza a fronte di una complessità superiore. Quando combinato con altri modelli, trova applicazione in numerosi ambiti, tra cui robotica, videogiochi, guida autonoma, visione artificiale ed elaborazione del linguaggio naturale.

Come già anticipato, un concetto fondamentale risiede nel fatto che la tradizionale distinzione tra modelli discriminativi e generativi tende a sfumare, soprattutto quando si considera la finalità del modello, piuttosto della formulazione probabilistica. Architetture come CNN, RNN o MLP, pur rientrando tradizionalmente nei modelli discriminativi, possono assumere finalità diverse a seconda dell'addestramento, della struttura probabilistica e della funzione di loss adottata [47].

I modelli autoregressivi generativi illustrano questa flessibilità [48]: predicono o generano un elemento alla volta, condizionandosi sugli elementi precedenti e decomponendo la probabilità di una sequenza come prodotto di probabilità condizionate. Originariamente sviluppati per serie temporali, i principi autoregressivi sono stati estesi

a dati non temporali come testo, immagini e audio. Ad esempio, CNN possono essere impiegate in contesti autoregressivi per la generazione di immagini, come in PixelCNN, mentre RNN, concepite per sequenze, possono essere adattate sia a compiti di classificazione sia a modelli generativi di linguaggio, sebbene nei moderni modelli NLP siano stati in larga parte sostituite dai Transformer. Analoga flessibilità si osserva nei MLP mascherati, come in NADE, e nei Transformer autoregressivi, come ChatGPT, in cui l'attenzione mascherata impedisce l'uso di informazioni future nella generazione sequenziale. Ulteriori approfondimenti sui modelli non trattati dello schema della Figura 2.11, sono consultabili in [36].

La Rivoluzione dei Transformer

I Transformer rappresentano oggi una delle architetture fondamentali nel deep learning. A differenza delle CNN e delle RNN, che si basano rispettivamente su operazioni di convoluzione e ricorrenza, i Transformer utilizzano esclusivamente il meccanismo di self-attention, risultando applicabili sia a compiti discriminativi sia generativi. Con la loro introduzione è emersa l'idea che l'attenzione sia sufficiente per modellare dipendenze complesse e a lungo raggio nelle sequenze, senza fare affidamento a ricorrenze o convoluzioni. Essendo altamente parallelizzabili, hanno permesso di superare i limiti dei modelli ricorrenti, che elaborano le sequenze in modo strettamente sequenziale e richiedono tempi di addestramento elevati [49].

Questa architettura conserva l'impostazione generale dei modelli sequence-to-sequence, basati sulla coppia encoder-decoder, ma ne rivoluziona i componenti interni. Nei modelli seq2seq, l'encoder converte la sequenza di input in una rappresentazione numerica compatta, mentre il decoder genera la sequenza di output in modo autoregressivo, generando un valore alla volta e lasciandosi condizionare esclusivamente sui valori precedenti della sequenza. Prima dell'introduzione dei Transformer queste architetture si basavano principalmente su modelli sequenziali quali RNN, LSTM o GRU e mantenendo la composizione originaria; successivamente i Transformer forniscono un'alternativa più efficiente grazie al meccanismo di attenzione.

L'architettura dei Transformer si basa su strati sovrapposti, ciascuno composto da un meccanismo di self-attention multi-head e da un livello feed-forward point-wise, presenti sia nell'encoder sia nel decoder. Il formato standard richiesto da tutti i Transformer in input è una sequenza di vettori embedded, ossia vettori numerici che rappresentano gli elementi della sequenza originale dopo l'embedding. Ogni token della sequenza (testuale, patch visiva, frame audio, valore temporale) viene convertito in un vettore numerico denso, e la sequenza viene organizzata in un tensore 2D di dimensione $sequence_length \times embedding_dim$, che corrispondono rispettivamente al numero di token nella sequenza e alla dimensione del vettore embedding di ciascun token.

Come evidenziato da Vaswani et al. [49], nel meccanismo di attenzione accade che su ciascun embedding, vengono calcolate tre proiezioni lineari: query (Q), key (K) e value (V). Le query indicano le informazioni che il token corrente sta cercando, le key rappresentano le caratteristiche degli altri token che possono rispondere a questa richiesta, e le value contengono le informazioni effettive da combinare. L'attenzione calcola quindi la similarità tra query e key per ponderare i value corrispondenti, producendo un output che integra selettivamente le informazioni più rilevanti della sequenza. Formalmente questo concetto può essere espresso dalla relazione F5:

$$Attention(Q, K, V) = softmax\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad [F5]$$

(tratta da Vaswani et al., 2017, *Attention Is All You Need* [49])

Dove Q, K e V sono le matrici che raccolgono rispettivamente tutte le query, le key e i value della sequenza; d_k è la dimensione delle key usata per normalizzare il prodotto scalare; QK^T è la matrice che misura la similarità tra ogni query e tutte le keys; Infine, la funzione *softmax* normalizza i punteggi di similarità in pesi, che vengono utilizzati per combinare i value degli altri token, producendo così una nuova rappresentazione finale per ciascun token.

Nella architettura Transformer, il concetto di attenzione viene esteso tramite la multi-head attention, che esegue più meccanismi di attenzione in parallelo, ciascuno specializzato nel cogliere differenti tipi di relazioni sintattiche, semantiche, locali o globali, producendo rappresentazioni più ricche e informative. Questo meccanismo viene impiegato in tre modalità distinte: la self-attention dell'encoder, che applica l'attenzione all'interno della sequenza

di input per costruire una rappresentazione globale coerente del contesto; la self-attention del decoder, interna alla sequenza di output, resa autoregressiva per impedire a ogni posizione di accedere ai token futuri, garantendo la generazione passo dopo passo; e infine l'attenzione encoder-decoder, che consente al decoder di interrogare selettivamente la rappresentazione prodotta dall'encoder, determinando a ogni passo quali parti dell'input siano più rilevanti per generare il token successivo all'interno dell'output.

Le architetture BERT, GPT e T5 rappresentano tre esempi di modelli fondamentali basati su Transformer che si differenziano per struttura, obiettivi e applicazioni [50]:

- BERT, basato solo sull'encoder bidirezionale, cattura il contesto precedente e successivo di ogni parola, risultando efficace nella comprensione del linguaggio naturale ma inadatto alla generazione.
- GPT, invece, utilizza solo il decoder e in modalità autoregressiva, predicendo ogni parola a partire dalle precedenti, ed è quindi particolarmente adatto alla generazione.
- T5 adotta l'intera architettura encoder-decoder e converte ogni task di NLP in un formato text-to-text, supportando sia compiti di comprensione sia di generazione.

Insieme, questi modelli costituiscono le basi dei moderni Large Language Models, alla base di sistemi come ChatGPT, con applicazioni soprattutto legate alla creazione automatica di contenuti nelle chatbot e negli assistenti virtuali [28]. La Figura 2.12 seguente illustra le principali applicazioni dei modelli Transformer.




Figura 2.12: Domini e Applicazioni dei Transformer, tratta da [28].

Large Language Models e la transizione verso la multimodalità

I Large Language Models (LLM) sono modelli generativi di grandi dimensioni basati sull'architettura Transformer capace di generare sequenze di token tramite un processo autoregressivo. Si dicono di grandi dimensioni perchè presentano miliardi di parametri e sono addestrati su enormi quantità di dati. Nascono come modelli per il linguaggio naturale, progettati per apprendere rappresentazioni profonde del testo. Tramite il pre-training auto-supervisionato, acquisiscono capacità generali di comprensione e generazione del linguaggio che permettono di svolgere molti compiti senza addestramento specifico. Riescono a generalizzare su compiti non visti e gestiscono contesti molto lunghi, inoltre possono essere specializzati tramite instruction tuning e alignment. I primi LLM moderni compaiono con GPT-3 (175B di parametri) [51].

Sebbene i Large Language Models siano stati originariamente concepiti per l'elaborazione del testo, essi possono oggi operare su sequenze di token indipendentemente dalla loro natura, a condizione di essere opportunamente addestrati o progettati per tale scopo. Tale capacità, come già accennato nella sezione precedente, deriva dall'architettura Transformer, la quale consente di processare diversi tipi di input: testuali, visivi, audio o di altra natura, purché opportunamente rappresentati mediante embedding numerici.

In questa prospettiva, risulta quindi evidente che, quando si parla di multimodalità, il riferimento riguarda la natura dell'input e non dell'output. È cruciale, a questo proposito, distinguere tra i concetti di Large Language Model (LLM), Multimodal Large Language Model (MLLM) e, più in generale, di multimodalità.

Un Large Language Model (LLM) è un modello addestrato su dati testuali, specializzato nella generazione e comprensione di testo, e mantiene questa natura anche quando riceve input multimodali, pur non essendo direttamente addestrato su immagini, audio o video. Per gestire input di diversa natura, gli LLM con estensioni multimodali vengono affiancati da encoder dedicati (visivi, audio, ecc.) che trasformano tali dati in embedding numerici compatibili con i token testuali del modello. Questi embedding già contengono relazioni interne grazie all'encoder e questo consente all'LLM di elaborare sequenze multimodali come se fossero sequenze di testo, senza essere stato addestrato su dati non testuali. La generazione di output non testuali invece, quando presente, è affidata a modelli separati specificamente orientati allo scopo, che ricevono in input il testo prodotto dall'LLM.

Un Multimodal Large Language Model (MLLM) per contro, pur basandosi tipicamente su un LLM, è progettato per integrare modalità aggiuntive al testo. Immagini, audio o video vengono trasformati da encoder specializzati in embedding compatibili con i token linguistici e successivamente elaborati dagli stessi layer e meccanismi di attenzione del modello. Il sistema viene addestrato nativamente su più modalità, ossia su multiple (es. testo + immagini + audio), permettendo l'apprendimento di relazioni cross-modali tra le varie tipologie di input. In questo modo, la multimodalità diventa una proprietà intrinseca del modello, e non una semplice estensione tramite encoder esterni. Riesce a sviluppare una rappresentazione integrata nativa, con attenzione condivisa tra modalità, e può generare output multimodali o fare ragionamenti cross-modali più complessi.

Inoltre, è importante chiarire che non tutti i modelli multimodali sono MLLM. Questi ultimi rappresentano una classe specifica progettata attorno a un nucleo linguistico LLM che inserisce le altre modalità all'interno del suo meccanismo di apprendimento, dando origine a un'integrazione profonda, non a una semplice combinazione di più modelli. Esempi di MLLM sono GPT-4 multimodale e Gemini [52], mentre CLIP o LXMERT sono esempi di sistemi multimodali ma non MLLM.

2.4.6. AI Ibrida

L'AI ibrida combina diversi paradigmi di intelligenza artificiale per sfruttarne i punti di forza e mitigare le debolezze reciproche [3]. Ad esempio, integrando sistemi simbolici, efficaci nel ragionamento, con modelli di deep learning, abili nell'apprendimento ma poco interpretabili, si ottengono sistemi capaci di apprendere e al contempo più spiegabili e affidabili. Ma l'approccio ibrido comprende anche la combinazione di altre tecniche come reinforcement learning e algoritmi evolutivi. Un'applicazione concreta tipica di AI ibrida è l'auto autonoma, dove il deep learning gestisce la percezione, la conoscenza di dominio viene codificata tramite regole o vincoli nelle decisioni, e algoritmi di ottimizzazione pianificano i movimenti. Di seguito si presenta la tassonomia per tecniche (Figura 2.13) relativa a tale paradigma [3].




Figura 2.13: Tassonomia del Hybrid AI con metodi e algoritmi più famosi, schema rielaborato da tabella di Taxonomy of Artificial Intelligence [3].

In questo caso la classificazione propone una distinzione su tre tipologie di modelli ibridi: i sistemi Neuro-Simbolici, i metodi che combinano la computazione evolutiva con sistemi simbolici e l'ultimo che vede la combinazione tra knowledge graph e reti neurali grafiche (GNNs).

Il modello Neuro-Symbolic Visual Question Answering (NS-VQA) è un esempio di applicazione che integra percezione neurale e ragionamento simbolico, tipicamente usato per rispondere a domande su immagini. Le reti deep learning interpretano la domanda e generano un programma simbolico, mentre l'immagine viene trasformata in una rappresentazione strutturata della scena (oggetti, attributi, relazioni). Il programma simbolico viene eseguito su questa rappresentazione, producendo risposte verificabili e affidabili [53].

La seconda voce rappresentata nella tassonomia appartiene alla famiglia dei sistemi ibridi, categoria che combina moduli discreti di natura simbolica insieme a moduli continui neurali con dinamiche differenziabili [54]. Tra questi figurano i sistemi di pianificazione ibrida, di cui un esempio tipico è SHOP2+RL [3], che integra la pianificazione gerarchica di SHOP2 [55] con l'apprendimento per rinforzo [56]. Il planner simbolico gestisce la scomposizione del compito in sotto-task, mentre il modulo di RL ottimizza l'esecuzione delle azioni. Questa combinazione consente di affrontare problemi di long-horizon planning che i due moduli se presi singolarmente, non avrebbero risolto in maniera efficiente.

Un altro sistema neuro-simbolico è rappresentato da DeepProbLog [57], che estende il linguaggio logico-probabilistico ProbLog integrando moduli neurali per la percezione. Le reti neurali percepiscono fatti con probabilità, che vengono poi utilizzati dal motore logico-probabilistico per eseguire inferenza simbolica su regole, vincoli e relazioni tra gli oggetti percepiti. Questo approccio è efficace nei compiti che richiedono sia percezione sia ragionamento strutturato, per esempio nel riconoscere cifre e poi risolvere un'operazione logica, o interpretare un'immagine e verificare le relazioni presenti.

Le Logical Neural Networks (LNN) [58] integrano operatori logici differenziabili dentro un'architettura neurale, dove ogni nodo rappresenta una formula logica definita tramite funzioni continue ottimizzabili e ogni predicato ha un intervallo di verità che gestisce incertezza e conoscenza incompleta mantenendo coerenza logica. Questa struttura permette di combinare apprendimento tramite backpropagation e ragionamento simbolico esplicito, capace di incorporare regole o vincoli. Costituiscono un approccio promettente per applicazioni che richiedono spiegabilità e ragionamento guidato dalla conoscenza.

I sistemi neuro-fuzzy piuttosto, combinano l'apprendimento delle reti neurali con l'interpretabilità e la gestione dell'incertezza della logica fuzzy. A differenza dei sistemi fuzzy classici che richiedono la definizione di funzioni di appartenenza e regole IF-THEN manualmente [59], i modelli neuro-fuzzy riescono ad apprenderele automaticamente dai dati, mantenendo però strutture leggibili e controllabili. Il modello più rappresentativo è ANFIS (Adaptive Neuro-Fuzzy Inference System) [60], che implementa una logica fuzzy differenziabile, quindi ottimizzabile tramite backpropagation. Questi sistemi sono ideali per applicazioni che richiedono adattività e trasparenza, come controllo di processi, robotica e supporto decisionale basato su dati incerti e conoscenza esperta.

Ultima categoria di modelli neuro-simbolici è rappresentata da NTP [61] e dILP [62], che rientrano nella famiglia del Differentiable Logic Programming, dove si rendono alcune parti del ragionamento logico continue e ottimizzabili tramite backpropagation. La differenza tra i due consiste nel fatto che, mentre NTP rende differenziabile l'inferenza logica e serve per provare delle regole date, dILP rende differenziabile l'apprendimento delle regole, imparando le regole stesse dai dati. DILP è anche capace di generare automaticamente regole simboliche e programmi logici che spiegano i dati, aspetto che lo rende allo stesso tempo collocabile tra i Program Synthesis Model.

L'integrazione tra Genetic Programming (GP) e Symbolic Regression (SR) è un esempio di AI ibrida che combina rappresentazioni simboliche e principi evolutivi. Basata sugli algoritmi genetici di Holland [63], il GP evolve strutture simboliche sotto forma di alberi sintattici, mentre la SR individua automaticamente le espressioni matematiche che meglio descrivono i dati [64]. In questo schema, SR fornisce la struttura simbolica e GP funge da motore evolutivo per generare e ottimizzare tali modelli.

Infine, l'ultimo modello di AI ibrida trattato è rappresentato dalle Graph Neural Networks (GNNs) applicate ai Knowledge Graph, che combinano una struttura simbolica esplicita, ossia il grafo, con l'apprendimento automatico del modello di machine learning. Il modello può fare previsioni (es. link prediction) e fornire contemporaneamente un contesto strutturato con cui verificare la coerenza. Gli usi principali includono il Knowledge Graph Completion, per completare parti mancanti del grafo, e la Relation Inference, per stimare nuove relazioni non esplicitate ma coerenti con la struttura globale [3].

2.4.7. Tabella riassuntiva della tassonomia per tecniche di Intelligenza Artificiale

	AI per tecniche				
	<i>AI Simbolica</i>	<i>AI evolutiva-bio ispirata</i>	<i>Machine Learning</i>	<i>Deep Learning</i>	<i>AI ibrida</i>
Tecniche	Forward Chaining (1960)	Evolution Strategies (ES) (1965)	Linear Regression (1805, 1877)	Convolutional Neural Networks (CNNs) (1998, 2012)	
	Backward Chaining (1960)	Genetic Algorithm (GA) (1975)	Logistic Regression (1958)	Recurrent Neural Networks (RNN) (1990)	
	Production Systems (1972)	Differential Evolution (DE) (1997)	Decision Trees (1963, 1984, 1986)	Long Short-Term Memory (LSTM) (1997)	

Tecniche	Resolution Algorithm (1965)	Genetic Programming (GP) (1992)	Random Forest (2001)	Gated Recurrent Units (GRUs) (2014)	
	Unification Algorithm (1965)	Memetic Algorithms (1989)	Support Vector Machines (SVM) (1995)	Multilayer Perceptrons (MLPs) (1958–1986)	
	Semantic Networks (1956, 1966)	Neuroevolution (NE) (1994)	Gradient Boosting (1999)	Deep Reinforcement Learning- Deep Q-Network (DQN) (2015)	
	Ontology-Based Reasoning (1990)	Particle Swarm Optimization (PSO) (1995)	Principal Component Analysis (PCA) (1901)	Transformers (2017)	
	Frame-Based Reasoning (1975)	Ant Colony Optimization (ACO) (1992)	K-Nearest Neighbors (KNN) (1951)	Autoregressive Models (2013) (incl. Transformer decoder-only (es. GPT))	
	Truth Maintenance Systems (1976)	Artificial Bee Colony (ABC) (2005)	Naive Bayes (1960)	Deep Belief Networks (DBNs) (2006)	
	Constraint Satisfaction (1977)		K-Means Clustering (1957, 1967)	Variational Autoencoder (VAE) (2013)	
				Generative Adversarial Networks (GANs) (2014)	
				Diffusion Models (2015, 2020)	

	AI per tecniche				
	<i>AI Simbolica</i>	<i>AI evolutiva-bio ispirata</i>	<i>Machine Learning</i>	<i>Deep Learning</i>	<i>AI ibrida</i>
Tecniche	X			X	Neuro-Symbolic Visual Question Answering (NSVQA) (2019)
	X		X		Hybrid Planning Systems (e.g., SHOP2 + RL) (2015)
	X			X	DeepProbLog (2018)
	X			X	Logical Neural Networks (LNN) (2020)
	X		X		Neuro-Fuzzy Inference System (ANFIS) (1993)
	X			X	Neural Theorem Prover (NTP) (2017)
	X		X		Differentiable Inductive Logic Programming (dILP) (2017)
	X	X			Symbolic Regression with Genetic Programming (1992)
	X			X	Graph Neural Networks + Knowledge Graphs (2017)

Tabella 2.1: Tassonomia per tecniche di Intelligenza artificiale completa, rielaborazione sintetica tratta dalle tabelle di Taxonomy of Artificial Intelligence [3].

2.4.8. Agent, Agentic AI e architetture multi-agentiche

L'era Agentic nella sua accezione moderna (2022–oggi), caratterizzata da agenti neurali basati su LLM come AutoGPT, è in realtà preceduta da una fase distinta. Tra il 2018 e il 2021 la ricerca sugli agenti autonomi vede infatti una rinnovata attenzione verso approcci simbolici e neuro-simbolici. Pur inserendosi in una tradizione molto più lunga, i sistemi simbolici rappresentavano in questo periodo, i meccanismi di agenzia e autonomia costituenti dei sistemi agentivi, ancora programmati da regole esplicite e piani deterministici. Dopo l'arrivo degli LLM, questo paradigma lascia progressivamente spazio a un approccio basato su orchestrazione stocastica dei modelli generativi, dove le capacità generative dei modelli vengono sfruttate per pianificare e coordinare azioni e interazioni multi-agente. Per offrire una visione chiara e coerente di tale approccio, Abou Ali, M., et al. (2025) [5] propongono una distinzione lungo due assi indipendenti:

- Il Paradigma Architettuale (Simbolico o Neurale)
- La struttura agentiva (Agente Singolo o Multi-Agente).

Paradigma architettuale

L'attenzione verso questa dimensione di categorizzazione nasce dal bisogno di prevenire il così detto “retrofitting concettuale”, ossia il tentativo errato di voler forzare le architetture agentive neurali moderne all'interno degli schemi dell'era simbolica. Come ampiamente chiarificato nelle sezioni precedenti di questo capitolo, infatti, i due paradigmi non rappresentano una prosecuzione l'uno dell'altro, piuttosto sono costituiti da architetture, tecniche e principi di funzionamento nettamente separati.

In questo senso, si modifica anche il modo in cui i concetti di autonomia e agency, alla base dei sistemi agentivi, sono implementati nei due casi. A tal proposito è bene chiarire la differenza tra tre concetti: autonomia, agency e Agenticness.

Il concetto di autonomia richiama la definizione di uso comune, ossia la capacità del sistema di operare senza intervento esterno, prendendo decisioni e agendo in maniera indipendente. L'agency invece, racchiude un concetto più ampio, e identifica il comportamento orientato al raggiungimento di obiettivi, che incorpora intenzione, capacità decisionali, consapevolezza del contesto e dell'ambiente circostante [5]. Infine, l'Agenticness [65], è il grado in cui un sistema può raggiungere in modo adattivo obiettivi complessi in ambienti dinamici con supervisione diretta limitata (Shavit et al., OpenAI, 2023). In questo senso, l'Agenticness non rappresenta una dicotomia, bensì un livello graduale di intensità con cui si manifestano le caratteristiche che ne definiscono il concetto. Nel paradigma simbolico e neurale alcune definizioni assumono connotazioni diverse: in quello simbolico l'agency è guidato dal ragionamento basato su regole esplicite e dalla pianificazione algoritmica, mentre nel paradigma neurale, fondato su apprendimento statistico e sulle capacità generative degli LLM, è caratterizzato da generazione stocastica e orchestrazione tramite prompt.

In questo contesto, nel passaggio tra un paradigma e l'altro, il Deep Reinforcement Learning (DRL) ha rappresentato un passaggio abilitante, consentendo agli agenti di apprendere policy da dati complessi tramite reti neurali e introducendo capacità di generalizzazione tra compiti tramite il meta-DRL. Ma il cambiamento decisivo è stato segnato dall'arrivo degli LLM, con cui si passa definitivamente dalla progettazione top-down della logica interna, all'orchestrazione di pipeline generative tramite prompt. LangChain, AutoGen o CrewAI sono esempi di framework di tipo neurale che si basano su questo paradigma di LLM Orchestration, ognuno abilitato da meccanismi specifici per scopi dedicati. LangChain, ad esempio, adotta un meccanismo di prompt chaining con cui esegue orchestrazione di sequenze lineari di chiamate LLM e API ed è più adatto ad automazione di workflow multi-step, mentre AutoGen si specializza in task collaborativi, abilitando dialoghi strutturati tra diversi agenti LLM.

Sempre in relazione al tipo di architettura, Abou Ali, M., et al. (2025) evidenziano una forte specializzazione per dominio dei singoli paradigmi: i settori ad alta criticità e altamente regolamentati, come sanità e tecnologia legale, tendono a favorire architetture simboliche o neurali rigidamente vincolate, mentre ambiti più dinamici come la finanza adottano orchestrazioni neurali per gestire analisi complesse. Oggi le tendenze future dell'AI agentiva stanno andando verso architetture ibride. Tra queste, emergono come possibili candidati i sistemi neuro-simbolici

grazie a cui, come già accennato, sarebbe possibile superare i limiti dei singoli paradigmi e ottenere complessivamente un valore aggiunto [5].

La struttura agentiva

A seguito di quanto analizzato risulta evidente che, nel panorama attuale, non tutti gli agenti si basano su LLM. Esistono infatti agenti robotici fisici, in grado di interagire autonomamente con l'ambiente tramite meccanismi di reinforcement learning, e continuano a esistere gli agenti simbolici, particolarmente efficaci in contesti ristretti e nell'esecuzione di compiti altamente specializzati. Tuttavia, dal punto di vista gestionale e strategico, le aziende tendono a privilegiare approcci più general-purpose, capaci di affrontare una certa varietà di task. In questa prospettiva, gli agenti LLM sono spesso quelli prediletti. Infatti, la loro flessibilità consente di orchestrare workflow complessi, integrarsi con strumenti e basi dati esterne e adattarsi a compiti eterogenei. Malgrado ciò, è importante considerare che questa generalizzabilità comporta dei limiti, tra cui minore efficacia su task estremamente specifici e la necessità di supervisione per mitigare rischi quali le allucinazioni, facendo sì che i sistemi specializzati rimangano insostituibili nei domini tecnici ristretti.

Considerata la crescente diffusione degli agenti basati su LLM, nonché la loro prevalenza nelle applicazioni presentate nei capitoli successivi, tale trattazione sulla composizione strutturale concentra l'analisi su questa tipologia di agenti.

A questo proposito, una specificazione importante riguarda la differenza tra: LLM, agente LLM e multi-agente LLM [66]. Un singolo LLM, anche con RAG, è spesso sufficiente per richieste semplici, ma non per compiti complessi che richiedono pianificazione in più passi, ragionamento iterativo o uso di strumenti esterni. In questi casi entrano in gioco gli LLM agent, capaci di pianificare, selezionare tool, consultare basi di dati e migliorare progressivamente le proprie risposte, svolgendo workflow autonomi basati sulla conoscenza appresa e recuperata. Alcuni lavorano come singoli agenti, altri attraverso workflow multi-agente.

Dunque, un LLM di per sé, è solo un modello che non possiede agency, capacità decisionale o la possibilità di interagire autonomamente con ambienti. Un agente LLM invece, non è un semplice modello, ma una composizione di più elementi che lavorano insieme per consentire decision-making autonomo, esecuzione di task e interazione con sistemi esterni. In altri termini, può essere visto come un LLM incorporato in un framework esterno che: fornisce input strutturati per guidare i comportamenti; garantisce l'allineamento con obiettivi specifici (prompt); interpreta i suoi output per assicurarne coerenza e utilizzabilità nelle applicazioni successive (parser); abilita di tanto in tanto l'interazione con sistemi esterni (tool) tramite meccanismi di function calling, tecniche RAG per recuperare informazioni da fonti esterne e interazioni basate su API, per ottenere dati aggiuntivi o automatizzare certe parti del processo.

Sebbene i sistemi single-agent funzionino bene per compiti semplici e riescano a operare in modo sufficientemente autonomo, questi mostrano limiti quando devono affrontare compiti più complessi o collaborativi. Per esempio, presentano problemi di scalabilità, non riuscendo efficientemente a svolgere compiti estesi e parallelizzabili o workflow multi-step; tendono a generalizzare lungo tutte le attività anche se queste richiedono competenze specifiche e sono soggetti al problema delle allucinazioni.

Al contrario, i Multi-Agent Systems (MAS) orchestrano più agenti, ciascuno con un ruolo specializzato, che collaborano per raggiungere obiettivi più sofisticati. Questo approccio, si basa sul principio "divide and conquer", cioè, suddividere un compito complesso in sotto compiti più semplici da distribuire tra i vari agenti che possono eseguirli anche in parallelo. La crescente modularizzazione di questa architettura introduce dunque specializzazione, parallelizzazione dei compiti da cui consegue maggiore scalabilità e un livello superiore di supervisione, anche delle allucinazioni prodotte, grazie alla verifica incrociata tra agenti.

Le architetture MAS si presentano in forme diversificate: possono essere decentralizzate, come nella Network Architecture basata su comunicazioni peer-to-peer, oppure centralizzate, come nella Supervisor Architecture, in cui un supervisore assegna e coordina i task. Esistono anche strutture gerarchiche, con livelli multipli di agenti; modelli Supervisor-as-Tools, in cui un agente principale si avvale di agenti specializzati come strumenti, e infine architetture custom o ibride, progettate combinando più schemi in modo personalizzato per adattarsi a esigenze applicative specifiche [66].

2.5. *Confronto e Valutazione delle tecniche di Intelligenza artificiale*

A seguito dell'analisi dei principali paradigmi, architetture, algoritmi e modelli dell'intelligenza artificiale, questa sezione si concentra sulla strutturazione sistematica delle conoscenze per consentire un confronto operativo tra le diverse tecniche. L'obiettivo è estendere l'analisi oltre la distinzione basata sul principio di funzionamento, integrando una prospettiva implementativa e comparativa, così da completare la base metodologica necessaria a mettere in relazione gli strumenti di AI con le applicazioni pratiche nei processi di progettazione, tema approfondito nelle sezioni applicative della tesi.

2.5.1. Scelta dei paradigmi e delle tecniche da confrontare

Ai fini del confronto sono stati considerati esclusivamente quei paradigmi dell'intelligenza artificiale che possono essere trattati come categorie tecniche omogenee e valutabili secondo le dimensioni caratterizzanti selezionate. Rientrano in questa definizione l'AI simbolica, l'AI evolutiva, il Machine Learning tradizionale e il Deep Learning. Al contrario, approcci quali l'Hybrid AI e l'Agentic AI non sono stati inclusi nella comparazione, poiché non rappresentano paradigmi unitari dal punto di vista tecnico. Si tratta, infatti, di architetture composite che integrano metodi riconducibili ai paradigmi precedentemente citati, con livelli di eterogeneità tali da renderli inadatti a essere trattati come entità confrontabili in modo diretto.

Ai fini dell'analisi comparativa, per ogni paradigma sono state selezionate alcune tecniche rappresentative. Il confronto non è stato condotto a livello di paradigma nel suo complesso, poiché ciascuno comprende un insieme ampio e diversificato di metodi che, pur condividendo principi generali, possono differire significativamente rispetto alle dimensioni di valutazione considerate, differenze che l'analisi intende rendere esplicite. Per questo motivo, un confronto diretto tra paradigmi risulterebbe eccessivamente astratto e di scarsa utilità. Allo stesso tempo, includere tutte le tecniche disponibili sarebbe superfluo e dispersivo, in quanto molte di esse costituiscono varianti non sostanziali o evoluzioni incrementali che, pur correggendo limiti delle versioni precedenti, non differiscono rispetto alle dimensioni di confronto considerate. Per queste ragioni, la selezione si concentra sulle tecniche che meglio rappresentano le proprietà distintive dei rispettivi paradigmi e che risultano più adatte a un confronto coerente secondo le dimensioni considerate.

Una particolare attenzione è riservata alle tecniche di Deep Learning, che rappresentano il nucleo degli approcci più diffusi in epoca moderna. Per garantire un confronto metodologicamente rigoroso, il paradigma viene articolato su due livelli: da un lato le architetture di base, ossia CNN, RNN e Transformer; dall'altro una famiglia di modelli orientata a task generativi, come VAE, GAN e Diffusion Models. Questi ultimi, pur caratterizzati da strutture interne peculiari (ad esempio architetture encoder-decoder, meccanismi avversariali o processi di denoising), in diversi casi incorporano le architetture di base come componenti costitutivi.

L'introduzione dei modelli generativi come categoria funzionale autonoma nel confronto serve a rendere espliciti alcuni concetti utili ai capitoli successivi, dedicati all'impiego degli strumenti di AI nelle diverse fasi dei processi di progettazione, in particolare in quelle creative e divergenti, dove questi modelli trovano il loro principale ambito di applicazione.

2.5.2. Dimensioni caratteristiche di confronto

La comparazione delle tecniche è guidata da un insieme di dimensioni caratterizzanti formulate per mettere a fuoco gli aspetti essenziali di ciascun metodo e consentirne una valutazione trasversale tra paradigmi. In particolare, il confronto considera:

- le proprietà fondamentali (**Prop.**), che sintetizzano il principio di funzionamento e gli elementi distintivi della tecnica, derivati dalla tassonomia della sezione precedente;
- la tipologia di compito (**Task**) per cui la tecnica risulta tipicamente idonea, al fine di chiarirne la natura operativa;

- i requisiti degli input (**Input**), intesi come l'insieme delle informazioni necessarie allo svolgimento del compito. Tali informazioni comprendono sia quelle statiche o conoscitive, che costituiscono la base del ragionamento o dell'apprendimento (ad esempio regole, vincoli o dati di training), sia quelle dinamiche o operative, fornite durante l'esecuzione e in grado di condizionare direttamente l'output. Restano esclusi gli input che riguardano aspetti puramente tecnici o configurativi dell'algoritmo, al fine di circoscrivere l'analisi alla natura operativa della tecnica.
- l'interpretabilità (**Interpret.**), dimensione particolarmente significativa nei contesti aziendali;
- il dominio applicativo prevalente (**Dom.**) in cui la tecnica trova più frequentemente impiego;
- la scalabilità (**Scal.**), valutata rispetto al volume dei dati trattabili e alla complessità computazionale;
- le risorse computazionali richieste (**Ris. Comp.**) che spesso configurano un limite alla applicabilità della tecnica stessa;
- gli aspetti legati all'addestramento (**Temp. Add.**), comprendenti sia i tempi necessari sia le principali difficoltà correlate, nonché dove rilevante, indicazioni sui tempi di esecuzione.

2.5.3. Tabelle di confronto

A seguire sono riportate le Tabelle Tabella 2.2, Tabella 2.3, Tabella 2.4, Tabella 2.5, Tabella 2.6, Tabella 2.7, Tabella 2.8, Tabella 2.9, Tabella 2.10, Tabella 2.11 che definiscono il confronto tra tecniche per ogni paradigma esplicitato nel paragrafo 2.5.1.

AI Simbolica: paradigma basato su conoscenza esplicita rappresentata tramite simboli, regole e strutture logiche. Ragionamento deduttivo e deterministico.				
Tecniche	Dimensioni caratteristiche di confronto			
	Prop.	Task	Input	Interpret.
Rule-based expert system	Regole esplicite, motore di inferenza, conoscenza procedurale	Diagnosi tramite regole, verifica vincoli, deduzione azioni per supporto decisionale	Statici (conoscenza del sistema), regole if-then, relazioni logiche, concetti di dominio	Molto alta (regole esplicite)
			Dinamici/Operativi (fatti) fatti simbolici (attributo = valore, condizioni), i valori non sono data type, funzionano come simboli	
Knowledge Graph e Ontology reasoning	Entità-relazioni (grafo)	Query semantiche, deduzione di conoscenza implicita (inferenza semantica), supporto decisionale basato su relazioni semantiche	Statici: ontologie (classi, relazioni, vincoli, soglie)	Molto alta (conoscenza esplicita, reasoning basato su regole dichiarative, operatori logici)
	Logiche descrittive, vincoli formali e Inferenza semantica		Dinamici: nuove istanze come triple soggetto-predicato-oggetto, query semantiche	

Tabella 2.2: Confronto tra tecniche selezionate di AI simbolica (Rule-based expert system, Knowledge Graph e Ontology reasoning), parte 1.

AI Simbolica: paradigma basato su conoscenza esplicita rappresentata tramite simboli, regole e strutture logiche. Ragionamento deduttivo e deterministico.				
Tecniche	Dimensioni caratteristiche di confronto			
	Dom.	Scal.	Ris. Comp.	Temp. Add.
Rule-based expert system	Ragionamento automatico, Sistemi basati sulla conoscenza	Scalabilità limitata: crescita di regole/fatti genera esplosione combinatoria [67] [68]	Poche risorse, CPU; costo computazionale dato da pattern matching [69]; memoria occupata cresce con regole/fatti	Nessun addestramento (conoscenza fornita esplicitamente da esperti quindi assenza di addestramento. Relativamente all'esecuzione, l'inferenza è rapida)
Knowledge Graph e Ontology reasoning	Rappresentazione della conoscenza e Ragionamento	Scalabilità dipendente dall'espressività: DL-Lite ed EL rendono reasoning scalabile basi di conoscenza grandi [70], [71], [72]	CPU; costo computazionale cresce con la dimensione della ontologia e l'espressività della logica, DL-Lite [71], [72] logica più leggera che riduce la complessità	Nessun addestramento (discorso analogo ai sistemi esperti ma con tempi di esecuzione più lunghi)

Tabella 2.3: Confronto tra tecniche selezionate di AI simbolica (Rule-based expert system, Knowledge Graph e Ontology reasoning), parte 2.

AI Evolutiva: include tecniche che mantengono popolazioni di soluzioni a cui applicano operatori di crossover, mutazione e selezione, valutate dalla funzione di fitness in cui sono contenuti vincoli e condizioni del problema di ottimizzazione specificato.				
Tecniche	Dimensioni caratteristiche di confronto			
	Prop.	Task	Input	Interpret.
Genetic Algorithms	Evoluzione numerica e parametrica, Soluzioni codificate come cromosomi (bit, vettori)	Ottimizzazione numerica, ricerca globale (combinatoria, iterativa), soluzioni robuste ma non garantisce l'ottimo	Statici: funzione di fitness	Bassa: processo evolutivo tramite mutazioni casuali; anche se il criterio di valutazione (fitness) è noto
			Dinamici: dati di contesto per valutare la fitness (es. parametri fisici, condizioni ambientali, risultati di simulazioni, dati osservati, ecc.) numerici strutturati/semi-strutturati (scalari, array numerici, matrici ecc.)	
Genetic Programming	Evoluzione di strutture simboliche (alberi sintattici, funzioni, regole)	Generazione e selezione di programmi/strutture simboliche rappresentate come alberi sintattici guidati dalla funzione di fitness	Statici: function set, terminali statici, funzione di fitness	Media/bassa: output simbolico interpretabile, ma processo evolutivo stocastico e poco tracciabile
			Dinamici: valori assegnati ai terminali del programma, valori target usati dalla fitness per confrontare l'output del programma. Vettori numerici, serie temporali, dataset tabellari	

Tabella 2.4: Confronto tra tecniche selezionate di AI evolutiva (GA e GP), parte 1.

AI Evolutiva: include tecniche che mantengono popolazioni di soluzioni a cui applicano operatori di crossover, mutazione e selezione, valutate dalla funzione di fitness in cui sono contenuti vincoli e condizioni del problema di ottimizzazione specificato.				
Tecniche	Dimensioni caratteristiche di confronto			
	Dom.	Scal.	Ris. Cmp	Temp. Add
Genetic Algorithms	Ricerca e Ottimizzazione	Lo spazio di ricerca cresce esponenzialmente con numero di variabili, le valutazioni della fitness sono il collo di bottiglia. Tecniche aggiuntive aumentano la scalabilità [73] [74], [75]	CPU, Costo concentrato sulla valutazione della fitness, cresce con simulazioni complesse, altamente parallelizzabili [76], [77], [75]	Nessun addestramento, (tempo di esecuzione legato al numero di iterazioni e può variare in base alla complessità del problema)
Genetic Programming	Ricerca e Ottimizzazione	Scalabilità limitata dal bloat (crescita incontrollata di alberi sintattici) che aumenta il costo di valutazione e limita efficienza su problemi di grande dimensione, ma migliorabile con tecniche specifiche [78], [79], [80]	CPU, Costo dominato dalla valutazione della fitness ma è parallelizzabile perché ogni individuo può essere valutato indipendentemente [79], uso di RAM cresce col bloat degli alberi	Nessun addestramento

Tabella 2.5: Confronto tra tecniche selezionate di AI evolutiva (GA e GP), parte 2.

Machine Learning tradizionale: si fonda su modelli statistici addestrati su dataset statici. In questi la struttura del modello, ossia la forma funzionale che determina il comportamento, e le feature rilevanti che il modello riesce ad estrarre dai dati, vengono definite a priori, mentre i parametri vengono appresi automaticamente dai dati. Richiede dati che tipicamente devono essere organizzati e strutturati.				
Tecniche	Dimensioni caratteristiche di confronto			
	Prop.	Task	Input	Interpret.
Random Forest	Ensemble di alberi addestrati su campioni e subset di feature, decisioni robuste grazie all'aggregazione di predizioni dei singoli alberi	Classificazione e regressione, cattura pattern complessi e non lineari	Training: feature tabellari numeriche/categoriali (dati strutturati) Operativi: nuovo vettore di feature oggetto della predizione	Bassa: singoli alberi interpretabili, ensemble complessivo poco leggibile e complesso da ricostruire
SVM	Classificatore a margine massimo cerca linea o piano separatore, kernel per non linearità, efficace in alta dimensionalità	Classificazione e regressione, riconoscimento di pattern complessi e non lineari nei dati	Training: vettori di feature, adatto a dataset piccoli/medi e ben strutturati Operativi: nuovo vettore di feature	Media per SVM lineare; bassa per kernel (decisione basata su molti support vectors combinati e su spazi trasformati non osservabili)
K-Means	Algoritmo iterativo che assegna ogni punto al centroide più vicino, clustering basato su distanza e minimizzazione della variabilità intra-cluster [81], problemi di convergenza	Clustering e pattern discovery	Training: Dati tabellari numerici (strutturati) Operativi: nuovo vettore da assegnare a un cluster	Media/Alta: cluster sono definiti dai centroidi e la distanza dagli stessi, il processo è basato su regole geometriche intuitive ma i cluster non hanno semantica intrinseca

Tabella 2.6: Confronto tra tecniche selezionate di ML (Random Forest, SVM, K-Means), parte 1.

Machine Learning tradizionale: si fonda su modelli statistici addestrati su dataset statici. In questi la struttura del modello, ossia la forma funzionale che determina il comportamento, e le feature rilevanti che il modello riesce ad estrarre dai dati, vengono definite a priori, mentre i parametri vengono appresi automaticamente dai dati. Richiede dati che tipicamente devono essere organizzati e strutturati.				
Tecniche	Dimensioni caratteristiche di confronto			
	Dom.	Scal.	Ris. Cmp	Temp. Add
Random Forest	Predizione supervisionata	Il modello base non nasce per Big Data, ma è adattabile grazie alla forte parallelizzabilità e a implementazioni distribuite [82], [83]	CPU-based; altamente parallelizzabile (su diversi core di CPU) perché ogni albero è indipendente [84], memoria dipende da dimensione dataset (durante il training) e dal numero e profondità degli alberi (dopo il training).	Training generalmente più rapido rispetto a SVM [85] non lineari; dipende da n. alberi, profondità e n. di feature
SVM	Predizione supervisionata	Non molto scalabile, in particolare kernel SVM (che richiede matrice $N \times N$); migliorabile con algoritmi dedicati [86], [87], [88]	Kernel SVM richiedono memoria elevata per la matrice $N \times N$ (ancora peggio su dataset grandi con tanti N campioni), SVM lineare più leggera [88]	In generale addestramento più lento del RF nel caso di SVM con kernel, soprattutto se con dataset grandi. Il tempo di addestramento cresce molto velocemente all'aumentare della dimensione del dataset [85].
K-Means	Pattern discovery non supervisionato	Alta scalabilità, parallelizzabile, funziona bene con anche con dataset grandi ma con dataset di scala web gli hardware tradizionali limitano le prestazioni. [89], [90], [81],	Computazione vettoriale e basata sul semplice calcolo delle distanze su CPU, parallelizzabile, tuttavia, ricalcolo del centroide più vicino per ogni punto a ogni iterazione diventa rapidamente oneroso su dataset molto grandi come quelli di scala web [81]	Training rapido anche su dataset grandi (diventa lento su dataset di scala web, tuttavia tecniche come ranked retrieval accelerano la convergenza) [81]

Tabella 2.7: Confronto tra tecniche selezionate di ML (Random Forest, SVM, K-Means), parte 2.

Deep Learning: le rappresentazioni interne e le trasformazioni dei dati vengono apprese automaticamente dal modello. Questo limita le caratteristiche da definire a monte, tra le quali resta inclusa l'architettura. Riesce a gestire enormi moli di dati non strutturati.					
Tecniche		Dimensioni caratteristiche di confronto			
		Prop.	Task	Input	Interpret.
Architetture	CNN	Convoluzioni locali con pesi condivisi; estrazione gerarchica di feature	Vision tasks: classificazione, object detection, segmentazione; image-to-image tasks	Training: Dati strutturati organizzati nello spazio o nel tempo 1D/2D/3D (immagini, audio, video)	Bassa perchè filtri e attivazioni non interpretabili, rappresentazione gerarchica poco leggibile
				Operativi: gestisce anche input di dimensioni variabili (kernel convolutivo si applica in ripetizione) purché rimanga invariata la struttura del dato [40]. Non accettano input eterogenei.	
	RNN/LSTM	Modelli sequenziali con memoria tramite stati ricorrenti; LSTM mitiga il gradiente vanescente	Sequence modeling, time-series forecasting, anomaly detection, elaborazione di sequenze testuali e numeriche	Training: tensori 2D/3D che rappresentano dati sequenziali numerici, testuali ecc. (serie temporali, sequenze di token)	Bassa: stati ricorrenti non osservabili e difficile da interpretare il contributo di ogni elemento della sequenza
				Operativi: nuova sequenza da analizzare	
	Transformer	encoder-only (es. BERT, RoBERTa, ViT)	Comprensione e analisi del contenuto, estrazione di informazioni e relazioni ecc.	Training: tensori 2D/3D, sequenze di token embedding (testo tokenizzato, patch visive, frame audio, altri feature), anche versioni multimodali Operativi: Dati grezzi del dominio (testo, immagini, audio, ecc.), trasformati in token embedding	Bassa: la logica interna è poco trasparente perché le rappresentazioni sono altamente distribuite e ogni token interagisce con tutti gli altri tramite molte head di attenzione e numerose trasformazioni non lineari
		decoder-only (es. GPT, LLaMA, Mistral)	Generazione di sequenze, completamento di sequenze, reasoning generativo ecc.		
		encoder-decoder (es. T5, BART, Whisper)	Trasformazioni sequence-to-sequence (traduzione, riassunto, riscrittura)		

Tabella 2.8: Confronto tra tecniche selezionate di DL (architetture: CNN, RNN/LSTM, Transformer), parte 1.

Deep Learning: le rappresentazioni interne e le trasformazioni dei dati vengono apprese automaticamente dal modello. Questo limita le caratteristiche da definire a monte, tra le quali resta inclusa l'architettura. Riesce a gestire enormi moli di dati non strutturati.					
Tecniche		Dimensioni caratteristiche di confronto			
		Dom.	Scal.	Ris. Cmp	Temp. Add
Architetture	CNN	Computer Vision	Scalano bene con dati e parametri, altamente parallelizzabili per l'operazione di convoluzione [1], [91], [92].	Uso intensivo di GPU (specializzata per elevata parallelizzabilità delle convoluzioni), costo computazionale cresce con reti profonde (servono più GPU) VRAM è il principale collo di bottiglia come nelle altre applicazioni di DL [92] [93]	Training più efficiente delle reti fully connected grazie a pesi condivisi e connessioni locali, parallelismo accelera addestramento, reti profonde richiedono più tempo ma restano gestibili con ottimizzazioni. [40]
	RNN/LSTM	Time-series, Speech Processing, NLP etc.	Bassa, la sequenzialità impedisce la parallelizzazione e limita la scalabilità rispetto a CNN e Transformer [49], [94], [95]	GPU utilizzata solo per operazioni interne al time-step, sequenzialità dei time-step riduce efficienza della GPU perché non è parallelizzabile, memoria cresce con la lunghezza della sequenza, LSTM più costose delle RNN ma mantengono informazione per periodi più lunghi	Training lento per dipendenza sequenziale, LSTM più stabili e migliori su sequenze più lunghe, ma non eliminano il problema dell'exploding gradient, l'instabilità è risolta con l'aggiunta di altre tecniche
	Transformer	encoder-only (es. BERT, RoBERTa, ViT)	Alta scalabilità, completamente parallelizzabili a differenza delle RNN [49], sfruttano GPU/TPU in modo efficiente	Calcolo matriciale intenso per elaborazione parallela dei token, uso di GPU e TPU (Google), hardware ad hoc per questo tipo di operazioni [96] VRAM è il collo di bottiglia, cresce rapidamente con sequenze lunghe	Training stabile e parallelizzabile, ma self-attention comporta costo computazionale quadratico che lo rende oneroso in termini di tempo per sequenze lunghe
		decoder-only (es. GPT, LLaMA, Mistral)			
		encoder-decoder (es. T5, BART, Whisper)			

Tabella 2.9: Confronto tra tecniche selezionate di DL (architetture: CNN, RNN/LSTM, Transformer), parte 2.

Tecniche		Dimensioni caratteristiche di confronto			
		Prop.	Task	Input	Interpret.
Modelli generativi	LLM (Tipologia: Transformer decoder-only, autoregressivi, es. GPT, LLaMa)	Modello autoregressivo su larga scala, apprende rappresentazioni linguistiche profonde, addestrato per prevedere token successivo	Generazione autoregressiva di sequenze di token	Training: LLM puro allenato solo su testo tokenizzato convertito in tensore 2D (sequence_length × embedding_dim), (MLLM allenato su più dati diversi)	Bassa per la natura del transformer, per la struttura autoregressiva e la scala molto elevata del modello
				Operativi: LLM puro riceve solo prompt testuali tokenizzati, LLM + encoder esterno riceve oltre ai prompt testuali tokenizzati, anche embedding estratti da altre modalità (MLLM riceve input multimodali)	
	GAN	Addestramento avversariale tra generatore e discriminatore	Generazione di dati realistici	Training: discriminatore riceve dati reali, il tipo di dato dipende dal dominio, tipicamente immagini (tensore strutturato 3D (H × W × C)), il generatore riceve vettori latenti	Bassa, le rappresentazioni latenti non sono leggibili e la dinamica avversariale G-D è poco trasparente
				Operativi: presenti sono nelle versioni condizionali (text-to-image, image-to-image)	
	Diffusion Models (es Stable Diffusion, DALL·E 2)	Apprende a prevedere il rumore aggiunto (forward diffusion), ricostruisce campione rimuovendo rumore in step di denoising progressivo (reverse diffusion)	Generazione in base al tipo di dato di addestramento es. immagini (immagini realistiche, Image-to-image transformation, editing) text-to-image (text encoder esterno), audio, 3D	Training: Il dataset è composto da dati specifici (immagini testo, audio, 3D) da convertire in tensori per essere accettati dalla rete (es. immagini tensori 3D HxWxC, testo tensori 2D ecc.)	Bassa, lo spazio latente e il processo di denoising non leggibili, generazione tramite centinaia di trasformazioni lineari non ricostruibili
				Operativi: presenti solo nelle versioni condizionali (text-to-image, image-to-image, audio-conditioning ecc.)	
	VAE	Encoder-decoder probabilistico con spazio latente continuo	Generazione nuovi dati, ricostruzione parti mancanti dato, interpolazione tra esempi, Immagini generate di minore qualità rispetto a GAN e Diffusion Models [40]	Training: funzionano bene con dati ad alta dimensionalità (immagini e audio), dataset reale (immagini, audio, testo, tabellare...) convertito in tensori prima di entrare nell'encoder come per le altre tecniche di DL	Bassa, spazio latente è continuo e probabilistico poco interpretabile, la ricostruzione è basata su trasformazioni non lineari. Tuttavia più interpretabili di GAN e Diffusion (spazio latente più regolare)
				Presente solo per ricostruzione, editing o varianti condizionali, la generazione pura non richiede alcun input operativo	

Tabella 2.10: Confronto tra tecniche selezionate di DL (modelli generativi: LLM, GAN, Diffusion Models, VAE), parte 1.

Tecniche		Dimensioni caratteristiche di confronto			
		Dom.	Scal.	Ris. Cmp	Temp. Add
Modelli generativi	LLM (Tipologia: Transformer decoder-only, autoregressivi, es. GPT, LlaMa)	NLP dominio tipico, ma le estensioni multimodali con encoder specializzati lo rendono applicabile ad altri domini	Molto alta, scaling laws, prestazioni aumentano con numero di parametri dati e compute [9], addestrabili fino a centinaia di miliardi di parametri	Essendo basati su Transformer condividono i costi computazionali della self-attention, operando su scala maggiore richiedendo l'uso di molte GPU/TPU e consumi di VRAM molto più elevati	Basato su backpropagation standard, semplice e stabile dal punto di vista algoritmico. Tuttavia, il costo quadratico della self-attention e la grande quantità di dati necessari rendono il training estremamente lungo
	GAN	Vision (dominio dominante ma non esclusivo)	Possono scalare su dataset e modelli grandi ma con la scala cresce l'instabilità del training e aumentano molto le risorse computazionali richieste. [97], [98] [99]	GAN per alta risoluzione problemi di memoria, batch grandi migliorano stabilità e efficienza di uso GPU ma problemi con alta risoluzione, ProGAN risolve il problema riducendo batch size, Modelli grandi come BigGAN alte risorse computazionali (su TPU) [100]	Training instabile, difficile convergenza richiede più tentativi di tuning e verifiche che aumentano tempi di addestramento, richiede strategie di stabilizzazione ma a un costo computazionale maggiore [40]
	Diffusion Models (es Stable Diffusion, DALL·E 2)	Vision (dominio dominante ma non esclusivo)	Scalabilità abbastanza alta, training stabile e parallelizzabile, permette di scalare dataset molto grandi [101], [102]	Alti costi computazionali e molta VRAM occupata per la natura ricorsiva dei numerosi step, costo computazionale cresce con dati ad alta dimensionalità (es. immagini 3D), modelli text-to-image si producono matrici grandi da memorizzare [103], [104] [105].	Training lungo per il vasto numero di iterazioni e campioni rumorosi che richiede, tuttavia è stabile e regolare (rispetto a GAN)
	VAE	Multi-dominio in base ai tipi di dati e task	Scalabilità medio-alta dovuta al fatto che sono contenute reti standard senza meccanismi complessi, sono addestrati tramite metodo progettato per scalare a dataset di grandi dimensioni, parallelizzabile [106].	Relativamente leggeri dal punto di vista computazionale e del consumo di VRAM per la loro struttura semplice interna. Tuttavia, varianti molto profonde o gerarchiche (es NVAE) [107] più pesanti in memoria	Training semplice basato su ottimizzazione tramite backpropagation di una singola funzione obiettivo definita, efficiente e più stabile rispetto ai modelli avversariali [40]

Tabella 2.11: Confronto tra tecniche selezionate di DL (modelli generativi: LLM, GAN, Diffusion Models, VAE), parte 2.

La comparazione sviluppata nel presente capitolo non ha come obiettivo la delineazione dello stato dell'arte, né l'individuazione della tecnica più performante all'interno di ciascun paradigma di intelligenza artificiale. Un confronto di tale natura, infatti, implicherebbe l'impostazione di un vero e proprio problema decisionale che, per potersi definire strutturato, richiederebbe la definizione esplicita di un obiettivo, di un insieme di alternative e dei relativi vincoli, elementi che, allo stato attuale dell'analisi, non risultano ancora pienamente determinati.

L'intento del capitolo è piuttosto quello di offrire una panoramica organica e una prima base di confronto tra i principali paradigmi e le tecniche di intelligenza artificiale che costituiscono oggi il nucleo tecnologico e metodologico degli strumenti contemporanei. Sebbene tali strumenti si presentino, nella maggior parte dei casi, come sistemi complessi e ibridi, risultanti dall'integrazione di più tecniche e approcci orientati al perseguimento di specifici obiettivi, la comprensione delle caratteristiche, dei limiti e delle potenzialità proprie di ciascuna tecnica risulta fondamentale per interpretarne il ruolo all'interno di applicazioni più articolate.

Nel capitolo successivo saranno analizzate le fasi del processo di progettazione e proposta una mappatura teorica tra queste e le diverse famiglie di strumenti di intelligenza artificiale potenzialmente impiegabili. In tale contesto, obiettivi e vincoli risulteranno parzialmente definiti, contribuendo ad accrescere il livello di strutturazione del processo decisionale. Le alternative considerate per questa associazione sono costituite dagli strumenti di intelligenza artificiale di cui, nel presente capitolo, sono state illustrate le modalità di funzionamento e confrontati i vincoli di implementazione.

3. Dai modelli decisionali al framework teorico per l'applicazione dell'AI ai processi di progettazione

Considerare il processo progettuale e, più nello specifico, le fasi che lo compongono, consente di definire con maggiore chiarezza il contesto applicativo delle tecniche di Intelligenza Artificiale che questa tesi intende esaminare. A tal proposito, dopo aver analizzato le principali articolazioni del processo di progettazione, il presente capitolo si propone di sviluppare una mappatura di natura teorica, nella quale ciascuna attività e sottofase dei diversi livelli progettuali viene associata a uno o più strumenti di Intelligenza Artificiale idonei.

Una considerazione importante riguarda il fatto che l'accuratezza delle associazioni proposte nel framework è legata al diverso grado di specificità delle fasi del processo progettuale rispetto al dominio applicativo considerato. In particolare, per le fasi caratterizzate da attività concettualmente stabili e ricorrenti tra domini differenti, le associazioni risultano maggiormente trasferibili, rendendo la natura generalizzabile della mappatura più efficace. Al contrario, nelle fasi fortemente influenzate dalle specificità del dominio, la corrispondenza tra fase e strumento tende a perdere validità trasversale e, sebbene mantenga un valore generale, risulta meno accurata, poiché richiede un'interpretazione maggiormente contestualizzata.

Fasi quali il Planning o il Problem Structuring, pur presentando lievi adattamenti rispetto a contesti specifici, conservano una struttura e sequenza di attività in larga misura comune nei diversi ambiti progettuali. Fanno eccezione alcuni casi particolari, come la progettazione software, nella quale vengono adottate metodologie Agile specifiche, che introducono meccanismi peculiari come le user stories e il product backlog, e organizzano il processo di sviluppo attraverso Sprint. Ma nella maggioranza dei casi queste due fasi, presentando un buon livello di trasversalità delle attività svolte, rendono le associazioni della mappatura trasferibili tra ambiti diversi.

Al contrario, fasi quali l'idea generation e il concept optimization risultano fortemente dipendenti dal dominio applicativo. Nella fase di idea generation, ad esempio, è richiesta una componente creativa la cui natura può variare sensibilmente in funzione del contesto. La progettazione di una sedia, lo sviluppo di un nuovo prodotto alimentare, la realizzazione di un componente ingegneristico o la sintesi di una nuova proteina implicano modalità creative profondamente differenti e, di conseguenza, un diverso rapporto con gli strumenti di Intelligenza Artificiale.

Analogamente, nella fase di optimization, la modellazione delle caratteristiche di un prodotto di largo consumo non comporta lo stesso livello di formalizzazione e di rigore richiesto per l'ottimizzazione di un componente aeronautico. Tali differenze non sono riconducibili esclusivamente alla transizione tra stadi progettuali distinti, dal Conceptual, all'High-Level System Architecture, fino al Detailed design, ma riflettono la specificità del contesto applicativo in cui il processo di progettazione è inserito.

Nelle fasi convergenti del processo decisionale può emergere, in alcuni casi, una maggiore uniformità delle metodologie adottabili, poiché le attività di valutazione richiedono spesso la definizione di criteri e l'assegnazione di pesi, procedure che risultano in larga misura generalizzabili rispetto ai diversi domini applicativi. Tuttavia, anche nelle fasi convergenti, la dipendenza dal contesto può riemergere perché criteri di natura diversa implicano livelli di formalizzazione e di rigore differenti. La valutazione di aspetti quali l'estetica, la novità o la sostenibilità percepita non è assimilabile alla valutazione di prestazioni tecniche, requisiti di sicurezza o margini strutturali, che richiedono modelli formali, simulazioni e validazioni ingegneristiche rigorose.

Risulta pertanto evidente che, essendo la trattazione orientata a un'analisi multidominio, l'obiettivo del capitolo non consiste nell'individuazione di uno strumento ottimale in senso assoluto, bensì nella definizione di una mappatura di riferimento di carattere teorico. Tale mappatura risulterà tanto più accurata quanto maggiore sarà il grado di trasversalità della singola fase rispetto ai diversi domini applicativi. Al contrario, per le fasi fortemente vincolate al contesto, oltre a fornire associazioni di carattere indicativo ed esempi preliminari di applicazioni specifiche, si rimanda al terzo capitolo, nel quale si procederà con l'analisi di casi studio concreti, all'interno dei quali sarà possibile apprezzare con maggiore dettaglio le specificità di ciascuna fase e le differenze legate all'impiego degli strumenti nei differenti ambiti disciplinari. Tale approccio permetterà di evidenziare le

divergenze tra l'impostazione teorica e le applicazioni pratiche, determinate dai molteplici vincoli dei contesti operativi concreti.

3.1. *Il ruolo dei processi decisionali all'interno dei processi di progettazione*

All'interno delle organizzazioni, il processo decisionale costituisce l'elemento centrale che guida e struttura le scelte ultime [108], incluse quelle che orientano i processi di progettazione.

La progettazione, infatti, può essere interpretata come una sequenza di decisioni interdipendenti che, attraverso cicli iterativi e incrementali, conducono alla produzione di risultati progressivamente migliori. Prima ancora di configurarsi come un problema organizzativo, il processo decisionale si presenta innanzitutto come un problema di natura cognitiva, soggetto ai limiti della razionalità umana [109]. Le capacità cognitive limitate, la disponibilità incompleta delle informazioni e il tempo ristretto costituiscono fattori che impediscono l'identificazione dell'alternativa realmente ottimale.

Per tali ragioni, Simon introduce il concetto di *satisficing*, in contrapposizione a quello del *maximizing*: data la realtà operativa delle organizzazioni, la scelta "sufficientemente buona" rappresenta la soluzione più realistica e raggiungibile. In questo senso, Simon afferma che, grazie alle organizzazioni, concepite come strumenti cognitivi collettivi, gli individui possono avvicinarsi a una forma di razionalità oggettiva [108].

Si apre pertanto un interrogativo rilevante: in che modo questa concezione di razionalità, intesa come prodotto dell'organizzazione, può essere oggi rivalutata alla luce dell'introduzione di strumenti di intelligenza artificiale a supporto dei processi decisionali?

Per rispondere a tale quesito, è utile richiamare un ulteriore concetto elaborato da Simon nel 1973 riguardante il livello di strutturazione del problema decisionale, introdotto in relazione alla possibilità di trattare computazionalmente i processi decisionali [110]. È opportuno precisare che queste considerazioni riflettono una concezione dell'intelligenza artificiale di natura prevalentemente algoritmica, coerente con il contesto storico in cui furono formulate.

La distinzione proposta da Simon oppone i *well-structured problems* (WSP) agli *ill-structured problems* (ISP). I primi sono caratterizzati dalla presenza di alcune proprietà ricorrenti quali: criteri di soluzione chiaramente definiti, uno spazio del problema esplicito, un insieme identificabile di mosse ammissibili, una conoscenza formalmente rappresentabile e procedure risolutive facilmente computabili. Simon sottolinea tuttavia come tali condizioni costituiscano un'idealizzazione, osservando che nessun problema reale le soddisfa pienamente.

Gli *ill-structured problems*, al contrario, si distinguono per la presenza di obiettivi ambigui o in evoluzione, condizioni iniziali incomplete, criteri di valutazione incerti, vincoli che emergono nel corso del processo e una continua ridefinizione dello spazio del problema stesso. Questa categoria descrive in modo più aderente la natura dei problemi complessi affrontati nei contesti decisionali e progettuali reali, nei quali la struttura del problema non è data a priori, ma si costruisce progressivamente attraverso l'azione e la reinterpretazione continua.

In questo quadro teorico, Simon sviluppa un modello all'interno del quale la soluzione emerge attraverso cicli successivi di esplorazione, valutazione e riformulazione iterativa. La distinzione tra *well-structured problems* (WSP) e *ill-structured problems* (ISP) non assume dunque un carattere qualitativo o dicotomico, bensì graduale in cui lo spazio del problema tende progressivamente a strutturarsi con l'avanzare delle attività di analisi e ridefinizione, rendendo il problema via via più trattabile.

Da questa prospettiva, Simon sostiene che la risoluzione di problemi destrutturati non richiede forme di intelligenza qualitativamente diverse, ma piuttosto una maggiore disponibilità di conoscenza, capacità di memoria e strumenti rappresentazionali adeguati [110]. Tale impostazione concettuale ha esercitato un'influenza significativa sui modelli contemporanei di progettazione iterativa e sui moderni approcci al *problem solving*, ma nel tempo è stata anche soggetta a modifiche e revisioni.

Per esempio, Reed, riesaminando la letteratura precedente identifica quattro tipologie di problemi. Tra questi i *design problems* rappresentano casi paradigmatici di ISP, in contrasto con i *puzzles*, che si distinguono come problemi ben strutturati. L'esito delle sue analisi non contraddice Simon, infatti conferma che la distinzione tra WSP e ISP è graduale e che gli stessi principi cognitivi si applicano a entrambi; tuttavia, aggiunge una precisazione significativa secondo cui, sebbene i principi cognitivi siano formalmente gli stessi, non operano né si manifestano nello stesso modo nelle due tipologie di problemi. Nei problemi destrutturati, infatti, la riformulazione continua del problema, l'evoluzione delle rappresentazioni, il maggiore ruolo della percezione e l'influenza decisiva dell'expertise modificano sostanzialmente la dinamica del problem solving [111].

Un ulteriore avanzamento teorico è proposto da Gorry e Morton nel 1971 [112], i quali reinterpretano la distinzione di Simon tra decisioni programmed e non-programmed [113]. I due autori propongono una nuova chiave di lettura del modo in cui il diverso grado di struttura cognitiva impiegato nell'affrontare decisioni di natura differente possa essere messo in relazione con il ruolo dell'essere umano e della macchina nei processi decisionali. Da un lato le attività ripetitive e routinarie, per le quali esistono procedure definite; dall'altro, quelle nuove, complesse e poco strutturate, che richiedono giudizio, interpretazione e continua definizione del problema. Ne deriva che i problemi strutturati possono essere gestiti automaticamente attraverso algoritmi e modelli formalizzati, mentre quelli non strutturati richiedono la centralità del giudizio umano.

Un altro concetto ripreso dagli autori riguarda il modello di problem solving articolato da Simon in tre fasi: Intelligence, Design e Choice [114]. La fase di *Intelligence* riguarda l'identificazione del problema e delle condizioni che interessano una decisione; la fase di *Design* consiste nella generazione delle possibili alternative; la fase di *choice* nella selezione dell'opzione più adeguata. Tali fasi sono iterative, ricorsive e gerarchiche, poiché ciascuna può generare a sua volta sotto-problemi che richiedono la ripetizione delle tre fasi. Nell'estensione proposta da Gorry e Morton, viene ribadita la medesima conclusione degli studi precedenti, ma aggiungendo un livello di chiarificazione superiore. La rivisitazione proposta specifica che, un problema completamente strutturato, presenta tutte e tre le fasi di Intelligence, Design e Choice e ciascuna è resa codificabile da regole e algoritmi; un problema semi-strutturato presenta solo alcune fasi strutturabili; un problema destrutturato risulta invece più difficilmente automatizzabile e richiede l'intervento umano in tutte le fasi. Dunque, in quest'ultimo caso, sistemi informativi e framework di sistematizzazione possono fornire supporto, ma non sostituire il giudizio e il controllo umano [112].

Con particolare riferimento ai processi di progettazione, questi configurano per loro natura problemi decisionali destrutturati, soprattutto nei contesti di innovazione. È in tale direzione che si collocano approcci ibridi come quello proposto da Montagna e Norese [115], i quali integrano metodi di identificazione e strutturazione del problema con strumenti di supporto decisionale tradizionali, offrendo un framework orientato a rendere più facilmente aggredibili situazioni ad elevata incertezza.

Nel complesso, emerge che, i problemi decisionali collocati in contesti fortemente destrutturati richiedono un maggiore intervento umano nella gestione del processo decisionale. Inoltre, in tali casi, i soggetti coinvolti possono avvalersi di framework o strumenti informativi finalizzati ad accrescere il livello di strutturazione del problema, rendendolo progressivamente più trattabile. Al contrario, i problemi decisionali caratterizzati da un più elevato grado di definizione richiedono un coinvolgimento umano ridotto, poiché risultano maggiormente formalizzabili mediante procedure automatizzabili con strumenti di supporto informatico. In termini generali, la tipologia e l'impiego di tali strumenti tende a differenziarsi in funzione del grado di strutturazione del problema decisionale.

Questa visione, relativa all'impiego di sistemi informativi differenziati e al ruolo del progettista nei processi decisionali e di interazione uomo-macchina, è estendibile anche al contesto specifico dell'intelligenza artificiale. Infatti, la visione attualmente più diffusa e consolidata, fondata sugli approcci tradizionali di intelligenza artificiale, risulta coerente con quanto appena delineato per i classici strumenti informativi.

Tuttavia, le soluzioni tecnologiche moderne più avanzate suggeriscono un'evoluzione di questa interpretazione. Infatti, alcuni sistemi di intelligenza artificiale sono oggi in grado di affrontare anche situazioni caratterizzate da elevata incertezza e complessità con un livello di autonomia maggiore rispetto agli approcci tradizionali, riproducendo parzialmente capacità tipicamente umane di adattamento. Infatti, approcci basati su agenti e sistemi multi-agente mostrano meccanismi di auto-organizzazione e di allineamento dinamico, in cui le strategie operative vengono aggiornate in funzione dei feedback correnti, risultando adatti a fenomeni complessi

tipici delle organizzazioni. Inoltre, gli avanzamenti introdotti dall'AI generativa suggeriscono la possibilità di intervenire artificialmente anche su compiti di natura creativa e divergente, riproducendo processi cognitivi umani diversi da quelli impiegati nelle tradizionali modalità convergenti di risoluzione dei problemi.

Inoltre, la ricerca sull'intelligenza artificiale sta esplorando direzioni di sviluppo senza precedenti, in particolare nell'ambito dell'Artificial General Intelligence (AGI). Dove, pur trattandosi di un campo ancora prevalentemente esplorativo, l'obiettivo è quello di avvicinarsi a forme di intelligenza più generali, capaci di emulare alcuni meccanismi cognitivi umani più impliciti, risultando capaci di gestire con un grado di autonomia crescente anche problemi che in precedenza non sarebbero stati attribuibili a sistemi artificiali.

Tali considerazioni verranno riprese nel paragrafo dedicato alla mappatura, dove saranno reinterpretate alla luce delle associazioni tra gli strumenti di Intelligenza Artificiale e le diverse fasi del processo di progettazione.

3.2. Il processo di progettazione: modelli teorici

Nell'ambito dei processi di progettazione si sono sviluppati approcci di natura diversificata che hanno definito dei riferimenti per guidare l'esplorazione e la selezione di soluzioni. Alcuni di questi, mantengono l'impronta del contesto da cui nascono, altri cercano di mantenere una logica più trasversale e generalizzabile.

Come già discusso, la progettazione è un processo strettamente connesso ai meccanismi decisionali che si collocano all'intersezione tra scienza e tecnologia e che coinvolgono molteplici ambiti disciplinari, ciascuno operante attraverso decisioni continue all'interno del proprio dominio [116]. Tra questi rientrano:

- Architettura e Industrial Design, dimensioni che culminano nel concetto di stile e nelle forme espressive dell'arte
- Scienze economiche, sociali, psicologiche e politiche
- Ricerca scientifica, orientata alla scoperta di nuovi modelli teorici e delle loro applicazioni pratiche
- Mondo dell'ingegneria e dei processi di produzione

Nel presente lavoro, il riferimento è circoscritto agli ambiti della ricerca scientifica, dell'industrial design e della progettazione ingegneristica. Tale specificazione riguarda soprattutto il capitolo successivo, in cui l'analisi assume un carattere meno trasversale e maggiormente specifico rispetto ai singoli domini.

All'interno di questo contesto si inseriscono i Design Methods, intesi come strumenti che guidano l'attività progettuale e che si articolano in tre principali stream di ricerca [117]:

- Scientific Design, che fa uso di strumenti scientifici rigorosi, spesso quantitativi o semi-quantitativi, generalmente specifici per ciascun ambito disciplinare.
- Design Science, letteralmente scienza della progettazione, che comprende quell'insieme di metodi propri del progettare in quanto tale, indipendentemente dall'ambito applicativo.
- Science of Design, ovvero il filone che studia i processi di progettazione con l'obiettivo di comprenderne le dinamiche cognitive e i meccanismi di apprendimento, analizzando come i progettisti affrontano i problemi e generano soluzioni. In relazione a questo, la letteratura distingue diverse modalità di ragionamento impiegate dai progettisti: ragionamenti induttivi, attraverso cui, dai dati e dai fatti vengono derivate regole generali; deduttivi, in cui dalle regole si giunge alla soluzione; e abduttivi, tipici in particolare dei progettisti esperti, che dall'esperienza accumulata giungono direttamente alla soluzione applicando in modo implicito regole apprese.

I tre approcci considerati possono essere letti, nel contesto della presente trattazione, in funzione del ruolo attribuito all'intelligenza artificiale secondo due livelli tematici.

Da un lato, l'intelligenza artificiale può essere considerata come uno strumento progettuale aggiuntivo, collocabile sia tra gli strumenti ad alto livello di astrazione e a carattere trasversale alle discipline, come quelli

proposti dalla Design Science, sia tra quelli maggiormente specifici rispetto ai singoli domini applicativi, tipici dello Scientific Design. In questa accezione, l'AI è in grado di svolgere compiti non affrontabili mediante strumenti progettuali tradizionali, oppure di affrontarli in modo più efficiente.

Dall'altro lato, l'AI può essere interpretata come un elemento che estende le capacità cognitive del progettista nello svolgimento delle attività progettuali, operando come mezzo per l'implementazione e il coordinamento di framework e approcci progettuali esistenti, quando si configura in forme caratterizzate da un maggiore grado di autonomia, che internalizza facoltà di ragionamento, comprensione e controllo tipicamente umane. In questa prospettiva, la Science of Design contribuisce a chiarire come realizzare strumenti di intelligenza artificiale ispirati ai meccanismi cognitivi del progettista.

Quando si analizzano i processi di progettazione, la letteratura tende a fare riferimento a tre elementi fondamentali: i Design Objects, i Design Spaces e le attività e i processi. In questa ottica, sono stati proposti diversi modelli teorici che costituiscono tuttora riferimenti consolidati.

Un primo contributo rilevante è quello di Smith & Browne (1993) [118], che affrontano il tema dei Design Objects mettendo in evidenza lo stretto legame tra progettazione e problem solving. Secondo gli autori, gli oggetti della progettazione sono costituiti da obiettivi, vincoli e alternative, che emergono attraverso un continuo passaggio tra il mondo reale e il mondo della coscienza, inteso come la mente del progettista. Tale passaggio è mediato da processi di natura interpretativa e rappresentativa, attraverso i quali il progettista costruisce e rielabora le rappresentazioni del problema e delle possibili soluzioni. In relazione alla presente trattazione, gli strumenti di intelligenza artificiale possono risultare particolarmente adatti sia a operare a livello della coscienza del progettista, sia a fungere da supporto o veicolo per tali processi interpretativi e rappresentativi.

Stempfle e Badke-Shaub (2002), piuttosto, hanno esaminato come i progettisti organizzano il loro lavoro, osservando che una parte rilevante del tempo non viene dedicata esclusivamente alla gestione degli oggetti della progettazione in termini di obiettivi, vincoli e alternative, ma anche alla pianificazione delle modalità con cui le attività devono essere svolte. In questo senso, emerge che le attività e i processi diventano una dimensione fondamentale del lavoro progettuale [119].

Su questa linea si colloca anche il contributo di Schön [120], che interpreta la progettazione come un processo riflessivo. La riflessione in azione consente al progettista di riformulare e trasformare progressivamente il problema progettuale, determinando l'evoluzione degli obiettivi, dei vincoli e delle alternative disponibili e, di conseguenza, delle scelte progettuali.

Un'altra proposta teorica è quella di Hatchuel & Weil (2003) [121], che, attraverso la C-K theory, introducono il concetto di Design Spaces. In questo modello, il processo di progettazione è descritto come un continuo spostamento della mente del progettista tra lo spazio dei concetti (C-space) e lo spazio della conoscenza (K-space). Attraverso operazioni di espansione e congiunzione, il progettista è in grado di elaborare nuovi concetti a partire da una conoscenza iniziale e, a sua volta, di generare nuova conoscenza riutilizzabile a partire dai concetti sviluppati. Tale dinamica richiama sensibilmente alcuni meccanismi di apprendimento implementati dalle tecniche di machine learning e deep learning.

Infine, un modello particolarmente rilevante è quello di Gero, noto come modello FBS (Function-Behaviour-Structure) [122] che consente di mettere in relazione diversi livelli di progettazione (concettuale, architettuale, di dettaglio) e dimensioni differenti quali i design objects, i design spaces, le attività e i processi. Nel modello FBS, la progettazione è descritta come il passaggio dalla funzione, definita a livello concettuale dai designers che traducono i requisiti in finalità operative; al comportamento che ne rende possibile la realizzazione, concepito dai progettisti di dettaglio; fino alla struttura, formulata dalla collaborazione tra designers e progettisti architeturali, che ne consente la configurazione implementativa.

Funzioni, comportamenti e strutture costituiscono gli oggetti della progettazione e sono collocati, secondo Gero, in tre spazi distinti: mondo esterno, mondo interpretato e mondo atteso, tra i quali il processo progettuale si sviluppa attraverso attività sia divergenti sia convergenti.

Gli approcci descritti mettono in luce meccanismi cognitivi della progettazione trasversali alle discipline, in quanto propri del modo di ragionare del progettista. Nei diversi contesti applicativi, tuttavia, si sviluppano metodologie più specifiche.

Da un lato, approcci User-Centred, tipici del design industriale che si basano sui principi del Design Thinking [123] [124] guidano le scelte progettuali a partire dai bisogni degli utenti e delle interazioni del prodotto o servizio con utilizzatori, soggetti interessati e ambiente circostante lungo l'intero ciclo di vita.

Dall'altro, si distinguono approcci di natura tecnico-ingegneristica, maggiormente orientati all'ottimizzazione delle prestazioni, sebbene nell'ultimo periodo anche questi abbiano progressivamente integrato la dimensione esperienziale, a causa della diffusione sempre crescente dei servizi.

Nella pratica, metodologie User-Centered e approcci orientati alle prestazioni vengono spesso impiegati in modo parallelo e complementare su livelli progettuali differenti.

Ne consegue nuovamente che, la scelta dell'approccio progettuale, così come le modalità di ragionamento e i bisogni cognitivi e di rappresentazione del progettista, risultano fortemente dipendenti dal contesto di applicazione del processo di progettazione. Inoltre, nelle realtà aziendali volte alla realizzazione di processi sviluppo prodotto, i diversi ambiti progettuali tendono frequentemente a intersecarsi e a dover individuare una base comune di comunicazione per potersi integrare, ricorrendo a strumenti capaci, da un lato, di adattarsi alle specificità di ciascun ambito e, dall'altro, di fornire un riferimento condivisibile.

3.2.1. Un modello unificato: Stage-Based Design Process

Livelli e domini possono essere considerati come dimensioni che risultano distinte, ma intersecate. Ogni dominio implementa infatti istanze specifiche di ciascun livello di progettazione e, al contempo, alcuni domini risultano caratterizzati in modo più marcato da determinati livelli.

Ad esempio, il livello concettuale è tradizionalmente associato al mondo dell'Industrial Design, poiché gli output tipici di questo dominio sono prevalentemente esito delle attività di tale fase. La progettazione di dettaglio, al contrario, trova maggiore centralità nei contesti ingegneristici e nelle attività di ricerca e sviluppo, sia aziendali sia accademiche. L'high-level system design è invece caratteristico di sistemi complessi, composti da molteplici componenti funzionali diversi, che richiedono l'integrazione e il coordinamento di discipline eterogenee all'interno di un'unica architettura di sistema.

Per mantenere un'impostazione trasversale sia rispetto ai domini applicativi, sia ai diversi livelli della progettazione, nel contesto del processo di sviluppo prodotto, si fa riferimento a un modello unificato noto in letteratura come Stage-Based Design Process. Tale modello riflettendo una gestione del processo coerente con gli approcci sviluppati nell'ambito della Design Science, propone una strutturazione in fasi valida per le diverse categorie progettuali. Allo stesso tempo, all'interno di ciascuna fase, si prevedono attività che possono fare ricorso sia a strumenti comuni, sia specifici, per ciascun livello e dominio.

Coerentemente con tale impostazione, si distinguono le fasi del processo di progettazione in divergenti e convergenti.

Tra le prime rientrano la definizione e strutturazione del problema, la generazione delle idee, la combinazione delle idee e la generazione e ottimizzazione dei concept. Quest'ultima, pur includendo attività di natura anche convergente, è assimilabile a livello macro a una fase divergente, poiché produce un insieme di soluzioni alternative, ciascuna valida ma con combinazioni eterogenee dei parametri ottimizzati. Le fasi convergenti comprendono invece le attività di valutazione e selezione. A tutte queste si anticipa una fase preliminare di planning, che precede tipicamente il design concettuale nel processo di sviluppo prodotto e assume un ruolo cruciale soprattutto nei contesti di innovazione.

Sebbene la struttura per fasi sia studiata per rappresentare un riferimento comune, nei diversi livelli e domini alcune fasi possono risultare assenti, assumere un ruolo dominante rispetto alle altre o essere interpretate in chiave differente.

Nel design concettuale, ad esempio, la creatività è particolarmente accentuata nella fase di generazione delle idee, mentre l'ottimizzazione è condotta con un basso livello di formalizzazione numerica. La funzione obiettivo infatti, per quanto presente, modella spesso variabili qualitative o semi-quantitative, legate ad attributi del prodotto difficilmente misurabili. Inoltre, in questa dimensione, assume inoltre un ruolo centrale la soddisfazione dei bisogni e l'attenzione verso i meccanismi di interazione, che guidano le fasi iniziali attraverso la raccolta e la traduzione dei requisiti in soluzioni orientate all'utente.

Al contrario, negli ambiti scientifici e ingegneristici, il registro progettuale segue una matrice prevalentemente tecnica. La dimensione creativa assume un ruolo più contenuto, pur rimanendo rilevante in alcuni casi di idea generation, in particolare per favorire innovazioni radicali, come dimostrato dal metodo TRIZ nell'applicazione del principio di separazione. In queste discipline, diventano invece prioritarie l'ottimizzazione algoritmica delle prestazioni, la producibilità e la fattibilità tecnica ed economica. In questo caso l'ottimizzazione assume un ruolo centrale perché può essere affrontata in modo efficace grazie all'utilizzo di funzioni obiettivo basate su variabili quantificabili.

Infine, pur suggerendo una sequenzialità di fondo, le fasi del modello non configurano un processo lineare, ma iterativo e ripetitivo all'interno dello sviluppo prodotto. Non tutte le fasi sono sempre presenti e il loro ordine può variare in funzione del problema affrontato, evidenziando una maggiore affinità con approcci di tipo agile rispetto alla sequenzialità rigida tipica dei modelli produttivi tradizionali.




Figura 3.1: Domini, livelli e fasi della progettazione nel processo sviluppo prodotto.

3.3. Applicazione delle categorie di collegamento e compatibilità alle fasi progettuali e agli strumenti di Intelligenza Artificiale

3.3.1. Categorie di collegamento e compatibilità

L'associazione tra le diverse fasi del processo di progettazione e gli strumenti di Intelligenza Artificiale può essere interpretata e giustificata attraverso l'applicazione congiunta di due piani categoriali. Pur sviluppandosi secondo logiche concettualmente distinte, tali piani presentano una natura intrinsecamente complementare.

- Il primo piano riguarda la tipologia di task, che descrive, da un lato, la natura operativa delle attività relative alle diverse fasi del processo progettuale e, dall'altro, le tipologie di azioni che ciascuno strumento di AI è in grado di eseguire. In questa logica, le categorie di riferimento rientrano in ciò che Norese e Ostanello definiscono Context of Action (CoA) [125] e comprendono: Identification (ID), Structuring (STR), Development (DEV), Control (CNTR) e Communication (COM).
- Il secondo piano fa riferimento al ruolo operativo dello strumento di Intelligenza Artificiale e al relativo livello di autonomia, espresso attraverso le categorie di support (SUP), augmentation (AUG) e automation (AUT) [126], che qualificano il modo in cui lo strumento opera in relazione al progettista. Se osservata dal punto di vista delle fasi del processo, questo piano assume una connotazione parallela, esprimibile in termini di livello di criticità dell'attività e di supervisione umana richiesta e distinguibile secondo una scala ordinale articolata in tre livelli: ALTO, MEDIO, BASSO.

L'associazione simultanea delle categorie alle due dimensioni considerate, ossia le attività del processo progettuale e gli strumenti di Intelligenza Artificiale, consente di costruire una mappatura solida che permette da un lato, di verificare l'adeguatezza dello strumento rispetto al tipo di compito richiesto dalla fase; dall'altro, di garantire la compatibilità tra il livello di autonomia, il ruolo operativo con cui lo strumento agisce e il grado di controllo umano ritenuto necessario in funzione della criticità della specifica attività all'interno della fase progettuale.

3.3.1.1. Tipo di task

Secondo il framework istituito da Norese e Ostanello (1988) [125], gli strumenti che servono a supportare le attività decisionali non intervengono sempre nello stesso modo, piuttosto, questi devono essere scelti in funzione del Context of Action (CoA) in cui si opera. Ogni fase del processo progettuale costituisce infatti un CoA distinto, con caratteristiche e bisogni specifici, e richiede quindi strumenti adeguati alla natura dell'attività svolta.

Il modello riconduce le attività del processo decisionale a cinque categorie fondamentali:

- Identification (ID): consiste nel definire il problema decisionale tramite la raccolta e la comprensione di dati interni ed esterni al contesto aziendale, in modo da poter cogliere le opportunità, definire le strategie e avere a disposizione le informazioni necessarie per le altre fasi del processo decisionale.
- Structuring (STR): struttura il problema decisionale organizzando la conoscenza a disposizione in una forma comprensibile e accessibile, consente di avere a disposizione una rappresentazione impostata e sistematica del problema, per avere una base di partenza per la fase di generazione delle soluzioni e una definitiva, per valutare le alternative generate nella fase convergente.
- Development (DEV): rappresenta la fase del processo decisionale in cui il lavoro si orienta concretamente verso la costruzione di soluzioni. Dopo aver identificato e strutturato il problema, qui si passa alla generazione di alternative e alla creazione di possibili scenari, si esplorano le diverse combinazioni di opzioni e si traducono le rappresentazioni del problema in configurazioni operative.
- Control (CNTR): è la fase in cui le soluzioni sviluppate vengono verificate e validate per accertare che rispettino i vincoli e gli obiettivi definiti durante la strutturazione del problema. In questo contesto, il confronto e la valutazione giocano un ruolo centrale nell'analisi delle alternative e rendono possibile individuare criticità, opportunità di miglioramento e margini di ottimizzazione, spesso attivando un

nuovo ciclo generativo. Il controllo diventa così il momento in cui il processo decisionale può essere corretto, raffinato o riformulato, dando origine a iterazioni successive di miglioramento continuo.

- **Communication (COM):** è la dimensione che abilita e sostiene la collaborazione, sia tra stakeholder interni ed esterni, sia tra l'essere umano e gli strumenti utilizzati. È un elemento trasversale che connette e supporta tutte le altre fasi, facilitando la condivisione delle informazioni e la comprensione reciproca.

3.3.1.2. Ruolo operativo, livello di autonomia, criticità e supervisione nell'interazione uomo-macchina

In questo secondo caso, le categorie prese in esame sono quelle che emergono dall'interazione uomo-macchina. Dal punto di vista dello strumento, tali categorie riguardano il ruolo operativo e il livello di autonomia che è in grado di manifestare. Dal lato della fase del processo progettuale, vengono invece considerati il livello di criticità delle attività e il grado di supervisione umana richiesto. Considerate congiuntamente all'interno della relazione uomo-fase-strumento, queste dimensioni concorrono a determinare le associazioni della mappatura finale, sulla base della loro compatibilità reciproca.

Prospettiva dello strumento

Dal punto di vista dello strumento, il ruolo operativo e il livello di autonomia sono distinguibili in tre categorie: SUP, AUG e AUT, che devono essere lette in relazione ad alcuni concetti importanti, dipendenti sia dalle proprietà dello strumento in quanto tale, sia dalla relazione dello strumento con la fase specifica.

Il passaggio da SUP ad AUT, implica un livello di autonomia crescente che influenza e viene nello stesso tempo influenzato, dal livello di presenza richiesto del soggetto umano per completare lo svolgimento di una attività. Meno lo strumento è autonomo, più il soggetto deve essere presente, più la categoria individuata per quello strumento è assimilabile a SUP. Il viceversa implica una maggiore tendenza verso AUT. La necessità di intervento umana, tuttavia, è a sua volta legata a diversi aspetti, i quali in parte riguardano lo strumento, in parte la specifica attività trattata:

- **Livello di criticità della fase:** cambia a seconda di attività convergenti o divergenti. Le attività convergenti, implicando un gate decisionale che definisce il passaggio al ciclo incrementale successivo risultano maggiormente critiche in termini di impatto prodotto e questo aumenta il livello di supervisione necessaria.
- **Affidabilità del modello:** in alcuni casi, il modello è noto per avere dei flop, legati sia all'addestramento, sia a come il modello apprende (es. hallucinations per gli LLM) e quindi l'affidabilità cala, soprattutto quando viene usato per supportare fasi critiche. Questa affidabilità dipende in parte dal meccanismo di funzionamento dello strumento e dallo scopo per cui è stato progettato, in parte dal suo stadio evolutivo, che, se ancora non avanzato, presenta alcuni problemi da raffinare.
- **Livello di interazione con lo strumento:** qualora, per le modalità con cui lo strumento è concepito e implementato, il processo di utilizzo richieda un'elevata interazione, l'utente è chiamato a guidarne in modo continuo il funzionamento, determinando inevitabilmente un aumento del coinvolgimento del soggetto umano. Tale condizione non è tuttavia casuale, ma è il risultato di scelte progettuali connesse allo sviluppo dello strumento, nelle quali il modello di interazione viene definito in funzione dell'attività applicativa per cui esso è concepito e, di conseguenza, del livello di supervisione richiesto dalla fase in cui è impiegato, oltre che del grado di evoluzione tecnologica e di autonomia che è in grado di garantire.
- Come estensione dei punti precedenti, un ulteriore elemento determinante è rappresentato dallo stadio evolutivo dello strumento, che merita una trattazione separata.

Il livello di autonomia dello strumento costituisce una dimensione dinamica, che evolve nel tempo in relazione al progresso tecnologico. Questa prospettiva è già presente nelle formulazioni di Altshuller, il quale, attraverso le leggi di evoluzione dei sistemi tecnici, interpreta l'autonomia non

come una proprietà isolata dello strumento, ma come un esito dell'evoluzione del sistema tecnico nel suo complesso [127], [128]. In particolare, la Legge della Completezza delle Parti del Sistema prevede che un sistema funzionale includa tutte le componenti necessarie allo svolgimento della funzione, comprese quelle di controllo. Negli stadi evolutivi iniziali, tali funzioni possono essere svolte dal soggetto umano, considerato parte integrante del sistema, mentre negli stadi successivi esse tendono a essere progressivamente internalizzate nello strumento.

Questo processo comporta una riduzione del coinvolgimento diretto del soggetto umano all'avanzare del progresso tecnologico dello strumento, che implica una migrazione del suo ruolo, il quale si sposta dalla mera esecuzione operativa verso funzioni di supervisione, decisione e controllo di alto livello, fino a risultare sostituito anche nei compiti di gestione.

- Livello di strutturazione delle variabili e del contesto: quando si devono modellare feature qualitative o quantitative, situazioni strutturate o destrutturate, contesti complessi o imprevedibili piuttosto che definiti e ripetitivi, qualora le previsioni o le formulazioni richiedano un'interpretazione soggettiva, varia l'intervento umano richiesto.
- Infine, è possibile individuare due ulteriori fattori determinanti, tra loro speculari. Da un lato, la natura delle facoltà cognitive richieste nella fase, comprendenti il ragionamento logico, la creatività, la capacità di calcolo e le competenze organizzative. Dall'altro, le capacità operative dello strumento adottato, le quali incidono sul grado di intervento umano richiesto e sul livello di autonomia dello strumento nelle diverse fasi, attraverso la caratterizzazione della tipologia di task che esso è in grado di implementare. Nello schema di Figura 3.2, questi due fattori consentono di associare entrambe le prospettive, quella della fase e quella dello strumento, alla categoria di collegamento comune, rappresentata dalla tipologia di task.
- Livello di autonomia, supervisione umana richiesta e l'insieme dei fattori che li determinano, consentono di definire il ruolo operativo dello strumento. In una prima modalità, lo strumento interviene su compiti che il soggetto umano sarebbe in grado di svolgere anche autonomamente, limitandosi a facilitarne o ad accelerarne l'esecuzione. In una configurazione più avanzata, lo strumento agisce come amplificatore delle capacità umane, estendendo le possibilità di calcolo, creatività e operatività del progettista e consentendo di operare su scale ed efficienze non riproducibili manualmente, ad esempio attraverso l'esplorazione di un numero significativamente maggiore di alternative o la gestione di enormi volumi di dati. Infine, nelle versioni più avanzate, lo strumento può integrare funzioni di organizzazione, coordinamento e controllo di attività elementari, internalizzando i meccanismi di gestione e i processi decisionali all'interno del sistema.

Alla luce di queste considerazioni, le tre categorie SUP, AUG e AUT sono definite chiarendo, per ciascuna, il livello di autonomia, il ruolo operativo dello strumento e il ruolo del soggetto umano all'interno del sistema di interazione.

- Support (SUP): dal punto di vista dello strumento, la configurazione di supporto è caratterizzata da un ruolo di assistenza all'operatore umano, orientato ad aumentare l'efficienza operativa, fornire supporto informativo, ridurre il carico cognitivo e migliorare la rapidità di esecuzione delle attività. In questa modalità, l'Intelligenza Artificiale non sostituisce il soggetto umano né svolge compiti che l'uomo non sarebbe in grado di eseguire autonomamente, ma lo affianca, soprattutto nelle fasi analitiche e decisionali, che risultando più critiche in termini di impatto economico e strategico, devono essere adeguatamente guidate dal progettista. In questa configurazione, il soggetto umano mantiene la piena responsabilità e il controllo del processo decisionale, interagendo con lo strumento in modo iterativo o utilizzandolo come supporto circoscritto a specifiche porzioni del task complessivo.
- Augmentation (AUG): in questo caso, lo strumento consente l'esecuzione di attività che, per complessità, scala o intensità computazionale, non risulterebbero gestibili manualmente. Parallelamente, estende le capacità cognitive e creative dell'utente, aumentando il numero di alternative generabili in tempi ridotti. Nel complesso, è reso possibile lo svolgimento di attività

precedentemente irrealizzabili o eseguibili solo con livelli di produttività significativamente inferiori. Queste caratteristiche comportano un incremento del livello di automazione e della partecipazione operativa dello strumento, che elabora una porzione più ampia del task complessivo e assume un ruolo di augmentazione piuttosto che di semplice supporto, risultando compatibile con attività a criticità più alta. Il soggetto umano mantiene la piena responsabilità e il controllo del processo decisionale, intervenendo principalmente attraverso l'interpretazione dei risultati, l'impostazione di vincoli e la guida dei cicli iterativi successivi, con una frequenza di interazione con lo strumento inferiore rispetto al caso SUP.

- Automation (AUT): in questa categoria, lo strumento di Intelligenza Artificiale opera con un elevato livello di autonomia, eseguendo il compito assegnato riducendo o eliminando la necessità di un'interazione continua con l'operatore umano. Può agire sia su attività eseguibili dall'uomo sia su compiti che, per complessità di gestione simultanea o scala, risulterebbero difficilmente realizzabili manualmente. Tale configurazione è tipicamente applicata a processi ripetitivi, prevedibili e altamente strutturati, per i quali sono disponibili dati storici e modelli consolidati, ed è compatibile con attività a criticità medio-bassa, prevalentemente di natura operativa.

In contesti alternativi, lo strumento può anche pianificare e guidare il processo decisionale in ambienti dinamici, adattando le azioni in funzione dei segnali e dei feedback contestuali e aggiornando gli output per mantenerli coerenti con la situazione corrente. Nonostante questa capacità adattiva, tali sistemi risultano, allo stato attuale, maggiormente adatti ad attività a criticità moderatamente bassa, in ragione dei limiti di affidabilità e maturità tecnologica raggiunta.

Il soggetto umano fornisce indicazioni iniziali o requisiti di alto livello, mentre la responsabilità operativa viene in larga parte internalizzata nel sistema, che agisce in modo proattivo entro i vincoli definiti.

Prospettiva della fase

In questo caso si considerano due dimensioni principali: da un lato il livello di criticità della fase o dell'attività, dall'altro il grado di supervisione, inteso come livello di presenza e di intervento richiesto al soggetto umano nello svolgimento della fase o dell'attività stessa.

Il livello di criticità associato a ciascuna fase del processo progettuale può essere definito in funzione di un fattore determinante che coincide con la misura dell'impatto che le decisioni assunte in una determinata fase esercitano sullo sviluppo complessivo del prodotto e sui costi di correzione degli errori, in relazione alla loro capacità di propagarsi nelle fasi successive del processo. In questo senso, la criticità risulta generalmente elevata nelle fasi di strutturazione del problema, in cui si definiscono i criteri di generazione e di valutazione, e nelle fasi di valutazione e selezione vere e proprie, che stabiliscono le alternative da sviluppare nelle fasi successive o conducono a scelte definitive non reversibili.

Per quanto riguarda, il livello di supervisione umana richiesto, questo è spesso una conseguenza diretta della criticità della fase. In presenza di un'elevata criticità, anche il grado di supervisione tende a essere elevato. Tuttavia, possono verificarsi situazioni in cui, pur a fronte di una criticità moderata, risulta comunque necessario mantenere alto il livello di supervisione umana e questo dipende principalmente da due fattori:

- Il primo è rappresentato dal grado di strutturazione del problema decisionale, strettamente legato alla complessità e alla variabilità del contesto dinamico in cui l'attività si colloca. Quanto più una decisione si inserisce in un contesto ben definito e prevedibile, tanto minore è la necessità di flessibilità decisionale tipicamente associata all'intervento umano.
- Come estensione del precedente, un altro fattore importante già citato è rappresentato dalla natura delle facoltà cognitive coinvolte nelle attività. Le attività di tipo creativo o esperienziale, così come le valutazioni qualitative, che richiedono sensibilità, giudizio soggettivo o componenti non pienamente razionalizzabili, tendono a richiedere un maggiore livello di supervisione umana. Al contrario, attività ripetitive, formalizzabili, programmabili, e allo stesso modo valutazioni quantificabili, risultano più facilmente implementabili attraverso algoritmi o funzioni esplicite.

Tali considerazioni possono essere qualitativamente espresse attraverso una scala a tre livelli, che riassumono il grado di criticità e di supervisione umana che viene o richiede di essere coinvolta nelle fasi o attività progettuali:

- **ALTO:** in termini di criticità, caratterizza fasi ad elevato impatto strategico ed economico, nelle quali le decisioni condizionano in modo determinante l'intero percorso progettuale. Errori o formulazioni scorrette tendono a propagarsi e amplificarsi nel tempo, poiché il costo delle modifiche cresce con l'avanzare dello sviluppo.

A livello di supervisione umana richiesta invece, queste fasi sono spesso contraddistinte da elevata ambiguità e da problemi decisionali destrutturati, in cui la definizione stessa del problema influenza in modo sostanziale le scelte successive. Inoltre, vengono coinvolte capacità di valutazione qualitativa e di generazione creativa che, poiché richiedono giudizi basati su emozioni, sfera percettiva, intuizione ed esperienza professionale, sono tradizionalmente associabili al soggetto umano.

- **MEDIO:** il livello di criticità si riduce poiché, pur coinvolgendo processi di valutazione e selezione, le decisioni si collocano in uno stadio del processo in cui risultano ancora in larga parte correggibili, senza generare effetti critici sulle fasi successive.

In termini di supervisione umana richiesta, essendo che il contesto diventa più strutturato e i problemi decisionali maggiormente codificabili, diventa possibile delegare allo strumento una parte dell'operatività, pur mantenendo un ruolo centrale del soggetto umano nell'interpretazione dei risultati e nell'orientamento del processo.

- **BASSO:** In questo caso le attività non coinvolgono processi valutativi oppure, qualora lo facciano, producono effetti limitati all'interno dell'attività stessa, che in caso di errori può essere reiterata senza generare conseguenze dannose sulle fasi successive del processo. Inoltre, questo livello è tipico di attività basate su problemi decisionali strutturati, caratterizzati da bassa ambiguità e da operazioni ripetitive fondate su criteri quantificabili. In questi casi le attività risultano eseguibili in modo algoritmico e quindi maggiormente automatizzabili, la supervisione umana rimane necessaria ma può essere esercitata a un livello più alto e meno continuo.




Figura 3.2: Categorizzazione tra le fasi del processo di progettazione e gli strumenti di Intelligenza Artificiale e relativi fattori influenzanti.

3.3.2. Applicazione delle categorie di collegamento alle fasi del processo progettuale

In questa sezione vengono analizzate le categorie di collegamento associate alle diverse fasi del processo progettuale, comprendenti l'output atteso, la tipologia di task, il livello di criticità e il grado di supervisione umana richiesto, come riportato nelle Tabella 3.1–Tabella 3.6.

Con riferimento al livello di criticità, è opportuno osservare come, nel contesto della progettazione di nuovi prodotti e, ancor più, nei processi di innovazione, le fasi a bassa criticità e bassa partecipazione del soggetto umano risultino relativamente rare.

Tali contesti sono infatti prevalentemente destrutturati e caratterizzati da processi decisionali continui che, in quanto tali, includono attività di valutazione e selezione, critiche per la loro natura convergente.

In questa fase dell'analisi, in quanto preliminare e propedeutica alla mappatura finale, il livello di criticità viene assegnato a priori, sulla base della natura intrinseca della fase del processo progettuale, indipendentemente dallo specifico strumento di AI impiegato. Al limite in alcuni casi può essere considerato il grado di automatizzabilità della fase, qualora essa risulti estremamente codificabile, ma senza alcun riferimento a strumenti specifici.

Dal punto di vista della criticità, emergono come centrali le attività di problem structuring e di valutazione e selezione finale, in quanto maggiormente rilevanti per l'impatto strategico ed economico sul processo di sviluppo prodotto e sul mercato di destinazione. In questo lavoro, il problem structuring è interpretato come un'attività fondamentale per il successo complessivo del processo, in contrasto con approcci che gli attribuiscono limitatamente un ruolo di supporto e organizzazione.

Si osserva inoltre che le tabelle seguenti adottano l'impostazione del modello unificato definito nel paragrafo 3.2.1. Tale impostazione consente di rendere l'applicazione delle fasi valida sia ai diversi livelli del processo di progettazione (Conceptual design, High-level system architecture, Detailed design), sia a un livello più generale, a differenti domini progettuali, pur riconoscendo che ciascun dominio presenti scostamenti specifici rispetto allo schema generale.

Un'ultima precisazione rilevante concerne la distinzione tra planning e progettazione, intesi come due processi distinti ma strettamente connessi. Tale distinzione, ampiamente riconosciuta in letteratura, risulta coerente con il fatto che entrambi includono tutte le diverse tipologie di task CoA, orientate alla realizzazione di un ciclo decisionale completo.

Infine, un'ultima precisazione riguarda il fatto che nella progettazione, l'attività di Evaluation è formalmente collocata al termine del processo, ma viene tuttavia scomposta e distribuita all'interno delle diverse fasi, al fine di rendere espliciti i punti in cui hanno luogo decisioni rilevanti.

Planning	
Criticità	Media
Supervisione umana	Alta
CoA prevalente	ID, STR

Sottofasi e attività	CoA	Output attesi	Livello di criticità e supervisione umana richiesta
○ Nuove possibilità tecnologiche [129] ○ Esplorazione panorama normativo e brevettuale [129] ○ Esplorazione dei concorrenti e della supply chain ○ Identificazione dei segmenti di mercato ○ Raccolta preferenze e bisogni clienti [129] (interviste dirette, contenuti dal web e dai social media, focus group, scenari d'uso, ecc.)¹ ○ Raccolta di dati comportamentali e demografici, CRM, statistiche	ID	○ Rapporto di scouting tecnologico e di mercato ○ Documento di analisi normativa e degli standard ○ Rapporto di analisi competitiva e della catena del valore ○ Documento di analisi del panorama brevettuale	Criticità MEDIA Le informazioni disponibili e le elaborazioni effettuate risultano ancora insufficienti a supportare decisioni rilevanti, l'attività è infatti prevalentemente orientata alla ricerca, alla raccolta e all'elaborazione delle informazioni, al fine di colmare tale gap. Trattandosi di una fase altamente preliminare, le decisioni eventualmente assunte hanno un impatto limitato sulle fasi successive, in quanto le direzioni progettuali possono ancora essere modificate e non sono stati ancora intrapresi interventi concreti difficilmente reversibili o costosi da correggere.
○ Riconoscimento dei bisogni dettagliati [129] ○ Definizione dei vincoli normativi [129] ○ Analisi di Porter ○ Riconoscimento delle competenze necessarie e degli accordi per l'innovazione ○ Organizzazione delle informazioni raccolte sugli stakeholder per costruire le personas ○ Definizione dei segmenti di mercato ○ Definizione dei bisogni terziari e secondari e primari ○ Reportistica	STR	○ Repository di dati di mercato e degli utenti (CRM, dataset statistici, profili demografici) ○ Documento delle personas	
○ Generazione delle idee primitive [129] ○ Generazione di possibili strategie	DEV	○ Documento dei segmenti di mercato ○ Lista dei bisogni	
○ Verifica, valutazione e validazione di ogni elemento che contribuisce allo sviluppo del processo decisionale [129] (es. simulazioni strategiche, previsione della domanda e dei costi, NPV ecc.) ○ Prioritizzazione e selezione delle idee e delle strategie generate da portare avanti	CNTR	○ Resoconto di analisi SWOT e Porter (o stesso output ottenuto con strumenti diversi) ○ Rapporto di inquadramento strategico	Supervisione umana ALTA In questa fase il contesto decisionale è fortemente destrutturato e caratterizzato da un'elevata variabilità, per cui è molto importante il controllo e la gestione da parte del soggetto umano
○ Aumento della frequenza e dell'efficacia delle osservazioni ambientali non filtrate [129] ○ Alta comunicazione, collaborazione e trasferimento della conoscenza tra stakeholder interni all'azienda e tra soggetti interni ed esterni all'azienda (gatekeeper)	COM	○ Product Development Charter: giustifica l'esito della go or not go decision	

Tabella 3.1: Associazione delle categorie di collegamento alle attività e sottofasce del Planning: output attesi, tipologia di task da eseguire, criticità e livello di supervisione necessaria. Alcune delle attività presenti, con relativa associazione alla tipologia di task, sono tratte da Montagna.F (2011) [129].

¹ Le attività di raccolta dei bisogni, definizione delle personas e market research, tipiche di un approccio user-centred, si collocano generalmente tra le fasi di planning e di design concettuale. In questa tesi vengono ricondotte alla fase di planning, per evidenziare il duplice contributo market side e demand side nella raccolta ed elaborazione delle informazioni e dei vincoli tipico di tale fase.

Fase divergente Problem Definition&Structuring	
Criticità	Alta
Supervisione umana	Alta
CoA prevalente	STR

Sottofasi e attività	CoA	Output attesi	Livello di criticità e supervisione umana richiesta
- Definizione delle dimensioni del problema che raggruppano le informazioni raccolte [129]: vincoli market side, bisogni demand side, dimensione tecnica (funzionalità e producibilità), dimensione economica, strategica, ambientale - Traduzione delle dimensioni del problema in requisiti: bisogni in requisiti demand side; vincoli regolatori, competitivi e brevettuali in requisiti market side; requisiti funzionali (post applicazione preliminare di FBS, analisi delle interazioni del sistema con l'ambiente, individuazione di risorse scambiate e harmful effects) _ Conceptual Design - Traduzione dei requisiti in specifiche_ Detailed Design - Definizione di un modello di valutazione [129]: definire il modello e i criteri di valutazione, con eventuali pesi (criticità massima).	STR	- Design Brief - Documento dei requisiti_Conceptual Design - Documento delle specifiche_Detailed Design - Documento dei rischi (es. harmful effects) - Documento che riporta criteri di valutazione e relativi pesi per fase convergente - Diagramma di decomposizione funzionale - Diagramma di Rodenacker - Documento di definizione dell'architettura di sistema - BOM preliminare_Conceptual Design - BOM ingegneristica preliminare_Detailed Design (quella definitiva è inclusa nella documentazione in output alla progettazione, in input alla fase di industrializzazione) - Matrice funzione-componente. - Product positioning preliminare (in base ai bisogni raccolti, alla PCA e alla analisi sui competitors).	Criticità ALTA La definizione e la strutturazione iniziale del problema esercitano un'influenza determinante sia sulla generazione delle alternative sia sui successivi processi valutativi. La chiarificazione di requisiti e obiettivi in questa fase orienta lo spazio delle soluzioni esplorabili, mentre la definizione di criteri e pesi guida le successive attività di confronto e selezione. Questo passaggio da una condizione destrutturata a una progressivamente organizzata costituisce un momento chiave del processo progettuale, poiché condiziona in modo decisivo l'intero sviluppo successivo.
Identificazione di nuovi harmful effects emersi dalle alternative di strutturazione del problema (Guida la definizione di nuovi requisiti; attività iterativa lungo il ciclo di progettazione).	ID/ CNTR		
- Analisi funzionale (decomposizione con albero funzionale) - Costruzione del diagramma di Rodenacker, - Definizione del sistema tecnico - Associazione componenti a funzioni (grado di integrazione della architettura)	DEV/ STR		
- Verifica, valutazione e validazione degli elementi risultanti [129] - Prioritizzazione e Selezione delle strutturazioni da portare avanti	CNTR		
- Interazioni tra progettisti e stakeholders interni ed esterni, gestione dei feedback, attività di recupero e modellazione della conoscenza per facilitare interazioni [129] - Integrazione dei progettisti e dei sistemi in un ambiente coordinato e collaborativo [129]	COM		Supervisione umana ALTA Diretta conseguenza dell'alta criticità

Tabella 3.2: Associazione delle categorie di collegamento alle attività e sottofasi del Problem Definition&Structuring: output attesi, tipologia di task da eseguire, criticità e livello di supervisione necessaria. Alcune delle attività presenti, con relativa associazione alla tipologia di task, sono tratte da Montagna.F (2011) [129].

Fase divergente_Idea Generation	
Criticità	Media
Supervisione umana	Alta
CoA prevalente	DEV

Sottofasi e attività	CoA	Output attesi	Livello di criticità e supervisione umana richiesta
- Identificazione dei trade off e creazione del NOP, scomposizione finalizzata a facilitare l'aggregabilità dei problemi - Mappa concettuale delle proposte di idee che emergono dal brainstorming	STR	Network of Problems (NOP)	Criticità MEDIA In questa fase il problema risulta maggiormente strutturato grazie al lavoro svolto in precedenza e non sono ancora richieste decisioni vincolanti trattandosi di una fase esplorativa. L'obiettivo è generare criticamente nuove alternative, ossia produrre soluzioni aderenti ai requisiti definiti. Supervisione umana ALTA La componente creativa, soggettiva ed emotiva caratterizza tale fase, rende necessaria un'elevata supervisione, intesa come un forte coinvolgimento del soggetto umano nel processo
- Generazione di idee che soddisfano requisiti e risolvono contraddizioni _ Conceptual Design - Generazione di idee che soddisfano specifiche e risolvono contraddizioni_ Detailed Design (es. materiali, componenti specifici, tecnologie di processo possibili etc.)	DEV	- Matrice delle contraddizioni - Brainstorming report - Sintesi dei feedback degli stakeholder - Mappe concettuali	
- Interazioni tra progettisti e stakeholders interni ed esterni, gestione dei feedback, attività di recupero e modellazione della conoscenza per facilitare interazioni [129] - Integrazione dei progettisti e dei sistemi in un ambiente coordinato e collaborativo, attività di brainstorming volto alla generazione di idee creative e tecniche [129]	COM	Materiali visuali e testuali preliminari: immagini, schizzi, disegni tecnici preliminari, modelli CAD preliminari, simulazioni, schemi architettonici etc.	
Screening delle idee valide da avanzare alla fase di idea/component combination.	CNTR		

Tabella 3.3: Associazione delle categorie di collegamento alle attività e sottofasce dell'Idea Generation: output attesi, tipologia di task da eseguire, criticità e livello di supervisione necessaria. Alcune delle attività presenti, con relativa associazione alla tipologia di task, sono tratte da Montagna.F (2011) [129].

Fase divergente_Idea/Component Combination	
Criticità	Media
Supervisione umana	Media
CoA prevalente	DEV, STR

Sottofasi e attività	CoA	Output attesi	Livello di criticità e supervisione umana richiesta
Combinazione delle soluzioni generate in diverse overall solutions: ○ Combinazione di caratteristiche o feature delle soluzioni generate_Conceptual Design ○ Definizione di alternative di layout e delle relazioni tra componenti e moduli da combinare_High Level System Design ○ Combinazione degli elementi interni del singolo componente_Detailed Design	STR/DEV	○ Matrice delle combinazioni ○ Lista delle overall solutions	Criticità e supervisione umana MEDIA Il livello di strutturazione del problema aumenta, poiché, oltre ai requisiti definiti nelle fasi di definition e structuring, sono ora disponibili le alternative generate nella fase di idea generation, delle quali devono essere analizzate le possibili combinazioni. Sebbene tale attività richieda una forma di valutazione, in quanto non tutte le configurazioni risultano ammissibili, ciò comporta solo un lieve incremento della criticità. La valutazione decisiva delle alternative è infatti rimandata alla fase convergente, rendendo questa attività prevalentemente meccanica, combinatoria ed esplorativa, nella quale la compatibilità tra le diverse combinazioni di elementi deriva principalmente dal rispetto di vincoli e relazioni generalmente note, spesso direttamente garantite dalla presenza di interfacce standard, progettate per facilitare gli accoppiamenti.
○ Valutazione e selezione delle overall solutions da portare alla fase successiva di concept generation e optimization.	CNTR		

Tabella 3.4: Associazione delle categorie di collegamento alle attività e sottofasì dell'Idea/Component Combination: output attesi, tipologia di task da eseguire, criticità e livello di supervisione necessaria. Alcune delle attività presenti, con relativa associazione alla tipologia di task, sono tratte da Montagna.F (2011) [129].

Fase divergente_ Concept Generation	
Criticità	Medio-Bassa
Supervisione umana	Alta
CoA prevalente	DEV, CNTR

Fase divergente_ Concept Optimization	
Criticità	Medio-Bassa
Supervisione umana	Medio-Alta
CoA prevalente	DEV, CNTR

Sottofasi e attività	CoA	Output attesi	Livello di criticità e supervisione umana richiesta
Generazione di concept di prodotto resi visualizzabili o fisicamente tangibili a partire dalle overall solutions selezionate, definendo struttura interna ed esterna (shape). Per concept si intende: - Concretizzazione visiva delle combinazioni generate nella fase di idea combination_Conceptual Design; - Prototipi fisici o virtuali_Detailed Design	DEV	- Documenti relativi ai concept generati (caratteristiche tipiche, performance, confronto con i prodotti competitors, definizione approssimativa del pricing, product positioning attraverso mappe di valore ecc.) - Materiali visuali e testuali: immagini, disegni tecnici completi, modelli CAD, simulazioni, schemi architettonici etc.	Criticità MEDIO-BASSA Il problema decisionale risulta fortemente strutturato, con alternative, variabili, obiettivi, requisiti e vincoli chiaramente definiti. Le decisioni assunte non sono ancora vincolanti, poiché la fase è caratterizzata da modifiche iterative ed esplorative che consentono continui aggiustamenti. Supervisione umana ALTA È presente una componente creativa analoga a quella dell'idea generation, che limita la completa codificabilità algoritmica del processo (tipica invece della fase di ottimizzazione), in particolare nella definizione delle forme, la quale, pur nel rispetto dei requisiti, è spesso guidata dall'esperienza e dall'intuizione del designer.
Ottimizzazione dei concept generati considerando i singoli parametri e la soluzione complessiva² I parametri possono essere legati a: - Behaviour_Detailed Design, - Aspetti strutturali o funzionali_Conceptual/High Level System Architecture Design	DEV/ CNTR	- Report con risultati delle simulazioni e del ciclo di ottimizzazione - Specifiche di approvvigionamento e documentazione per la fase di industrializzazione - Demo/Mockup/Concept/prototipi virtuali o fisici	Criticità MEDIO-BASSA Il problema decisionale è fortemente strutturato, con alternative, vincoli, variabili e obiettivi di ottimizzazione chiaramente definiti e codificabili in un processo algoritmico iterativo basato su fasi generative e valutative e su funzioni di valutazione esplicite. La ripetibilità del processo, la presenza di un gate decisionale immediatamente dopo ogni attività generativa che consente di correggere gli errori all'interno della fase stessa e le valutazioni basate su calcoli predefiniti piuttosto che su stime qualitative, limitano la criticità di questa fase. Supervisione umana MEDIO-ALTA I risultati delle generazioni e delle valutazioni rese automatizzabili, caratterizzati da elevato contenuto tecnico, richiedono la supervisione di un esperto, che interpreta gli output, corregge e guida le iterazioni successive, favorendo la convergenza verso soluzioni complessivamente accettabili.

Tabella 3.5: Associazione delle categorie di collegamento alle attività e sottofasce del Concept Generation&Optimization: output attesi, tipologia di task da eseguire, criticità e livello di supervisione necessaria. Alcune delle attività presenti, con relativa associazione alla tipologia di task, sono tratte da Montagna.F (2011) [129].

² L'ottimizzazione può essere interpretata come un processo progettuale completo, in quanto caratterizzata sia fasi divergenti sia fasi convergenti, inclusa all'interno del processo di progettazione macro di livello superiore. All'interno di tale processo macro, essa viene collocata nella fase divergente per evidenziare che l'output dell'ottimizzazione non consiste generalmente in un'unica soluzione ottima, bensì in un insieme di soluzioni alternative accettabili, ciascuna migliorativa rispetto a quelle da cui è stata generata nell'iterazione precedente.

Fase convergente _ Concept Evaluation&Selection	
Criticità	Alta
Supervisione umana	Alta
CoA prevalente	CNTR

Sottofasi e attività	CoA	Output attesi	Livello di criticità e supervisione umana richiesta
○ Verifica, valutazione e validazione di ogni elemento risultante [129], compresa la prioritizzazione: screening e scoring secondo i criteri definiti nel problem definition&structuring, validazione tramite feedback pre e post lancio ecc. ○ Selezione degli elementi da portare alle iterazioni successive o dei concept definitivi ○ Calcolo NPV (previsione della domanda, calcolo dei costi, analisi degli scenari)	CNTR	○ Report di valutazione delle alternative ○ Selezione delle alternative intermedie o della scelta finale ○ Foglio di calcolo con NPV (previsione della domanda, calcolo dei costi, analisi degli scenari) ○ Business plan	Criticità e supervisione umana ALTA Fase completamente valutativa e selettiva, che guida le iterazioni successive del ciclo progettuale e, al termine, le decisioni definitive. Le scelte effettuate hanno un forte impatto economico e strategico sia nel breve che nel lungo periodo. Richiede l'integrazione di criteri multipli, il cui peso può variare dinamicamente in base ai cambiamenti che si verificano nel contesto. La valutazione deve rispettare i requisiti definiti, ma spesso si basa anche sull'esperienza, sulla emotività e sensibilità dei soggetti esperti.
○ Elevata comunicazione tra stakeholders interni all'azienda e tra stakeholders interni ed esterni ○ Brainstorming tra esperti per valutazione e selezione	COM		

Tabella 3.6: Associazione delle categorie di collegamento alle attività e sottofasi del Concept Evaluation&Selection: output attesi, tipologia di task da eseguire, criticità e livello di supervisione necessaria. Alcune delle attività presenti, con relativa associazione alla tipologia di task, sono tratte da Montagna.F (2011) [129].

3.3.3. Applicazione delle categorie di collegamento agli strumenti di Intelligenza Artificiale

Anche in questa seconda parte si procede all'associazione delle categorie di collegamento, questa volta riferite agli strumenti di Intelligenza Artificiale. Tali categorie coincidono con il ruolo operativo e il livello di autonomia attribuibile allo strumento. Analogamente a quanto avvenuto per le fasi del processo, viene ripresa la tipologia di task, qui intesa come la natura dell'attività che lo strumento è in grado di abilitare.

Nella Tabella 3.7 che segue, le tipologie di task riconducibili al Context of Action (CoA) sono associate ai diversi paradigmi mediante un indice numerico, volto a rappresentare come uno stesso strumento possa supportare attività di natura differente, pur mostrando un maggior grado di predisposizione per alcune rispetto ad altre.

In questa fase della mappatura, l'associazione dei paradigmi alle modalità SUP, AUG e AUT riflette esclusivamente le capacità operative che gli strumenti di Intelligenza Artificiale offrono allo stato attuale. Tale associazione non tiene ancora conto della fase del processo progettuale in cui lo strumento viene utilizzato, ma rappresenta un passaggio preliminare necessario.

Nella mappatura finale invece, quando lo strumento verrà messo in relazione con una specifica sottofase o attività del processo progettuale, le modalità SUP, AUG e AUT verranno riconsiderate sulla base delle interazioni concrete tra strumento e fase, tenendo conto della compatibilità dello strumento con il livello di criticità dell'attività e del grado di supervisione umana richiesto, rendendo l'associazione più accurata.

Tipologia di AI	Output producibili	CoA		Ruolo operativo & Livello di autonomia	
AI simbolica (rule-based, KB, ontologie, fuzzy logic)	Etichette discrete (true/false) o continue (percentuale probabilistica), relazioni simboliche, stringhe di brevi spiegazioni	1.STR	Formalizzazione del problema, ragionamento semantico, deduzione di conoscenza implicita	SUP	Applica regole definite dall'uomo; nessuna decisione autonoma; alta interpretabilità degli output; controllo deterministico basato su regole e conoscenza esplicita
		2.CNTR	Diagnosi problemi, verifica vincoli		

AI evolutiva e bio-ispirata (GA, GP, PSO, ES)	Parametri ottimizzati, strutture di soluzione complesse (combinazioni di parametri, programmi ecc.), Pareto front in problemi multi-obiettivo, valutazione soluzioni (funzione di fitness)	1.DEV	Esplorazione globale e combinatoria di spazi di soluzione e generazione di alternative ottimizzate rispetto a obiettivi multipli	AUG	Autonomia operativa dei cicli di generazione e valutazione delle alternative (guidata dalla fitness), post definizione manuale di obiettivi e vincoli; necessaria valutazione umana finale
		2.CNTR	Valutazione iterativa, confronto e selezione delle soluzioni per il ciclo generativo successivo		

ML tradizionale (SVM, RF, KNN, K-means)	Valori numerici, classi, probabilità	1.ID	Raccolta e analisi dei dati (estrazione feature, scoperta di pattern ecc.)	AUG/ SUP	Augmentazione delle capacità umane mediante l'elaborazione di grandi quantità di dati e l'individuazione di relazioni difficilmente osservabili o non trattabili manualmente per limiti di tempo e di carico computazionale. L'interpretazione dei risultati e la conduzione del processo decisionale rimangono interamente sotto il controllo di esperti, che utilizzano l'output come supporto informativo.
		2.CNTR	Predizione (es. regressione), verifica rispetto a target o soglie, confronto tra alternative in base a metriche quantificabili, classificazione per verifica conformità, clustering per rilevare anomalie		
		3.STR	Clustering per raggruppamenti, classificazione, riduzione dimensionale		
		4.COM	Supporto alla comunicazione tra esperti tramite produzione di grafici, predizioni di metriche ecc.		

DL (CNN, RNN, GNN, Transformer encoder-only es. BERT) ^{3,4}	Valori numerici, classi, probabilità, embedding (questi ultimi output intermedi impiegati come input per l'elaborazione di task successivi)	1.ID	Estrazione automatica di feature, comprensione semantica contestuale, classificazione a scopo identificativo	SUP/ AUG	Augmentazione delle capacità umane mediante l'elaborazione di grandi quantità di dati e l'individuazione di relazioni difficilmente osservabili o non trattabili manualmente per limiti di tempo e di carico computazionale. Consente l'individuazione di relazioni non lineari e pattern complessi, non rilevabili tramite strumenti di ML tradizionali. L'interpretazione dei risultati e la conduzione del processo decisionale rimangono interamente sotto il controllo di esperti, che utilizzano l'output come supporto informativo
		2.STR	Elaborazione degli elementi e relazioni individuate (numeriche, semantiche etc.) es. tramite classificazioni; traduzione delle feature estratte in embedding manipolabili		
		2.CNTR	Anomaly detection, forecasting di serie temporali, predizioni di metriche di valutazione e confronto, classificazione orientata alla valutazione		

DL gen (GAN, VAE, Diffusion Models, LLM ecc.) ^{3,4}	Contenuti originali generati; trasformazioni di contenuti esistenti (es. combinazioni, modifiche ecc.); Valutazioni qualitative contestuali delle alternative	1.DEV	Generazione di alternative e editing condizionato da prompt; brainstorming con assistente artificiale per esplorazione di idee	SUP/ AUG	Incremento della capacità creativa e del numero di alternative generate in tempi inferiori rispetto ai processi manuali. Richiede tuttavia un'elevata interazione con l'utente. Infatti, l'operatore guida i cicli di generazione, le modifiche, valida e perfeziona le alternative prodotte, mantenendo il controllo decisionale, soprattutto nelle fasi di valutazione e selezione. Il sistema opera secondo una logica reattiva, rispondendo ai prompt quando la modalità condizionale è ammessa.
		2.STR	Rielaborazione, organizzazione e schematizzazione concettuale di conoscenza o contenuti, pianificazione workflow o di liste di azioni, ricostruzione parti di dati mancanti, reasoning contestuale		
		2.COM	Recupero conoscenza e spiegazione concetti, traduzione in linguaggi tecnici differenti		

³ Nel Deep Learning si distingue tra modelli generativi e altri modelli usati a scopo predittivo, secondo una classificazione di natura funzionale, utile a descrivere i compiti che essi abilitano nei processi di progettazione e sviluppo prodotto. Tale distinzione è applicativa e non coincide con la tradizionale separazione probabilistica tra modelli generativi e discriminativi.

⁴ La collocazione dei modelli nelle due categorie funzionali del Deep Learning, generativa e predittiva, non deve essere intesa come rigida, ma riflette piuttosto gli impieghi tipici. Esistono infatti versioni o configurazioni degli stessi modelli che, in funzione degli obiettivi di addestramento o della loro integrazione in strutture più complesse, possono svolgere anche funzioni riconducibili all'altra categoria. In questo senso, non è l'architettura in sé a determinare in modo univoco la funzione del modello, ma un insieme di fattori.

DL gen (GAN, VAE, Diffusion Models, LLM ecc.) ^{3,4}	Contenuti originali generati; trasformazioni di contenuti esistenti (es. combinazioni, modifiche ecc.); Valutazioni qualitative contestuali delle alternative	3.CNTR	Validazione qualitativa/semi-quantitativa con metodi multicriterio, scoring e ranking, rilevazione errori e incongruenze tramite analisi contestuale	SUP/ AUG	Incremento della capacità creativa e del numero di alternative generate in tempi inferiori rispetto ai processi manuali. Richiede tuttavia un'elevata interazione con l'utente. Infatti, l'operatore guida i cicli di generazione, le modifiche, valida e perfeziona le alternative prodotte, mantenendo il controllo decisionale, soprattutto nelle fasi di valutazione e selezione. Il sistema opera secondo una logica reattiva, rispondendo ai prompt quando la modalità condizionale è ammessa.
		4.ID	Individuazione di pattern complessi nei dati e recupero informazioni da fonti esterne ed interne (quando integrati con tools)		

AI agentiva (LLM-based agents, multi-agent systems, embodied agents) ⁵	Piani, azioni, valutazioni e verifiche, risultati operativi (derivanti da task svolti dagli agenti o da tools esterni chiamati), controllati e aggiornati in tempo reale sulla base dei feedback dei segnali ricevuti, coordinamento di più task svolti contemporaneamente da agenti diversi	1.STR	Pianificazione (mappe, workflow, liste di azioni), decomposizione dei problemi e coordinamento dei task, aggiornamento dinamico dei piani in base ai risultati ottenuti	AUT/ AUG	Manifesta un comportamento proattivo associabile ad AUT quando internalizza controllo, pianificazione, decisione e adattamento dinamico ai risultati e ai segnali esterni, pur operando entro task, contesto applicativo e istruzioni di alto livello definiti dall'operatore. In altri casi mantiene una natura prevalentemente reattiva, rispondendo a comandi umani senza piena autonomia decisionale ma svolgendo e coordinando comunque task multipli con una complessità e una velocità non praticabili manualmente, rientrando così nella categoria AUG.
		2.DEV	Esecuzione di piani, task e uso autonomo di tool		
		3.COM	Collaborazione operativa con l'utente, coordinam. di compiti svolti da diversi tool e agenti, spiegazione delle azioni svolte		
		3.ID	Ricerca delle informaz., monitoraggio dello stato del sistema e dell'ambiente per identificare variazioni, segnali e feedback		
		3.CNTR	Verifica dei risultati prodotti e ricevuti, scoring delle alternative, autocorrezione e gestione dei fallimenti		

Tabella 3.7: Associazione delle categorie di collegamento ai paradigmi di AI: tipologie di output producibili, tipologia di task eseguibili, ruolo operativo e livello di autonomia.

⁵ Il ranking del tipo di task CoA varia a seconda della specifica implementazione dell'AI agentiva. Negli agenti software basati su LLM prevalgono STR e DEV, per l'utilizzo prevalente nell'organizzazione e nel coordinamento dei task da svolgere e della conoscenza (opzione considerata nella tabella per gli scopi della tesi). Considerando l'AI agentiva in termini di agenti robotici fisici, risultano predominanti le attività DEV e CNTR, che rappresentano la capacità dell'agente di eseguire azioni perseguendo obiettivi e adattare il comportamento in base ai risultati.

3.4. *Mappatura finale tra fasi progettuali e strumenti di IA*

In questo paragrafo si procede alla mappatura conclusiva, finalizzata ad associare a ciascuna sottofase o attività uno o più strumenti di Intelligenza Artificiale idonei a svolgere la tipologia di task richiesta. Tale associazione tiene conto del ruolo operativo e del livello di autonomia che lo strumento rende disponibile, in relazione alla compatibilità con il livello di criticità e di supervisione umana richiesta dalla fase. Da notare che le categorie associate ai due piani, quello degli strumenti e quello delle fasi, considerate in modo indipendente nelle sezioni preliminari, vengono in questa fase ridefinite alla luce delle specifiche relazioni di compatibilità prese in esame dalla mappatura.

I criteri di compatibilità di massima adottati assumono che:

- A criticità elevata corrisponda prevalentemente un utilizzo in modalità SUP, con un eventuale impiego in modalità AUG per offrire amplificazione delle capacità umane operative, creative, di calcolo, ma solo in presenza di una supervisione umana stringente (configurazione SUP/AUG);
- A criticità media risultino compatibili sia modalità SUP sia AUG, anche considerate singolarmente;
- A criticità bassa risultino teoricamente ammissibili tutte le modalità, inclusa AUT.

È importante osservare che, mentre la criticità rimane pressoché invariata in quanto caratteristica intrinseca della fase, il ruolo operativo attribuito allo strumento, il suo grado di autonomia e il livello di supervisione umana richiesta possono risultare modificati alla luce della specifica relazione tra fase e strumento.

Relativamente al livello di autonomia e al ruolo operativo, uno stesso strumento può essere impiegato in modalità differenti a seconda dell'attività svolta, assumendo gradi diversi di autonomia decisionale. Infatti, a fasi e attività differenti corrispondono livelli di criticità differenti, dai quali deriva un diverso fabbisogno di supervisione umana e, di conseguenza, una diversa autonomia operativa attribuibile allo strumento.

Quando i problemi risultano maggiormente strutturati, quantificabili e descrivibili mediante criteri espliciti, la necessità di intervento umano tende a ridursi, poiché tali attività sono più facilmente trattabili in modo affidabile attraverso procedure computazionali, coerentemente con la logica operativa dei sistemi algoritmici tradizionali. Ne deriva che in questi contesti, lo strumento può operare con un grado di autonomia più elevato. Al contrario, in situazioni caratterizzate da valutazioni qualitative e interpretative, nelle quali assumono rilievo componenti soggettive, l'affidabilità dello strumento diminuisce e si rende necessario un maggiore coinvolgimento del soggetto umano.

Quando il livello di autonomia tollerabile è ridotto e la presenza richiesta dell'operatore nel ciclo decisionale aumenta, l'impiego dello strumento tende a collocarsi nella modalità di supporto (SUP).

La modalità di augmentazione (AUG) diventa invece appropriata nei casi in cui il contesto risulti sufficientemente formalizzabile e traducibile in procedure computazionali che, integrate nel processo, consentono di potenziare le capacità umane. Il maggiore grado di strutturazione dell'attività ne consente un'esecuzione affidabile da parte dello strumento, mentre al soggetto umano resta prevalentemente il ruolo di interpretazione e valutazione degli output prodotti.

Per quanto riguarda la modalità AUT, essa risulta teoricamente compatibile con situazioni altamente strutturate e con fasi a bassa criticità, come avviene tradizionalmente nei contesti industriali in cui robot o sistemi automatizzati svolgono operazioni ripetitive e semi-programmate in un ambiente circoscritto.

Tuttavia, la recente evoluzione dell'Intelligenza Artificiale sta progressivamente modificando questo principio tradizionalmente affermato. Strumenti avanzati, quali agenti basati su modelli generativi o sistemi robotici fisici (embodied) dotati di apprendimento dinamico, iniziano infatti a operare con livelli significativi di autonomia anche in contesti decisionali destrutturati e incerti, adattandosi ai feedback ambientali e suggerendo la possibilità di un loro impiego autonomo anche in attività caratterizzate da un grado di criticità più elevato.

Nonostante ciò, è opportuno precisare che tali agenti, pur mostrando capacità di pianificazione e azione in contesti meno strutturati, necessitano comunque di obiettivi di alto livello e di un perimetro decisionale

sufficientemente definito. Risulta quindi limitata l'applicabilità di tali strumenti in contesti come il Planning, nei quali gli obiettivi macro non sono ancora definiti, se non in riferimento a micro-task operativi vincolati da obiettivi noti.

Da notare che, anche nei casi più avanzati, la presenza del soggetto umano non viene completamente eliminata dal ciclo. Tali agenti, infatti, richiedono spesso indicazioni operative di carattere generale per essere indirizzati nello svolgimento del task.

Da queste considerazioni emerge dunque la necessità di riconsiderare le categorie attribuite agli strumenti e alle fasi, nonché le relazioni di compatibilità di massima definite tra le due prospettive, quando queste vengono analizzate in relazione reciproca piuttosto che in modo indipendente, nell'ambito di specifiche applicazioni di associazione.

Infatti, il livello di supervisione umana richiesta può ridursi e, parallelamente, il grado di autonomia tollerato dello strumento può aumentare, anche in presenza di task caratterizzati da maggiore criticità, qualora gli strumenti in virtù di uno stadio evolutivo più avanzato, internalizzino progressivamente funzioni di controllo.

In linea con la legge di automazione di Altshuller, l'aumento delle capacità dello strumento accresce la sua affidabilità nello svolgimento autonomo del task, lasciando all'operatore umano un ruolo di supervisione complessivamente più limitato rispetto a quello che la fase, se non considerata in relazione allo strumento, richiederebbe. Questo perché lo strumento evoluto si carica di parte delle facoltà cognitive umane richieste, riducendo il carico cognitivo richiesto al soggetto umano. Alla luce di queste precisazioni, si introducono le tabelle che riportano la mappatura tra attività e strumenti, articolata secondo le fasi e le sottofasi del processo di sviluppo del prodotto entro cui si colloca la progettazione.

3.4.1. Planning

CoA	Attività/sottofase svolta da AI	Paradig.	Tecniche/Algoritmi/Modelli/Domini dell'AI/Framework/Architetture	SUP/ AUG/ AUT	Fonti
ID/ STR	Identificazione di cluster e segmenti preliminari (mercati, utenti, tecnologie, competitor)	ML trad.	Clustering: K-means, hierarchical	AUG	[130] [131] [132] [133]
	Ricerca di informazioni, dati, pattern, trend espliciti e latenti da fonti testuali eterogenee (brevetti, normative, report di settore, recensioni online, letteratura) per estrarre informazioni market side e demand side	DL/ ML	NLP, LLM: information extraction, Topic modeling, sentiment analysis Information Retrieval: recupera documenti, testi o informazioni rilevanti all'interno di grandi collezioni di dati; Natural Language Inference (NLI): controllore semantico; Question answering sui contenuti delle fonti	AUG	[130] [134] [135] [136] [131] [137] [138] [132] [139]
		ML trad.	ML non supervisionato: clustering delle feature di prodotto (estratte con NLP dalle recensioni) ML supervisionato (XGBoost, rete neurale supervisionata): modella la relazione tra feature di prodotto e soddisfazione del cliente predicendo il rating per ogni feature, classifica le recensioni in positive o negative Interpretable machine learning (SHAP): spiega modello black box	AUG	[140] [141]

ID/ STR	Ricerca di informazioni, dati, pattern, trend espliciti e latenti da fonti testuali eterogenee (brevetti, normative, report di settore, recensioni online, letteratura) per estrarre informazioni market side e demand side	DL	CNN: estrae feature di prodotto dei competitor dalle recensioni	AUG	[142]
		AI agentiv.	LLM agent based: l'LLM fornisce capacità cognitive e linguistiche, l'agente gestisce controllo, orchestrazione e contesto (RAG) per task come document retrieval e filtering	AUT	[135]
		ML trad.	ML non supervisionato, Clustering (k-means): scopre pattern discreti	AUG	[143] [130] [131]
		DL	Autoencoder (anche varianti per sequenze): estrae rappresentazioni latenti continue	AUG	
			Rete neurale gerarchica con self-attention: apprende relazione tra invenzioni e probabilità di successo e opera predizioni su nuove invenzioni, classificatore supervisionato per stimare il valore tecnologico futuro delle invenzioni	AUG/ SUP	[144] [131]
	Change detection (identificazione variazioni significative in dati visivi, serie temporali ecc.)	DL	Autoencoder, LSTM, Transformer (su sequenze, usati anche per classificazione quando disponibili etichette di cambio o di regime)	AUG	
		ML trad.	classificazione supervisionata (RF/Boosting/SVM/MLP)		
	Regressione e Forecasting per identificazione di trend ed evoluzioni future (es. vendite nel tempo, prezzi nel tempo)	ML trad.	Regressione supervisionata, forecasting feature-based: Random Forest, Gradient Boosting (XGBoost/GBDT), SVR, MLP (shallow NN)	AUG	[132]
		DL	DL predittivo, forecasting sequence-based: LSTM/GRU, Temporal CNN, Transformer temporali		
	Trascrizione di interviste reali, focus group, brainstorming	DL	Speech processing (dominio), Trasformer, Conformer (convolution + trasformer). Es. Whisper (OpenAI), wav2vec 2.0 (Meta)	AUT	
DEV/ ID	Generazione di interviste (per far emergere bisogni, vincoli, dimensioni del problema)	DL gen.	LLM: conduzione dell'intervista (genera e adatta le domande, mantiene il contesto), inferisce informazioni implicite, gestisce ambiguità e identifica problema e stakeholder.	AUG/ SUP	[145] [146]

STR/ DEV	Organizzazione e strutturazione delle informazioni raccolte per supportare le decisioni strategiche, includendo: l'identificazione dei gap di competenze, lo sviluppo di strategie per colmarli (innovazione, acquisizione o formazione), la strutturazione di temi e vincoli emersi dall'analisi brevetti e testi regolatori e la formalizzazione delle relazioni tra stakeholder, bisogni e variabili critiche di mercato e di offerta.	DL gen.	NLP: Topic modeling, mapping tra concetti (es. feature di prodotto e vincoli regolatori) e similarità semantiche; LLM + RAG per organizzare le informazioni integrando conoscenza contestuale, supportando analisi strategiche (competitor, stakeholder e bisogni, competency gap, SWOT, 5 forze di Porter)	SUP	[138] [147] [148]
		AI agentiv.	LLM agent based: l'LLM fornisce capacità cognitive e linguistiche, l'agente gestisce controllo, orchestrazione e contesto (RAG) per task sviluppo delle idee strategiche e ricerca delle informazioni contestuali.	AUG	[135]

STR	Organizzazione e strutturazione delle informazioni raccolte per supportare le decisioni strategiche, includendo: l'identificazione dei gap di competenze, lo sviluppo di strategie per colmarli (innovazione, acquisizione o formazione), la strutturazione di temi e vincoli emersi dall'analisi brevetti e testi regolatori e la formalizzazione delle relazioni tra stakeholder, bisogni e variabili critiche di mercato e di offerta.	AI simb.	Knowledge graph e ontologie leggere: rappresentano competenze, attori, stakeholder e bisogni; sistemi rule-based e community detection per organizzare ed estrarre relazioni semantiche formalizzate.	AUG/ SUP	[139] [136] [131]
		ML	ML supervisionato: SVM per classificare brevetti per qualità, area tecnologica o valore	AUG/ SUP	[131]
	Definizione dei bisogni individuati; redazione profili personas; definizione dei segmenti di mercato, redazione bozza di questionario	DL gen.	LLM (generazione di contenuti), NLP (Topic modeling, sintesi interpretativa, riformulazione concettuale, grouping concettuale, gerarchizzazione)	AUG/ SUP	[145] [149] [132]
	Classificazione e prioritizzazione dei bisogni (es. modello di Kano, bisogni terziari e secondari ecc.)	ML trad.	ML supervisionato (es. Random Forest)	SUP	[143]
		DL	GRU, Attention mechanism	SUP	[150] [151]
	Definizione delle dimensioni principali	Statistica multivar.	PCA/Factor analysis (riduzione dimensionale)	AUG	

DEV	Generazione delle idee primitive, generazione di possibili strategie	DL gen.	LLM: generazione di alternative coerenti con i requisiti specificati	AUG/ SUP	[148]
		AI agentiv.	LLM agent based: l'LLM fornisce capacità cognitive e linguistiche, l'agente gestisce controllo, orchestrazione e contesto (RAG) per task come sviluppo delle idee strategiche con recupero delle informazioni contestuali.	AUG	[135]

CNTR	Verifica, valutazione, validazione e prioritizzazione degli elementi risultanti (la selezione resta completamente a carico del soggetto)	ML trad.	ML supervisionato tradizionale e shallow DL (Random Forest, Gradient Boosting, XGBoost, KNN, Regressione Logistica, SVR e MLP) per scoring, ranking e screening preliminare delle idee di prodotto e delle alternative strategiche, stimando indicatori sintetici di costo, rischio, fattibilità e probabilità di successo a supporto delle decisioni go/no-go	SUP	[152] [132] [153] [154]
		AI neuro-simb.	ANFIS stima il successo dei nuovi prodotti da indicatori economico-strategici; il punteggio alimenta un Fuzzy Inference System per valutare le strategie di Ansoff e supportare la decisione strategica.	SUP	[155]
		DL	LSTM e Transformer: stimano indicatori quantitativi analizzando dati sequenziali e temporali (domanda attesa, performance previste nel tempo ecc.) da fornire in input ai metodi di scoring	AUG	
		DL gen.	LLM: confronto argomentato tra alternative, valutazione qualitativa, applicazione di metodi multicriterio	SUP	[148]
		AI agentiv.	LLM agent based: l'LLM fornisce capacità cognitive e linguistiche, l'agente gestisce controllo, orchestrazione e contesto (RAG) per task come screening delle idee generate.	AUG	[135]

STR/ CNTR	Modelli predittivi per stimare domanda, parametri di scenario e costi da casi analoghi, a supporto del calcolo preventivo dell'NPV.	DL	LSTM, Transformer temporali	AUG	
		ML trad.	RF, Boosting, SVR	AUG	

DEV/ CNTR	Simulazione scenari	DL gen.	Simulazione concettuale delle alternative strategiche tramite scenari “what-if” e stress test narrativi per individuare rischi e criticità emergenti.	AUG/ SUP	[135] [132]
		simulazione e stocastica	Metodo di Monte Carlo	AUG	
		ABM con componenti di ML	ABM per la pianificazione strategica: agenti (imprese, consumatori, fattori esterni) generano dinamiche di mercato competitive dalle cui interazioni si prevedono quote di mercato, profitti ed equilibri. Le imprese apprendono con Q-learning, i consumatori seguono modelli di scelta discreta.	AUG	[156]
CNTR	Analisi e valutazione scenario	DL gen.	LLM: interpretazione qualitativa dei risultati ottenuti dagli scenari delle simulazioni stocastiche	SUP	[132] [148]
		ML trad.	ML supervisionato (regressione e forecasting) analizzano i risultati delle simulazioni	AUG	[156]
COM	Traduzione tra linguaggi tecnici, documentazione e reporting, sintesi, question answering su conoscenza interna/esterna e brainstorming	DL gen.	LLM /LLM + RAG: supporta comunicazione interdisciplinare, recupero della conoscenza, genera rappresentazioni condivise e abilita brainstorming con soggetto artificiale	AUG/ SUP	
	Coordinamento e combinazione dei task svolti su diversi fronti e sintesi in un output coerente	AI agentiv.	LLM agent-based: l’LLM fornisce capacità cognitive e linguistiche, l’agente gestisce controllo, orchestrazione e contesto, riducendo il bisogno di coordinamento e comunicazione esterni.	AUT	[135]
	Information visualization e Visual analytics	Analisi statistica, strum. di visualizz. avanzata, ML trad.	ML supervisionato e non supervisionato (es. regressione, clustering, anomaly detection semplice), implementati da strumenti di visual analytics (es. Tableau)	AUG	[141]

Tabella 3.8: Mappatura tra attività/sottofasi e strumenti di Intelligenza artificiale nel planning strategico, interpretato in relazione ai processi di innovazione e alle fasi di supporto decisionale che precedono la progettazione nel processo sviluppo prodotto.

Nel Planning, tecniche di intelligenza artificiale come machine learning non supervisionato, quali K-means e clustering gerarchico, sono prevalentemente impiegate per individuare pattern e strutture latenti nei dati, identificare cluster e segmenti strategici preliminari (mercati, utenti, tecnologie e competitor), con lo scopo di supportare una prima segmentazione esplorativa utile a orientare le successive analisi di mercato e del contesto ambientale.

In merito all'analisi dei bisogni di mercato e della soddisfazione del cliente invece, diversi studi impiegano NLP e machine learning per prima estrarre, poi strutturare, informazioni testuali provenienti dalle recensioni online. In [143], LDA è utilizzata per estrarre topic tematici emergenti dalle recensioni di prodotto, mentre Random Forest associa a ciascun testo una classe di sentiment e un punteggio ordinale di soddisfazione, supportando l'identificazione di bisogni latenti e trend di mercato. In modo coerente, un altro approccio [140] combina NLP, word embedding e clustering per estrarre le feature di prodotto, stima il sentiment per ciascuna feature e utilizza XGBoost per predire il rating a stelle, rendendo il modello black box maggiormente spiegabile tramite SHAP.

In [141] reti neurali supervisionate classificano le recensioni in giudizi positivi o negativi e, integrate con indicatori quantitativi, supportano raccomandazioni di prodotti e brand. In questo ambito rientrano anche approcci che utilizzano reti neurali convoluzionali (CNN) per estrarre automaticamente gli attributi di prodotto più rilevanti dai testi già analizzati delle recensioni dei clienti, in modo tale da supportare l'attività successiva di valutazione del grado di differenziazione dei prodotti competitor, finalizzata in ultima istanza a sviluppare riflessioni preliminari sull'eventuale posizionamento strategico di un nuovo prodotto.

Nel contesto dello scouting tecnologico basato sull'analisi brevettuale, l'AI è utilizzata per individuare segnali precoci di valore e tecnologie emergenti. Lo studio [144] impiega modelli BERT per codificare semanticamente le claims brevettuali, che vengono aggregate tramite una rete neurale gerarchica con self-attention al fine di predire il valore tecnologico futuro delle invenzioni, misurato predicendo le citazioni attese.

In [131], un insieme eterogeneo di tecniche quali: ANN, modelli deep (DBN, RBM), SVM, clustering e NLP viene applicato alla classificazione dei brevetti, al technology forecasting e all'estrazione di dati finalizzata alla costruzione di mappe tecnologiche. Ontologie, knowledge graph e sistemi rule-based consentono inoltre di strutturare e collegare la conoscenza estratta, rendendola interpretabile e riutilizzabile nel supporto decisionale.

Per quanto riguarda l'identificazione e la sintesi dei vincoli regolatori, [137] propone il framework RIRAG, che struttura il task di recupero esaustivo delle obbligazioni normative e di generazione di risposte coerenti. Il framework integra LLM, Natural Language Inference e un classificatore supervisionato basato su LegalBERT per individuare le frasi che esprimono obblighi, ed è inoltre supportato dal dataset ObliQA, costruito su testi normativi dell'Abu Dhabi Global Market, utile per risalire ai vincoli regolatori.

Sul fronte dell'individuazione di trend emergenti, della competitive intelligence e del market insight, [157] propone un approccio che monitora i cambiamenti nel panorama HR identificando la crescita di trend emergenti tramite tecniche di NLP che tracciano la frequenza dei termini nel tempo su contenuti web raccolti tramite web scraping.

In [138] invece, gli LLM analizzano grandi volumi di dati eterogenei sui competitor (siti web, report, brevetti, news, job posting) per estrarre pattern e segnali deboli relativi a cambiamenti strategici, competenze e direzioni tecnologiche. In modo complementare, [132] mostra come NLP, ML supervisionato e non supervisionato e web scraping siano utilizzati per analizzare mercati e comportamento dei consumatori, mentre LLM e modelli sequenziali (LSTM, Transformer) supportano il forecasting, la change detection e la simulazione di scenari competitivi. Relativamente alla mappatura delle competenze e alla competency gap analysis, [139] utilizza NLP e LLM per estrarre automaticamente competenze da fonti testuali eterogenee (documenti interni, progetti, job description) e organizzarle in tassonomie e knowledge graph, consentendo confronti multilivello rispetto agli obiettivi strategici.

In modo affine, [147] propone un approccio basato su LLM in cui l'intera catena analitica formata da: estrazione delle competenze, confronto con i requisiti di ruolo, identificazione dei gap e raccomandazione di percorsi formativi è svolta tramite prompt strutturati, consentendo maggiore flessibilità e controllo del processo rispetto a pipeline ML tradizionali. Nelle attività di raccolta qualitativa delle informazioni strategiche, modelli di speech processing basati su architetture Transformer e Conformer sono impiegati per la trascrizione automatica di interviste e focus group. In parallelo, gli LLM vengono utilizzati per la conduzione di interviste esplorative, adattando dinamicamente le domande, mantenendo il contesto conversazionale e inferendo informazioni implicite, risultando particolarmente adatti a contesti caratterizzati da ambiguità e incompletezza informativa.

Nelle fasi di organizzazione, sintesi e strutturazione delle informazioni strategiche, gli LLM, spesso integrati con sistemi di Retrieval-Augmented Generation (RAG), supportano attività di sintesi interpretativa, grouping

concettuale, analisi dei gap di competenze e costruzione di framework strategici quali SWOT e cinque forze di Porter. Analogamente al caso precedente, anche in questo contesto, approcci di AI simbolica basati su knowledge graph e ontologie leggere consentono di rappresentare formalmente relazioni tra attori, competenze e bisogni, rendendo la conoscenza raccolta già strutturata e pronta per essere utilizzata durante il processo di progettazione.

Nelle fasi di ideazione e di primo screening delle idee, [135] impiega LLM come agenti cognitivi a supporto di decisioni qualitative e semi-strutturate, valutando le idee secondo rubriche derivate da interviste con esperti e integrando conoscenza aziendale tramite RAG in un sistema agentivo. In parallelo, [152] adotta un approccio basato su NLP e ML supervisionato, in cui le descrizioni testuali delle idee sono trasformate in feature numeriche e valutate tramite modelli come LASSO e Random Forest, affiancati da tecniche di explainable AI per garantire uno screening interpretabile.

Infine, con riferimento al supporto al ragionamento strategico, al forecasting e alla simulazione, [156] propone un framework di Agent-Based Modeling in cui imprese e consumatori sono modellati come agenti autonomi. In questo contesto le imprese apprendono strategie tramite Q-learning, mentre i consumatori seguono modelli di scelta discreta.

In [148], gli LLM sono utilizzati per la generazione e valutazione di strategie e business plan, mostrando una significativa correlazione con i giudizi di investitori esperti. In modo complementare, [153] utilizza modelli di ML supervisionato per lo screening preliminare delle idee di startup, mentre [155] introduce un approccio neuro-simbolico (ANFIS) che combina apprendimento automatico e regole fuzzy per stimare il successo dei nuovi prodotti e supportare la selezione delle strategie della matrice di Ansoff.

In Appendice D viene proposta una tabella di sintesi (Tabella D.1) che adotta una prospettiva alternativa, organizzando l'analisi per paradigmi di intelligenza artificiale e indicando, per ciascuno, le attività di planning strategico supportate dalle relative tecniche. L'obiettivo è condensare la mappatura e renderla esplicita dal punto di vista dell'AI, anziché seguire una struttura guidata dalle attività come quella proposta in Tabella 3.8.

3.4.2. Processo di progettazione

3.4.2.1. Fase divergente: Problem Definition&Structuring

La fase di definizione e strutturazione del problema vede l'impiego dell'intelligenza artificiale a supporto di un insieme eterogeneo di attività: la raccolta mirata delle informazioni, l'organizzazione delle nuove evidenze e delle informazioni rilevanti già emerse durante il planning strategico, la generazione di alternative di strutturazione del problema e la loro verifica preliminare, assumendo prevalentemente un ruolo di augmentazione e supporto dell'esperto umano senza sostituirlo mai nelle decisioni ultime, che in questa fase risultano particolarmente critiche. La mappatura delle attività e delle tecniche coinvolte è riportata nella Tabella 3.9 che segue.

CoA	Attività/sottofase svolta da AI	Paradig.	Tecniche/Algoritmi/Modelli/Domini dell'AI/Framework/Architetture	SUP/ AUG/ AUT	Fonti
STR	Strutturazione delle dimensioni del problema progettuale, organizzando e definendo al loro interno le informazioni raccolte durante il planning (vincoli market side, bisogni demand side, funzionalità e producibilità, dimensione economica, strategica, ambientale)	AI simb.	Knowledge graph e ontologie leggere: rappresentazione esplicita della conoscenza di dominio attraverso relazioni, categorie e vincoli. Semantic Web (RDF, SPARQL) consentono di rappresentare i dati estratti e di abilitarne l'interrogazione intelligente.	AUG/ SUP	[134] [158]
		DL gen.	LLM: riformulazione concettuale delle informazioni estratte (NLP: information extraction e topic modeling) dalla documentaz. preliminare di progetto, a supporto della definizione dei requisiti progettuali.	AUG	[159] [158]

STR	Traduzione delle informazioni relative alle dimensioni del problema in requisiti, product positioning preliminare	DL gen	LLM: supporto conversazionale alla traduzione delle informazioni in requisiti	SUP	[160] [145] [161] [162] [163] [164]
		MLtrad + DL	NLP filtra le frasi rilevanti ed estrae i Customer Needs (CN); Bi-LSTM+CRF cattura il contesto semantico e classifica frasi e keyword; modelli supervisionati (RF, Naïve Bayes, GB) mappano i CN estratti sui Design Parameters (DP).	SUP	[165] [166]
		DL	CNN: estraggono gli attributi di prodotto dalle recensioni; tecniche di XAI: stimano l'importanza complessiva di ciascun attributo (poi tradotti dal progettista in requisiti di differenziazione competitiva)	SUP	[142]
		ML trad.	ML semi-supervisionato: raggruppa le caratteristiche di prodotto nelle recensioni per collegare le opinioni dei clienti alle specifiche feature	SUP	[167]
			NLP (Dynamic Topic Modeling, Sentiment Analysis), ML supervisionato, ML non supervisionato (K-means): identificazione concorrenti, posizionamento competitivo dei prodotti (utile alla definizione preliminare della strategia di product positioning)	AUG	[130]
	Formalizzazione e standardizzazione dei requisiti e delle relazioni tra concetti emersi; organizzazione semantica dei requisiti in gruppi funzionali utilizzabili nella progettazione	ML/ DL	BERT e NLP: trasformazione dei requisiti e relazioni tra concetti espressi in linguaggio naturale in formati machine-readable (es. XML) che abilitano task successivi automatizzati (es. requirements validation, costruzione Functional block diagram FBD, PlantUML per diagrammi di caso d'uso ecc.)	SUP	[168] [169]
		AI simb.	Knowledge graph, ontologie leggere: modellazione esplicita di concetti, relazioni e vincoli semantici per garantirne tracciabilità e verificabilità	AUG/ SUP	[160] [170]
		DL + AI simb.	AI simbolica: ontologia di dominio; DL: BERT, Bi-LSTM e attention per Codifica della conoscenza simbolica in rappresentazioni neurali; UniLM genera requisiti in formato sintattico standard.	AUG (AUT)	[171] [146]

ID/ STR	Formalizzazione e standardizzazione dei requisiti e delle relazioni tra concetti emersi; organizzazione semantica dei requisiti in gruppi funzionali utilizzabili nella progettazione	AI agentiv.	Sistema multi-agente basato su LLM: agenti specializzati e coordinati svolgono compiti distinti, tra cui l'estrazione e strutturazione dei requisiti (Extractor Agent).	AUT	[172]
			Sistema multi-agente in cui l'agente di pianificazione traduce i requisiti in obiettivi di progettazione concreti per gli agenti specializzati (meccanica, elettronica, software), coordina gli agenti e gestisce i feedback umani attraverso ristrutturazione iterativa del problema di progettazione	AUT/ AUG	[173]
STR		DL/ MLtrad.	NLP, Sentence-BERT: rappresentare i requisiti estratti come vettori per catturare similarità semantica; clustering gerarchico: raggruppa i vettori relativi ai requisiti simili in cluster di gruppi funzionali omogenei; PCA per la riduzione dimensionale.	AUG	[174]

ID/ CNTR	identificazione di nuovi harmful effects o violazioni di requisiti già formalizzati, che emergono dalle alternative di strutturazione del problema generate	DL gen	LLM: analisi "what-if" concettuale, brainstorming guidato da operatore	SUP	[146] [175]
		ML trad.	ML supervisionato (RF): stima valore impatto ambientali del prodotto a partire da caratteristiche e dati EPD estratti e normalizzati tramite NLP in formato utilizzabile da ML	AUG	[176]
		AI simb.	Sistema esperto rule-based: verifica la conformità delle alternative strutturali a requisiti e vincoli formalizzati, applicando regole IF-THEN per dedurre effetti impliciti e segnalare violazioni che opera su base di conoscenza con interazioni sistema-ambiente, requisiti e vincoli formalizzati, classi di harmful effects note, regole esplicite formalizzate	AUG	

DEV/ STR ⁶	Applicazione del modello FBS; analisi funzionale (decomposizione del requisito funzionale in sotto-funzionalità figlie aggredibili singolarmente), diagramma di Rodenacker; definizione del sistema tecnico	DL gen.	LLM: agisce come amplificatore di idee e fornisce suggerimenti di configurazioni, propone strutturazione e suddivisione delle funzioni, con processo che resta interamente condotto dal progettista	AUG/ SUP	[177] [178] [164]
		AI simb.	Programmazione logica (Partial Order Planning): le funzioni del prodotto sono modellate come azioni di un algoritmo di pianificazione, consentendo di derivare decomposizione sequenzializzazione delle funzioni.	SUP	[179]

⁶ Sviluppo di alternative di strutturazione

DEV/ STR ⁶	Associazione componenti a funzioni; definizione preliminare del livello di integrazione/ modularità del sistema	ML trad	ML supervisionato: suggerimenti e ranking di componenti ammissibili per l'implementazione di funzioni, basato su associazioni osservate in prodotti e progetti precedenti.	SUP	
		DL	BERT, NLP mappano FR (functional requirements) e DP (design parameters) in uno spazio vettoriale per misurare accoppiamento e indipendenza funzionale, supportando decisioni di modularità; LLM propone alternative architetturali a partire dai requisiti ricevuti in input tramite prompting iterativo	SUP	[180] [181]
CNTR	Verifica, valutazione e validazione degli elementi risultanti (la selezione resta completamente a carico del progettista)	DL gen	LLM: supporto alla valutazione qualitativa iterativa delle alternative di strutturazione del problema e alla validazione dei requisiti, esplicitando trade off e suggerendo modifiche.	SUP	[146]
COM	Comunicazione interdisciplinare, reporting, sintesi, Q&A su conoscenza interna ed esterna, brainstorming	DL gen	LLM / LLM+RAG: traduzione tra linguaggi tecnici differenti (es. requisiti espressi con sintassi standardizzata), brainstorming e recupero delle informazioni per amplificare la conoscenza	SUP/ AUG	[171] [162] [182]
	Information visualization e visual analytics	Analisi statistica, visualizz. avanzata, ML trad	ML supervisionato e non supervisionato (es. regressione, clustering, anomaly detection semplice), implementati da strumenti di visual analytics (es. Tableau)	AUG	[163]

Tabella 3.9: Mappatura tra attività/sottofasi e strumenti di Intelligenza artificiale nel Problem Definition&Structuring.

Una prima area tematica riguarda l'organizzazione esplicita delle dimensioni del problema incluse componenti market side, demand side, aspetti legati al funzionamento tecnico, dimensioni economiche, strategiche e ambientali attraverso approcci di AI simbolica. Ontologie leggere e knowledge graph permettono di rappresentare in modo strutturato la conoscenza di dominio e le relazioni tra concetti, rendendo il problema esplicito e interrogabile. Tali strutture sono spesso integrate con tecnologie di Semantic Web, come RDF e SPARQL, per supportare l'estrazione e la consultazione di informazioni provenienti da testi normativi e legali, come mostrato negli approcci orientati alla formalizzazione dei vincoli regolatori [134] e alla rappresentazione strutturata dei requisiti tramite grafi della conoscenza [160].

Parallelamente, un ampio filone di studi si concentra sull'estrazione e chiarificazione delle informazioni dalla documentazione preliminare di progettazione mediante NLP e LLM. Tecniche BERT-based vengono utilizzate per analizzare testi non strutturati quali report tecnici e documenti di ricerca tipici delle fasi iniziali del processo di design [159]. In questi casi, l'AI supporta la riformulazione e la chiarificazione dei concetti, facilitando la traduzione iterativa delle informazioni in requisiti di diversa natura (demand side, supply side, funzionali), in un processo fortemente guidato dall'esperto umano.

La traduzione dei bisogni degli utenti in requisiti progettuali è ulteriormente supportata da pipeline di machine learning tradizionale e deep learning. In particolare, l'integrazione di filtri NLP, modelli Bi-LSTM e CRF consente l'estrazione e la classificazione dei customer needs da recensioni online e commenti di feedback [165], mentre modelli supervisionati come Random Forest, Naïve Bayes e Gradient Boosting permettono di associare tali bisogni a classi di design parameters, con un livello di automazione limitato alla classificazione di supporto. Questi approcci non generano decisioni progettuali, ma forniscono strutture informative che facilitano la successiva interpretazione da parte del progettista.

Un'area strettamente connessa riguarda l'analisi delle recensioni e delle opinioni dei consumatori per supportare la strutturazione competitiva del problema. CNN vengono impiegate per identificare attributi chiave di prodotto, mentre tecniche di Explainable AI (LIME, SHAP, Grad-CAM, LRP) consentono di stimarne l'importanza competitiva e interpretare il comportamento dei modelli [142]. Approcci semi-supervisionati e metodi di topic modeling dinamico permettono inoltre di collegare opinioni, caratteristiche di prodotto e posizionamento competitivo rispetto ai concorrenti, come mostrato negli studi orientati alla mappatura delle relazioni competitive ([167], [130]) che rendono disponibili informazioni utili allo svolgimento di analisi strategiche preliminari di product positioning.

Una volta individuati, i requisiti vengono sottoposti a processi di formalizzazione e standardizzazione. Modelli NLP e BERT-based trasformano testi espressi in linguaggio naturale in rappresentazioni machine-readable (ad esempio XML), abilitando attività successive come la validazione dei requisiti e la generazione automatica di diagrammi UML [169]. Tali rappresentazioni possono essere rafforzate mediante l'uso di knowledge graph e ontologie, oppure attraverso approcci ibridi neuro-simbolici che combinano modelli deep (BERT, Bi-LSTM con meccanismo di attention) e vincoli simbolici per generare requisiti conformi a sintassi e standard condivisi [171].

In contesti più avanzati, emergono approcci caratterizzati da un maggior grado di autonomia, che svolgono attività di strutturazione dei requisiti mediante sistemi multi-agent basati su LLM. In questi sistemi, agenti specializzati cooperano per estrarre, strutturare e riorganizzare i requisiti in vista dell'analisi delle contraddizioni progettuali e della generazione di alternative [172], [173].

Altre tecniche di embedding semantico, clustering gerarchico e riduzione dimensionale (PCA) supportano l'organizzazione dei requisiti in gruppi funzionali omogenei, riducendo ridondanze e assistendo l'analisi della modularità del sistema, contribuendo in ultima istanza alla definizione preliminare dell'architettura del sistema [180].

Nello sviluppo delle alternative di strutturazione del sistema, gli LLM operano come amplificatori cognitivi, suggerendo decomposizioni funzionali e configurazioni architettureali coerenti con i requisiti iniziali. Questi approcci includono sia modelli generativi inseriti in framework concettuali come FBS [178], sia tecniche di AI simbolica, come il Partial Order Planning, che organizzano e sequenzializzano le funzionalità del sistema come azioni di un problema di pianificazione da svolgere [179]. Il passaggio dai requisiti all'architettura è ulteriormente supportato da modelli NLP e BERT-based per valutare l'accoppiamento tra requisiti funzionali e parametri di progetto, e da recommender system supervisionati per suggerire associazioni tra componenti e funzioni, mantenendo il progettista come decisore finale.

Infine, l'ultima categoria riguarda quegli strumenti che supportano le fasi di controllo e verifica preliminare delle alternative di strutturazione generate. In questo contesto, LLM generativi vengono impiegati per analisi concettuali di tipo what-if e per l'identificazione di potenziali effetti indesiderati emergenti. Tali analisi sono talvolta affiancate da modelli ML supervisionati, ad esempio Random Forest applicati a dati ambientali o EPD, per stimare impatti ambientali preliminari, e da sistemi esperti rule-based che verificano automaticamente la conformità delle alternative ai requisiti e ai vincoli formalizzati [158].

In Appendice D viene proposta una tabella di sintesi (Tabella D.2) che adotta una prospettiva alternativa, organizzando l'analisi per paradigmi di intelligenza artificiale e indicando, per ciascuno, le attività di Problem Definition&Structuring associate. L'obiettivo è condensare la mappatura e renderla esplicita dal punto di vista dell'AI, anziché seguire una struttura guidata dalle attività come quella proposta in Tabella 3.9.

3.4.2.2. Fase divergente: Idea Generation

A seguire la Tabella 3.10 sintetizza il ruolo dell'AI nelle attività di idea generation lungo i diversi livelli di progettazione, dal conceptual al detailed design, evidenziando come il contributo impiegato nella fase di idea generation si riconfiguri lungo il processo progettuale, passando da forme di supporto prevalentemente creative a modalità di generazione sempre più strutturate e orientate da vincoli. Pur potenziando le capacità operative e creative del progettista (AUG), in questa fase l'AI richiede una supervisione umana costante (SUP), fondamentale per impostare, valutare e guidare iterativamente la generazione delle idee, sia sul piano creativo sia su quello tecnico.

CoA	Attività/sottofase svolta da AI	Paradig.	Tecniche/Algoritmi/Modelli/Domini dell'AI/Framework/Architetture	SUP/ AUG/ AUT	Fonti
STR	Identificazione dei trade off e creazione del NOP; mappa concettuale delle proposte di idee che emergono dal brainstorming	DL gen	LLM: esplicitazione e la riformulazione di sottoproblemi e contraddizioni identificati (con NLP), facilitando la costruzione iterativa del Network of Problems tramite cicli di prompting; traduzione di problemi confusi in enunciati focalizzati; generazione mappe concettuali a partire da trascrizioni di brainstorming	SUP	[183] [184]
		AI simb.	Esplicitazione dei concetti e delle relazioni individuate in un grafo di conoscenza formalizzata	AUG/ SUP	
STR/ COM/ CNTR		AI agentiv.	Sistema multi-agente basato su LLM con meccanismi di pianificazione e coordinamento di agenti per task specializzati, tra cui identificare le contraddizioni tra requisiti da risolvere	AUT	[172]
			Sistema multi-agente in cui l'agente di pianificazione traduce i requisiti in obiettivi di progettazione concreti per gli agenti specializzati (meccanica, elettronica, software), coordina gli agenti e gestisce i feedback umani attraverso ristrutturazione iterativa del problema di progettazione	AUT/ AUG	[173]

STR	Associazione tra requisiti funzionali e parametri di progetto	DL	BERT, NLP comprendono il linguaggio naturale e i feedback negativi sui prodotti (customer requirements, CR); s-BERT associa i CR ai functional requirements (FR) per similitudine semantica; BiLSTM e Self-Attention analizzano documenti tecnici e brevetti per collegare le funzioni ai design parameters (DP), apprendendo dalle relazioni nei progetti passati.	SUP	[166] [165] [185]
	Formalizzazione delle relazioni individuate	AI simb	Knowledge Graph: strutturazione dei concetti e delle relazioni estratte tra requisiti clienti (CR), funzionali (FR) e i parametri (DP)	AUG/ SUP	

			(guidando il progettista nella formulazione e validazione delle soluzioni generate)		
Concept. design	DEV	Generazione di schizzi, immagini, CAD, idee descrittive preliminari guidate dai requisiti specificati	DL gen.	Diffusion models, GAN, LLM e MLLM (fine-tuned su corpora testuali di progettazione come brevetti e idee di biomimicry): modelli condizionali che generano contenuti visuali e testuali vincolati ai prompt (text-to-text, text-to-image, image-to-image)	AUG/ SUP [150] [151] [186] [187] [188] [175] [189] [182] [190] [164]

DEV/ STR			DL, AI simb.	Pipeline modulare: componenti simbolici (rule-based e knowledge-based) e LLM vincolati nell'interpretazione semantica del problema e nella generazione di descrizioni contestuali basate sul principio solutivo scelto per risolvere il problema.	AUG/ SUP [183] [184]
STR	Associazione di principio solutivo/ insieme di principi solutivi/ design patterns per ogni problema specificato (TRIZ)	AI simb.		Sistema AI simbolica per supportare l'applicazione del metodo TRIZ che individua soluzioni alle contraddizioni identificate tramite formalizzazione delle regole esplicite che definiscono il ragionamento del sistema (più spiegabile dei modelli DL, ma non genera nuove sol.)	SUP [191]
				KG, regole di mapping: organizzazione dei concetti estratti in una base di conoscenza di dominio, collegando requisiti, parametri ingegneristici e soluzioni strutturali contenute nei brevetti;	AUG [185] [192]
			MLtrad.	NLP, BERT: estrazione delle informazioni (riconoscere funzioni, strutture, tecnologie e parametri ingegneristici e relazioni tra questi dai brevetti); trasforma concetti in vettori su cui vengono applicati metodi computazionali deterministici per calcolare la similarità semantica tra requisiti e soluzioni brevettuali ML supervisionato, SVM: classificazione dei requisiti in design pattern noti risolutivi; classificazione dei brevetti nei principi solutivi di TRIZ	AUG/ SUP [193] [185] [192]

STR	Associazione di principio solutivo/ insieme di principi solutivi/ design patterns per ogni problema specificato (TRIZ)	AI simb. + ML trad.	KG: codifica la conoscenza degli esperti da progetti passati in un'ontologia di dominio ML: trasforma il KG in un tensore e lo analizza con tecniche di relational learning, cerca connessioni tra soluzioni e problemi progettuali; stima relazioni mancanti (soluzioni per nuovi problemi); cattura fattori	SUP [194]
-----	--	------------------------	--	--------------

			latenti (conoscenza tacita); score di probabilità per ogni possibile relazione problema–soluzione		
--	--	--	---	--	--

High Level System/ Detailed Design	DEV/ STR/ CNTR	Associazione componenti-funzioni (successiva alle associazioni preliminari del problem structuring)	ML trad, AI simb.	ML supervisionato (sistemi di raccomandazione, classificazione e ranking): suggerire e prioritizzare componenti candidati in base ad associazioni osservate in progetti precedenti, combinato con moduli simbolici che verificano i vincoli derivati dalle specifiche	SUP	
---------------------------------------	----------------------	---	----------------------	---	-----	--

DEV/ CNTR/ COM/ STR		Generazione di idee di nuove forme, materiali, soluzioni, valori dei parametri tecnici, guidate dai vincoli di progettazione.	AI agentiv.	Sistema multi-agent basato su LLM con agenti specializzati che generano soluzioni per ogni trade-off; meccanismi di pianificazione e coordinamento degli agenti; reflector agent che critica e verifica le soluzioni ingegneristiche prodotte	AUT	[172]
				Sistema multi-agente in cui l’agente di pianificazione traduce i requisiti in obiettivi concreti per gli agenti specializzati che si occupano della progettazione specifica (meccanica, elettronica, software) dove in ciascuna è svolta idea generation; coordinamento agenti; gestione feedback umani	AUT/ AUG	[173]
Concept./ detailed design	DEV/ CNTR		Topology Optimiz., AI evol., ottimizz. numerica	Generative design tradizionale: Topology Optimization, Algoritmi evolutivi (GA, NSGA-II multi-objective), Ottimizzazione numerica (Gradient-based optimization): per esplorazione idee guidata da vincoli	AUG	
			DL gen, ML trad AI evol.	Generative design data-driven (ML/DL): DL gen (VAE comprime geometrie in spazio latente continuo consentendo esplorazione controllata, GAN o modelli di diffusione per garantire realismo geometrico e coerenza delle forme); addestrati su progetti passati per apprendere relazioni implicite tra forma, funzione e performance, vincoli fisici; Algoritmi evolutivi / reinforcement learning (guidano l’esplorazione orientando le iterazioni successive verso soluzioni migliorative)	AUG	[186]

COM	Traduzione tra linguaggi tecnici differenti, documentazione e reporting, sintesi dei concetti, Q&A su conoscenza aziendale interna ed esterna (recupero rapido di informazioni e amplificazione della conoscenza), brainstorming.	DL gen.	LLM, LLM+RAG, MLLM: facilitano la comunicazione tra esperti di domini diversi, generando testi, tabelle, grafici e schemi che favoriscono una comprensione condivisa. Funzionano come un assistente AI per il brainstorming e il recupero delle informazioni. Insieme a Diffusion Models, GAN stimolano argomentazioni nei brainstorming tramite le immagini generate, riducendo i fraintendimenti verbali tra esperti già a partire dall'early design.	AUG/ SUP	[189] [182]
STR/ COM		AI Simb + ML	KG, ontologie di dominio e reti semantiche, tecniche di ML, semantic learning: organizzare dati storici di progetto, risultati di simulazioni, test precedenti e regole esperte, preservando la conoscenza tacita degli esperti rendendola accessibile tramite query	AUG/ SUP	[194] [195] [170]
CNTR	Screening delle idee generate	N/A	Selezione a carico del progettista	-	

Tabella 3.10: Mappatura tra attività/sottofasi e strumenti di Intelligenza artificiale nell'Idea Generation.

Un primo insieme di contributi affronta la traduzione dei feedback dei clienti in decisioni progettuali, collocandosi all'interfaccia tra requisiti espressi in linguaggio naturale e parametri ingegneristici.

In [166] viene proposto un approccio in cui BERT è utilizzato per l'estrazione delle caratteristiche di prodotto e per l'analisi del sentiment, s-BERT abilita il matching semantico tra requisiti dei clienti e funzioni di prodotto e un'estensione che comprende BiLSTM e self-attention analizza i testi di brevetti e documenti tecnici per mappare il collegamento tra funzioni e parametri tecnici. I concetti estratti (requisiti cliente (CR), funzionali (FR) e parametri di progetto (DP)) vengono organizzati poi in una base di conoscenza interrogabile, un knowledge graph, che esplicita le relazioni specificate nei testi per guidare la fase generativa.

In modo affine, [185] utilizza BERT e NLP per strutturare la conoscenza brevettuale in un knowledge graph, ma con un focus sull'impiego di metodi computazionali deterministici per la valutazione delle soluzioni. Mediante metriche che analizzano la similarità semantica tra concetti espressi in forma vettoriale, valutano il grado di corrispondenza tra requisiti e soluzioni brevettuali, guidando la generazione di nuove soluzioni.

Altri approcci impiegano LLM per esplicitare sottoproblemi e contraddizioni latenti, riformulare enunciati confusi in formulazioni focalizzate e facilitare la costruzione iterativa del Network of Problems (NOP) attraverso cicli di prompting guidato. Consentono, inoltre, la generazione automatica di mappe concettuali a partire da trascrizioni testuali delle sessioni di brainstorming, supportando il progettista nella sintesi e organizzazione delle idee emergenti [183], [184].

Un ulteriore filone di ricerca affronta la risoluzione dei conflitti progettuali integrando AI con i framework FBS e TRIZ. In [192], tecniche di NLP estraggono dai brevetti elementi di conoscenza relativi alle funzioni e agli assetti strutturali dei sistemi, mentre il behaviour è interpretato dall'esperto umano e organizzato in un multi-layer knowledge graph (mKGCD) articolato su quattro livelli (Funzione, Comportamento, Struttura, Brevetti). Una SVM classifica i brevetti secondo i principi TRIZ, usato come framework per la risoluzione delle contraddizioni, e un modulo Word2Vec abilita il confronto semantico tra i concetti inseriti dal progettista e quelli nel grafo, supportando l'individuazione di soluzioni brevettuali affini.

In aggiunta, altri studi si concentrano completamente sull'integrazione dell'AI con la metodologia TRIZ per la generazione inventiva. In AUTOTRIZ [183] ad esempio, l'LLM svolge un task di NLP per comprendere la

descrizione del problema digitata in linguaggio naturale, per poi mapparla in una contraddizione TRIZ (parametro in miglioramento e in peggioramento), ricondotta, tramite ragionamento rule-based deterministico, alla matrice delle contraddizioni e ai rispettivi principi inventivi, la cui interpretazione è poi contestualizzata dall'LLM rispetto al problema specifico.

Lo studio [184] invece, integra l'LLM lungo l'intera pipeline del metodo TRIZ: dalla comprensione semantica del problema alla mappatura sui 39 parametri ingegneristici, fino all'identificazione e spiegazione delle contraddizioni, lasciando al progettista la selezione finale.

Un approccio alternativo adotta un modello neuro-simbolico che usa TRIZ come base del ragionamento simbolico. A differenza degli approcci basati su LLM, l'AI non è impiegata per una contestualizzazione creativa dei principi al problema specifico, ma per formalizzare e rendere interpretabile il processo TRIZ. Inoltre, sono impiegati modelli di machine learning a valle dell'applicazione delle regole, per supportare la valutazione quantitativa delle soluzioni. Il caso studio [191], relativo a un impianto per l'estrazione dell'acido benzoico, dimostra l'applicabilità industriale del metodo proposto.

In misura complementare, altri studi considerano gli LLM come partner cognitivi nella generazione concettuale. AskNatureGPT [188] li impiega nel bio-inspired design per ampliare lo spazio esplorativo iniziale, mentre [189] utilizza il ragionamento linguistico e il prompting strutturato per riformulare il problema ed esplorare alternative concettuali con feedback umano. Infine, [182] evidenzia il ruolo dei foundation models multimodali nel collegare testi, immagini, schizzi e modelli CAD e nell'orchestrare strumenti esterni tramite l'inserimento degli LLM in contesti agent-based, integrando i risultati prodotti dagli strumenti nel processo progettuale senza sostituire le pratiche ingegneristiche tradizionali.

Un orientamento alternativo è quello mostrato da [193] che affronta la connessione tra requisiti testuali e soluzioni progettuali che risultano già codificate nel contesto della progettazione delle interfacce utente, utilizzando NLP per estrarre i requisiti da documenti testuali e trasformarli in una rappresentazione semanticamente strutturata, per poi ricorrere a una SVM per associare ciascun requisito a una classe corrispondente di un pattern di interaction design (ad esempio dashboard, search filters o notifications) di soluzioni passate.

Altri studi esplorano l'uso di sistemi multi-agente basati su LLM per l'idea generation. In [172], agenti specializzati e coordinati gestiscono compiti di conceptual design, inclusa l'identificazione delle contraddizioni e delle strategie risolutive, mentre [173] estende l'approccio al detailed design tramite un agente di pianificazione centrale che orchestra agenti disciplinari (meccanica, elettronica, software) e integra iterativamente i feedback umani.

In casi applicativi specifici, nelle fasi di conceptual e detailed design, l'idea generation è supportata da tecniche di generative design tradizionale o data-driven, quali topology optimization, algoritmi evolutivi multi-obiettivo (NSGAI) e ottimizzazione numerica [186], talvolta integrando DL generativo (VAE, GAN, diffusion models) per apprendere relazioni implicite tra forma, funzione e performance, combinati insieme ad algoritmi evolutivi o di reinforcement learning che orientano iterativamente l'esplorazione verso soluzioni migliorative. Sebbene siano tradizionalmente associati alla fase di ottimizzazione, tali approcci trovano applicazione anche nell'idea generation, dove supportano la generazione di concetti progettuali realistici e compatibili con i vincoli. Ciò risulta particolarmente rilevante nei prodotti ingegneristici, in cui la creatività deve svilupparsi in modo inscindibile dalla fattibilità tecnica.

Diversi contributi analizzano la gestione e il riuso della conoscenza progettuale tacita come supporto all'idea generation: [194] modella la conoscenza tacita in knowledge graph e utilizza relational learning per inferire e ordinare relazioni problema-soluzione, [195] impiega AI simbolica e grafi di conoscenza per collegare domini eterogenei nel system e detailed design, mentre [170] studia reti semantiche costruite tramite termini estratti con NLP e ML non supervisionato su grandi corpora tecnici. Tali reti supportano attività di knowledge retrieval, knowledge association e reasoning, risultando particolarmente rilevanti nelle fasi iniziali di progettazione per il recupero di prior art, la generazione di analogie di soluzioni e la valutazione di novità e creatività. Infine, l'AI viene utilizzata come infrastruttura di supporto alla comunicazione e alla collaborazione interdisciplinare durante l'idea generation. LLM, LLM con RAG e MLLM facilitano la traduzione tra linguaggi tecnici differenti, la sintesi della documentazione, il question answering su conoscenza aziendale e il brainstorming

assistito [189], [182]. L'integrazione con modelli generativi visuali (diffusion models, GAN) consente di stimolare il confronto tra esperti tramite immagini riducendo ambiguità e fraintendimenti già nelle prime fasi del processo di progettazione

In Appendice D viene nuovamente proposta una tabella di sintesi (Tabella D.3) che adotta una prospettiva alternativa, in maniera analoga a quanto fatto per le fasi precedenti, con l'obiettivo di rendere la mappatura esplicita dal punto di vista dell'AI, anziché seguire una struttura guidata dalle attività come quella proposta in Tabella 3.10.

3.4.2.3. Fase divergente: Idea/Component Combination

La Tabella 3.11 sintetizza il contributo dell'intelligenza artificiale nella fase di Idea/Component Combination, mettendo in evidenza il suo ruolo nel supportare la combinazione sistematica di idee, soluzioni, moduli e componenti lungo i diversi livelli di progettazione, e nel facilitare l'esplorazione combinatoria e la verifica preliminare delle overall solutions. Pur mantenendo il progettista umano un ruolo centrale di controllo, le crescenti possibilità di codificazione e strutturazione dell'attività, rendono più rilevanti approcci a maggiore livello di automazione, quali quelli basati su sistemi di AI agentiva.

CoA		Attività/sottofase svolta da AI	Paradig.	Tecniche/Algoritmi/Modelli/Domini dell'AI/Framework/Architetture	SUP/ AUG/ AUT	Fonti
Conceptual Design	DEV/ STR	Combinazione di: idee, singole soluzioni, feature, per dare origine a overall solutions coerenti con i requisiti	DLgen	LLM, MLLM, VAE, GAN, Diffusion Models: modelli generativi condizionali (text-to-text (LLM, MLLM) text-to-image, image-to-image, con requisiti e richieste di combinazioni specificati nei prompt	AUG/ SUP	[175] [189] [196] [190]
High Level System Design	DEV/ CNTR/ STR	Combinazione di moduli e sottosistemi in assetti architetture, considerando relazioni strutturali e funzionali, garantendo vincoli di interfaccia, compatibilità e scambio di flussi di risorse	DL gen	Graph generative models: generano e combinano architetture apprendendo le relazioni tra i componenti, la coerenza strutturale è incorporata nel processo generativo stesso: Autoregressive graph generative models (ogni nodo aggiunto al grafo è condizionata dalla struttura già costruita), Grammar-based graph models (coerente garantita da regole esplicite), Graph VAE (esplorano varianti di architetture possibili sulla base di esempi di riferimento)	AUG	[197]

High Level System Design	DEV/ CNTR/ STR	Combinazione di moduli e sottosistemi in assetti architettureali, considerando relazioni strutturali e funzionali, garantendo vincoli di interfaccia, compatibilità e scambio di flussi di risorse	DLgen	LLM: tratta moduli e i componenti come token generando combinazioni di sequenze coerenti alternative (fine-tuning su esempi che contengono le relazioni da apprendere). È accettabile per la combinazione di moduli in strutture semplici e prettamente sequenziali	AUG/ SUP	[198] [199] [200]
			AI agentiv.	Deep Multi-Agent Reinforcement Learning: tratta la progettazione come un processo decisionale sequenziale, in cui più agenti cooperano per esplorare e valutare combinazioni di componenti nelle architetture. La generazione è guidata dalla conoscenza ingegneristica derivata da QFD e Axiomatic Design, integrata nell'ambiente e nella funzione di reward.	AUG/ AUT	[201]

Detailed Design/ Conceptual Design di prodotti ingegnerist.	DEV/ CNTR	Combinazione di soluzioni/ elementi singoli all'interno di un componente o di un complessivo	Topology Optimiz. AI evol., ottimizzaz. numerica	Generative design tradizionale: Topology Optimization, Algoritmi evolutivi (GA, NSGA-II multi-objective), Ottimizzazione numerica (Gradient-based optimization) per combinazione delle soluzioni guidata da vincoli	AUG	[197]
			DL gen, ML trad, AI evol.	Generative design data-driven (ML/DL): DL gen (VAE comprime geometrie in spazio latente continuo consentendo esplorazione controllata, GAN o modelli di diffusione per garantire realismo geometrico e coerenza delle forme); addestrati su progetti passati per apprendere relazioni implicite tra forma, funzione e performance, vincoli fisici; Algoritmi evolutivi / reinforcement learning (guidano l'esplorazione orientando le iterazioni successive verso combinazioni migliorative)	AUG	[186] [196] [197]
	DEV/ CNTR/ COM/ STR		AI agentiv.	Sistema multi-agente in cui l'agente di pianificazione traduce i requisiti in obiettivi concreti per gli agenti specializzati che si occupano della progettazione specifica (meccanica, elettronica, software) dove in ciascuna è svolta idea/component combination; coordinamento agenti; gestione feedback umani	AUT/ AUG	[173]

Conceptual Design	CNTR	Verifica, valutazione, validazione e prioritizzazione degli elementi risultanti (la selezione resta completamente a carico del soggetto)	ML trad	ML supervisionato (RF, GB, SVR) e shallow DL (MLP) per attività di scoring e ranking tramite stima quantitativa di KPI proxy e indicatori sintetici di costo, rischio, complessità, impatto ambientale ecc. (modelli addestrati su esempi di valutazioni storiche)	AUG	
			DL gen.	LLM: confronto argomentato tra alternative, valutazione qualitativa, applicazione di metodi multicriterio, validazione qualitativa dei requisiti	AUG/ SUP	[189]
High Level System/ Detailed Design			ML trad, DL	ML supervisionato (SVR, RF, GB) o tecniche di DL (MLP profonde, CNN, GNN, quando input o output ad alta dimensionalità e dataset estesi) usati come surrogate models delle analisi FEM per le valutazioni intermedie di parametri multipli (stress, peso, costo); RL (decision making sequenziale che guida l'esplorazione successiva delle combinazioni valutando quelle precedenti), Graph ML (valutazione strutturale delle configurazioni)	AUG	
			AI simb.	Rule-based compliance checking (se definite esplicitamente le regole e le relazioni nella fase di strutturazione del problema)	AUG	

Tabella 3.11: Mappatura tra attività/sottofasi e strumenti di Intelligenza Artificiale nell' Idea/Component Combination.

Una prima categoria considera l'AI come supporto alla combinazione guidata di idee nelle fasi iniziali del Conceptual Design. In questo ambito, modelli di deep learning generativo abilitano un'esplorazione combinatoria vincolata tramite prompting: LLM e MLLM supportano l'integrazione di concetti e idee in configurazioni coerenti con i comandi specificati e le rendono disponibili in formato descrittivo o visivo (text-to-text, text-to-image, image-to-image, image-to-text), mentre VAE, GAN e modelli di diffusione consentono la fusione visiva e morfologica delle soluzioni, traducendo le indicazioni specificate nei prompt, quando presenti nelle loro versioni condizionali [175], [189], [196], [190].

Un altro studio [202] propone invece un'applicazione dell'AI che rende l'idea combination guidata dal legame tra emozioni degli utenti e forme del prodotto. Questo diventa utile soprattutto per lo sviluppo di quei prodotti le cui prestazioni tecniche sono ormai standardizzate e facilmente imitabili, mentre la risposta emotiva suscitata dalla forma diventa un fattore competitivo decisivo, come nel caso dello scooter elettrico, menzionato come caso applicativo. Il processo prevede che vengano usate delle tecniche di NLP per identificare, dalle recensioni online di prodotto, delle variabili Kansei chiave (ad esempio "comfortable", "stable", "portable", "cool"), poi una rete convoluzionale CNN lavora su dati strutturati per estrarre pattern e relazioni locali tra le variabili di design e apprende quali configurazioni di shape tendono a essere associate a determinate risposte emotive; infine, GRU e Attention mechanism catturano le dipendenze complesse tra le forme del prodotto che suscitano le emozioni identificate dalle variabili Kansei per poi valutare le combinazioni e identificare quelle che colpiscono maggiormente la sfera percettiva del cliente. In questa fase l'AI non viene usata per generare direttamente la forma

finale del prodotto, piuttosto suggerisce e valuta idee di combinazioni efficaci, che diventano input per la fase di concept generation.

In [198] invece, viene proposta la quadrisociation come metodo di ideazione che combina simultaneamente quattro domini disciplinari, superando i modelli classici di bisociazione e trisociazione, per affrontare problemi complessi e multidimensionali. I Large Language Models vengono usati in questo contesto come strumenti di supporto cognitivo, facilitando l'esplorazione di connessioni tra ambiti eterogenei e analizzando grandi quantità di informazioni relativi a blocchi di conoscenza diversi, ma senza generare direttamente soluzioni ingegneristiche complete.

I casi studio proposti, come Telehealth immersiva e Smart Water Bottle, mostrano come la quadrisociazione consenta di integrare tecnologie e saperi diversi (es. AR/VR, sostenibilità, IoT, nanotecnologie, psicologia comportamentale) per sviluppare concept e architetture di sistema.

Nel caso in cui la fase di combinazione risulti applicata a livello di sistema, come nell'high level system design, l'obiettivo non è più la combinazione di singole idee, ma di moduli e sottosistemi in configurazioni architetture dove contano fortemente le relazioni e le interazioni tra gli elementi presenti. In questo contesto, i Graph Generative Models rappresentano un approccio centrale. L'architettura del sistema è modellata come un grafo e la coerenza strutturale è incorporata direttamente nel processo generativo. Modelli autoregressivi generano nuovi nodi e connessioni condizionandoli alla struttura già costruita, mentre approcci grammar-based garantiscono la validità delle configurazioni tramite regole esplicite [197]. I Graph VAE, invece, consentono l'esplorazione di varianti architetture sulla base di esempi esistenti, da cui hanno appreso relazioni di compatibilità di interfaccia e coerenza tra le funzioni modellate.

In alternativa, LLM opportunamente fine-tuned possono trattare moduli e componenti di prodotto come token, generando sequenze di combinazioni coerenti. Tale approccio risulta però principalmente adeguato a strutture semplici, dove le relazioni tra elementi non sono fortemente reticolari, piuttosto lineari e sequenziali [198], [199], [200].

Un altro approccio che affronta questa fase come un processo decisionale sequenziale è rappresentato dai sistemi agentivi. Nei modelli di Deep Multi-Agent Reinforcement Learning, diversi agenti cooperano per esplorare e valutare combinazioni di componenti all'interno di un'architettura di prodotto. La generazione delle soluzioni non è puramente data-driven, ma viene guidata da conoscenza ingegneristica formalizzata, derivata da framework come QFD e Axiomatic Design, integrata nell'ambiente e nella funzione di reward [201]. Nel caso di prodotti complessi, viene nuovamente proposto l'approccio agentivo che traduce i requisiti in obiettivi operativi per agenti specializzati (meccanica, elettronica, software), all'interno dei quali la combinazione di idee e soluzioni avviene localmente e globalmente, con meccanismi di coordinamento tra gli agenti e gestione del feedback umano [173].

Per prodotti caratterizzati da un certo livello di rigore tecnico ingegneristico, i livelli Conceptual e Detailed della progettazione sono entrambi caratterizzati dalla necessità di combinare soluzioni elementari, forme, parametri, in modalità guidata dal rispetto di vincoli predefiniti. A questo scopo il Generative Design che implementa tecniche evolutive, di ottimizzazione e talvolta estensioni di DL generativo e di apprendimento automatico, consente l'esplorazione di configurazioni alternative valide, migliorandole ad ogni ciclo iterativo rispetto agli obiettivi di valutazione specificati o appresi [186], [196], [197].

Infine, un ultimo ambito tematico riguarda la valutazione e prioritizzazione delle combinazioni di soluzioni generate, dove le tecniche utilizzabili si distinguono a seconda del tipo di processo di progettazione implementato. Modelli di machine learning supervisionato tradizionale (RF, Gradient Boosting, SVR) e shallow deep learning (MLP) sono impiegati per attività di scoring e ranking, stimando KPI proxy quantitativi quali costo, rischio, complessità o impatto ambientale sulla base di valutazioni storiche. Questi modelli non forniscono una valutazione prestazionale accurata, ma supportano la selezione preliminare delle alternative più promettenti e sono dunque particolarmente adatte al design concettuale.

In un'ottica analoga, gli LLM sono utilizzati per il confronto argomentato tra alternative, la valutazione qualitativa e l'applicazione di metodi multicriterio, mantenendo la decisione finale in capo al progettista [189].

Con riferimento alla valutazione dell'output di questa fase, in particolare per prodotti ingegneristici modellati nei livelli più avanzati della progettazione, come nel design di dettaglio, i modelli di tipo ML e DL possono essere impiegati come surrogate models delle analisi FEM o di simulazioni complesse, consentendo una valutazione intermedia delle configurazioni generate. In parallelo, approcci simbolici di tipo rule-based consentono il controllo di conformità, qualora regole, relazioni e vincoli siano stati preventivamente esplicitati e formalizzati nella fase di Problem Structuring.

Come per altre fasi, anche per quella di Idea/Component Combination viene presentata in Appendice D una tabella di sintesi (Tabella D.4) che esplicita la mappatura dal punto di vista dell'AI, anziché seguire la strutturazione per attività di Tabella 3.11.

3.4.2.4. Fase divergente: Concept Generation, Shape Exploration & Concept Refinement

Di seguito si propone la Tabella 3.12 relativa all'esplorazione del ruolo dell'AI nella attività di concept generation, orientata al raffinamento e alla concretizzazione delle forme progettuali, dalla visualizzazione dei concept alla modellazione CAD/CAE, fino alla prototipazione fisica e virtuale negli stadi più avanzati della progettazione.

CoA	Attività/sottofase svolta da AI	Paradig.	Tecniche/Algoritmi/Modelli/Domini dell'AI/Framework/Architetture	SUP/ AUG/ AUT	Fonti
DEV	Esplorazione delle forme del concept, reso visivamente disponibile	DL gen	MLLM, GAN, Diffusion Models, VAE, modelli generativi condizionali (text-to-image, image-to-image, editing di immagini)	AUG/ SUP	[186] [175] [189] [196] [203] [204]
ID/ CNTR		DL	CNN-GRU-Attention: cattura mappatura non lineare tra emozioni e forme; valuta combinazioni identificando quelle che massimizzano il valore Kansei (emozioni associate alle caratteristiche di prodotto)	SUP	[202]
DEV/ CNTR	Modellazione (CAD/CAE) per esplorare forme e strutture dei concept generati	ML trad	ML supervisionato (RF, GB, Shallow MLP): Feature recommendation, Constraint suggestion; modelli addestrati su progetti CAD passati.	SUP	
DEV		DLgen	Diffusion Model condizionale, flusso concepito in 2 step: text-to image, image-to-3D	AUG/ SUP	[205]
CNTR		AI simb	Sistemi rule-based: constraint checking	AUG	
DEV	Prototipazione rapida fisica e virtuale	3D printing, additive manufact.	3D printing, additive manufacturing, spesso seguono generative design	-	
		DL gen.	LLM fine-tuned: traduce comandi testuali in prototipi virtuali (es. genera interfaccia utente interattiva delle applicazioni web)	AUG/ SUP	[203]

Tabella 3.12: Mappatura tra attività/sottofasi e strumenti di Intelligenza Artificiale nel Concept Generation.

La fase di Concept Generation è dedicata all'esplorazione delle forme e al raffinamento del concept. Il termine concept va interpretato in modo differente in funzione del livello del processo progettuale considerato e può essere inteso, in generale, come la concretizzazione, visiva o fisica, delle idee o dei componenti precedentemente sintetizzati in combinazioni di soluzioni. Coerentemente, anche l'impiego degli strumenti di Intelligenza Artificiale utilizzati in questa fase, varia in relazione al livello di avanzamento del processo progettuale.

Nelle fasi iniziali, in cui la progettazione è prettamente concettuale, l'idea è quella di modellare visivamente le overall solutions selezionate nello step precedente di idea combination, per rendere visivamente disponibile il prodotto complessivo e poterlo modellare, perfezionare e rifinire attraverso strumenti CAD dedicati.

Per quanto riguarda l'esplorazione delle forme, si usano prevalentemente modelli di deep learning generativo come MLLM, GAN, VAE e Diffusion Models che consentono di creare concept innovativi, di alta qualità e che riflettano creatività combinatoria, a partire da idee e modifiche implementate tramite modalità condizionate (text-to-image, image-to-image ed image editing) [186], [175], [189], [203], [204]. Tali modelli accettano diversi tipi di input quali: testo, schizzi, tag emotivi o segnali ECG, che riflettono requisiti funzionali del prodotto e aspetti stilistici e cognitivi del designer. Infatti, per allineare la comprensione dei designer con quella dell'AI generativa, alcuni studi integrano caratteristiche cognitive dei designer nel dataset di addestramento.

Altri, mostrano la possibilità di ottenere diverse combinazioni a partire da modifiche riguardanti attributi di forma, colore, materiale e texture. Ad esempio, DA-GAN è stato utilizzato per trasformare un gilet in una maglietta, modificando maniche e colore ma mantenendo il pattern originale. I risultati dimostrano una significativa superiorità prestazionale rispetto a un approccio esclusivamente manuale. Un caso applicativo mostra a tal proposito come la generazione del frontale di un'automobile richieda 3,4 s, contro i circa 20 min dei metodi tradizionali [196].

In questa fase si distinguono i VAE, che risultano maggiormente adatti a un'esplorazione continua dello spazio rappresentato da concept esistenti, mentre si prestano meno alla fase di idea generation per la limitata capacità di generazione di novità concettuale radicale.

Inoltre, alcuni Diffusion Model condizionali, attraverso un processo in due step, dal text-to-image all'img-to-3D [205], consentono di ottenere rapidamente modelli 3D esplorativi a partire da descrizioni testuali o immagini. Tale approccio evita l'ottimizzazione iterativa di proposte alternative multi-view tipica di metodi come DreamFusion, che richiedono ore di GPU per singolo oggetto, permettendo invece la generazione completa in 1–2 minuti su singola GPU.

L'esplorazione delle forme rappresenta un'attività intrinsecamente creativa, ma nella pratica progettuale deve essere guidata dai requisiti inizialmente definiti, così da garantire che le soluzioni generate risultino coerenti con le esigenze di interazione e di esperienza del cliente. Per questo motivo, esistono degli approcci, come quello basato su CNN, GRU e Attention, che sono impiegati per apprendere la mappatura non lineare tra caratteristiche formali del prodotto ed emozioni percepite (secondo l'approccio Kansei engineering). In questo caso l'AI non genera nuove forme ma apprende le relazioni e valuta le combinazioni di attributi, identificando quelle che massimizzano il valore emozionale atteso, per guidare la generazione e la valutazione del concept [202].

Un ulteriore ambito tematico riguarda l'integrazione dell'AI nei processi di modellazione CAD/CAE per il raffinamento dei concept. Tecniche di machine learning supervisionato (ad esempio Random Forest, Gradient Boosting e MLP poco profondi), addestrate su archivi di progetti precedenti, vengono utilizzate per fornire raccomandazioni di feature e configurazioni già validate, oltre che per supportare la gestione dei vincoli e degli errori.

Quando le regole sono ben definite e le relazioni risultano esplicite e dunque formalizzabili, come spesso accade nel caso di prodotti ingegneristici e tecnici, possono essere usati sistemi simbolici rule-based che verificano la coerenza geometrica e progettuale delle soluzioni.

Infine, dopo il completamento dei cicli di ottimizzazione e valutazione, si procede alla prototipazione, volta alla realizzazione fisica di una versione ottimizzata dei concept. In questa trattazione, viene collocata nella fase correntemente considerata per mantenere una visione unitaria del processo di design, pur rappresentando nello sviluppo prodotto una sezione distinta e avanzata. Infatti, configurando il passaggio dalla rappresentazione visuale

alla realizzazione materiale della soluzione ottimizzata, questa fase rappresenta l'evoluzione concreta della fase di concept generation.

Tecniche di prototipazione rapida come quelle basate su additive manufacturing e 3D printing sono spesso integrate in flussi di generative design per verificare l'output della progettazione generativa. Per altri tipi di prodotti come le interfacce web, i LLM consentono la creazione di prototipi virtuali a partire da descrizioni testuali, per esempio Lovable [203] traduce requisiti espressi in linguaggio naturale in mock-up di interfacce app funzionanti, secondo pattern ricorrenti di progettazione, integrando implicitamente le good practices di usabilità e affordance. Nel complesso, tali risultati evidenziano il ruolo dell'AI nel garantire la continuità e facilitare il passaggio tra ideazione, rappresentazione visiva e materializzazione della soluzione progettuale.

In Appendice D è resa disponibile come per gli altri casi la tabella di sintesi (Tabella D.5) che propone una prospettiva alternativa, organizzando l'analisi per paradigmi di Intelligenza Artificiale, in alternativa all'organizzazione per attività adottata in Tabella 3.12.

3.4.2.5. Fase divergente: Concept Optimization

La Tabella 3.13 che segue descrive invece il ruolo dell'intelligenza artificiale nella fase di Concept Optimization, ancora una volta distinguendo tra diversi livelli di progettazione, qualora le divergenze applicative degli strumenti lo richiedano. Per soluzioni a minore contenuto tecnico, il contributo dell'AI è prevalentemente valutativo, con suggerimenti di modifica a supporto del progettista. Al contrario, nel caso di soluzioni ingegneristiche parametrizzabili, l'AI abilita cicli automatici di generazione e selezione, sfruttando la modellazione matematica delle variabili progettuali per condurre miglioramenti multi-obiettivo basati su dominanza di Pareto o coordinando processi di ottimizzazione distribuiti tra agenti specializzati.

CoA		Attività/sottofase svolta da AI	Paradig.	Tecniche/Algoritmi/Modelli/Domini dell'AI/Framework/Architetture	SUP/ AUG/ AUT	Fonti
Concept. Design	CNTR	Valutazione e selezione mirata dei concept generati più promettenti da avviare alla successiva iterazione di ottimizzazione (aspetti strutturali e funzionali)	ML trad./ DL	ML supervisionato o DNN (quando relazioni non lineari) impiegati come surrogate models per stimare rapidamente KPI multidimensionali e supportare la valutazione comparativa delle alternative progettuali	AUG/ SUP	[206]
				ANN (MLP) per la valutazione sintetica delle prestazioni ecologiche del design (materiali, efficienza energetica, riciclabilità), e logica fuzzy per la gestione dell'incertezza nei parametri progettuali.	AUG/ SUP	[207]
	DEV/ CNTR		AI evol.	NSGA-II applicato a design concettuali parametrizzabili, traducibili in variabili quantitative, per la valutazione multi-obiettivo delle alternative generate; sulla base della dominanza di Pareto vengono selezionate le soluzioni più promettenti da sottoporre alla successiva iterazione di ottimizzazione	AUG	[208] [209] [197]
			DLgen	LLM: analisi qualitativa dei risultati, suggerimenti per implementare modifiche	SUP	[189]

Detailed Design/ Concept. Design di prodotti ingegnerist.	DEV/ CNTR	Valutazione e selezione mirata dei componenti generati più promettenti da avviare alla successiva iterazione di ottimizzazione (aspetti legati alle performance tecniche e al behaviour del sistema)	Topology Optimiz., AI evol., ottimizzaz. numerica	Generative design tradizionale: Topology Optimization, Algoritmi evolutivi (GA, NSGA-II multi-objective), Ottimizzazione numerica (Gradient-based optimization) per ottimizzazione iterativa (cicli generazione e selezione) delle soluzioni in base ai vincoli e obiettivi definiti	AUG	[197] [210] [206]
			DL gen, ML trad, AI evol.	Generative design data-driven (ML/DL): DL gen (VAE comprime geometrie in spazio latente continuo consentendo esplorazione controllata, GAN o modelli di diffusione per garantire realismo geometrico e coerenza delle forme); addestrati su progetti passati per apprendere relazioni implicite tra forma, funzione e performance, vincoli fisici; Algoritmi evolutivi / reinforcement learning (guidano l’esplorazione orientando le iterazioni successive verso combinazioni migliorative)	AUG	[186] [197]
	DEV/ CNTR/ COM/ STR		AI agentiv.	Sistema multi-agente in cui l’agente di pianificazione traduce i requisiti in obiettivi concreti per gli agenti specializzati che si occupano della progettazione specifica (meccanica, elettronica, software) dove in ciascuna è svolta concept optimization; coordinamento agenti; gestione feedback umani	AUT/ AUG	[173]
				Deep Multi-Agent Reinforcement Learning: automatizzare la generazione e valutazione di concetti di prodotto, integrando conoscenza ingegneristica (QFD e Axiomatic Design) nella funzione di reward (gli agenti apprendono non solo cosa ma anche come progettare). Gli agenti progettano in modo collaborativo e ottimizzano un reward comune legato alla qualità del concetto di prodotto	AUT/ AUG	[201]

Detailed Design/ Concept. Design di prodotti ingegnerist	DEV/ CNTR/ COM/ STR	Valutazione e selezione mirata dei componenti generati più promettenti da avviare alla successiva iterazione di ottimizzazione (aspetti legati alle performance tecniche e al behaviour del sistema)	AI agentiv.	Framework multi-agente basato su LLM che allinea progettazione concettuale e ingegneristica integrando fin dalle fasi iniziali vincoli tecnici e principi ingegneristici; agenti orchestrati analizzano il mercato, estraggono attributi formali, generano concept visivi e geometrie 3D approssimate, successivamente validate tramite surrogate model neurali con physics-attention per la valutazione tecnica (es. aerodinamica) con cui apprendere correlazioni fisiche interne al flusso; compie previsioni su grandezze tecniche del modello generato senza ricorrere a simulazioni complesse.	AUT/ AUG	[211]
	COM/ STR			Agenti basati su LLM chiamano tool che si occupano di sviluppare simulazioni o calcoli ingegneristici per poi elaborare e interpretare i risultati ricevuti.	AUG/ SUP	[182]
	CNTR	Valutazione delle alternative progettuali da avviare alle iterazioni successive di ottimizzazione o alla valutazione finale.	MLtrad/ DL	Modelli di ML supervisionato o DNN (relazioni non lineari) impiegati come surrogate models per la stima rapida di KPI multidimensionali in base a valutazioni apprese di soluzioni passate, AI data-driven guidata dalla fisica (Physics-informed feature engineering: integrazione vincoli fisici negli input delle reti) per rendere le valutazioni dei modelli black box maggiormente spiegabili	SUP	[210] [195]

Tabella 3.13: Mappatura tra attività/sottofasi e strumenti di Intelligenza Artificiale nel Concept Optimization.

La fase di ottimizzazione può essere vista come un micro-processo iterativo di progettazione, basato sull'alternanza continua tra generazione e valutazione, inserito all'interno di un processo progettuale di livello superiore. Collocandosi in uno step intermedio, le attività divergenti e convergenti di questa fase vengono supportate da strumenti differenti rispetto a quelli tipici delle fasi esplorative iniziali e valutative finali. In particolare, quella generativa è fortemente guidata da vincoli e da obiettivi tecnici di ottimizzazione delle performance, diversi quindi degli strumenti creativi tipicamente usati nelle fasi esplorative iniziali. Mentre in quelle convergenti, gli strumenti richiedono una rigerosità e una precisione inferiori rispetto a quelli che supportano la valutazione finale, trattandosi di attività ripetute per molteplici iterazioni piuttosto che di un'unica fase finale decisiva.

Per esempio, alcuni studi utilizzano modelli di machine learning supervisionato e reti neurali profonde per la valutazione comparativa rapida degli output intermedi di progettazione. Questi operano come surrogate models per stimare rapidamente KPI multidimensionali, riducendo il ricorso a simulazioni numeriche costose (CFD, FEM, analisi RCS) [206]. Al fine di valutare rapidamente ma in maniera realistica soluzioni ingegneristicamente complesse come quelle aerodinamiche, i modelli di ML/DL sono arricchiti da conoscenza fisica. In particolare, Quando le relazioni da apprendere sono fortemente non lineari e collegano discipline diverse, si usano le DNN che riescono a catturare queste dipendenze con un errore molto basso. A partire da un dataset generato offline (es. modelli aerodinamici, strutturali, RCS e di peso), le DNN imparano a mappare variabili geometriche (es. area

alare, aspect ratio, sweep, fusoliera) e condizioni operative (es condizioni di volo: Mach, Reynolds, angolo d'attacco) diventando dei valutatori multidisciplinari. In questi casi, vengono combinate con approcci di physics-informed feature engineering, che integrano vincoli fisici direttamente negli input delle reti neurali, migliorando la plausibilità e la spiegabilità delle valutazioni rispetto a modelli puramente black box [210], [195].

Quando l'obiettivo invece è ottimizzare rispetto a obiettivi che riguardano l'effetto del sistema sull'ambiente, in ottica Life Cycle Assessment (LCA), alcuni approcci utilizzano reti MLP per svolgere una valutazione sintetica delle prestazioni ecologiche dei concept (materiali, efficienza energetica, riciclabilità), integrate con logica fuzzy per gestire l'incertezza di alcune variabili. Lo studio [207] contestualizza questo approccio applicandolo al caso della progettazione di un frigorifero.

Nei prodotti ingegneristici complessi, l'ottimizzazione del concept di prodotto consiste nella determinazione di configurazioni parametriche che combinano assetti strutturali e prestazioni tecniche compatibili, valutate rispetto a obiettivi multipli, spesso conflittuali.

In tali contesti, l'approccio più diffuso è il Generative Design, che combina algoritmi evolutivi multi-obiettivo (in particolare NSGA-II) per l'individuazione dei fronti di Pareto e la selezione delle soluzioni non dominate, tecniche di ottimizzazione topologica, e, in alcuni casi, modelli di deep learning generativo e di machine learning per apprendere le relazioni di dominio implicite tra forma, funzione e performance in progetti pregressi [186], [209], [197], [210], [206]. In alcuni casi vengono anche impiegate tecniche di reinforcement learning, oltre alle pratiche evolutive, per guidare i cicli di ottimizzazione e orientare le iterazioni successive verso configurazioni migliorative.

L'impiego congiunto di queste tecniche consente di estendere tali approcci anche a prodotti caratterizzati da un minore rigore tecnico, a condizione che gli aspetti rilevanti del problema siano formalizzabili e traducibili nel linguaggio computazionale dei metodi adottati. Per esempio, [208] propone un sistema di supporto alla progettazione che impiega NSGA-II per ottimizzare la soluzione, contemporaneamente sia rispetto alle aspettative percettive ed emotive del cliente, sia rispetto ai parametri ingegneristici oggettivi di performance, superando la loro tradizionale trattazione separata, il cui esito portava a incoerenze sugli stessi attributi.

L'approccio include anche Fuzzy Regression per modellare, a partire dal QFD, la relazione tra requisiti del cliente e parametri tecnici, gestendo attraverso la logica Fuzzy l'imprecisione dei giudizi soggettivi; e utilizza ANFIS (Adaptive Neuro-Fuzzy Inference System) per apprendere il legame tra forme e reazioni emotive.

In maniera simile, [209] affronta l'ottimizzazione multi-obiettivo della forma di un prodotto per massimizzare più emozioni percepite. Le forme sono parametrizzate in variabili numeriche e valutate tramite logica fuzzy, che trasforma giudizi emotivi vaghi in un valore di fitness emotivo continuo. Un DNSGA-II (versione migliorata di NSGA-II) esplora poi lo spazio delle forme e produce un insieme di soluzioni Pareto-ottimali, tra cui il designer seleziona quella più adatta.

Inoltre, le tecniche multi-agente già citate nelle fasi precedenti, svolgono un ruolo significativo anche nelle fasi di ottimizzazione. Infatti, in [173], l'ottimizzazione avviene sia all'interno delle singole progettazioni degli agenti specializzati (meccanica, elettronica, software), sia a livello di sistema, coordinando gli agenti e integrando i feedback umani. In [201] invece, l'architettura di Deep Multi-Agent Reinforcement Learning consente agli agenti di apprendere come progettare in modo collaborativo, ottimizzando una funzione di reward comune che incorpora conoscenza ingegneristica formale tramite QFD e Axiomatic Design (AD). Il QFD viene usato per tradurre i requisiti del cliente in pesi quantitativi, mentre AD verifica la fattibilità e la compatibilità tra componenti. Infine, [211] mostra un framework multi-agente basato su LLM, per integrare styling e aerodinamica già nelle fasi iniziali del design automobilistico, superando le discordanze tipiche dell'early design tra soluzioni creative e requisiti tecnici vincolanti per le fasi successive della progettazione. Nel framework, gli agenti orchestrati da LLM traducono requisiti qualitativi in concept visivi tramite modelli generativi di diffusione, i rendering 2D vengono poi convertiti in geometria 3D approssimata mediante modelli di ricostruzione neurale. Le configurazioni risultanti sono successivamente sottoposte a screening tramite surrogate models neurali con meccanismi di physics-attention per la previsione di grandezze tecniche, senza ricorrere a simulazioni complesse. In ultima istanza, per la valutazione finale, gli agenti basati su LLM possono orchestrare tool esterni per impostare simulazioni o calcoli ingegneristici, interpretandone i risultati [182].

La medesima tabella di sintesi, che organizza l'analisi per paradigmi di Intelligenza Artificiale, è riportata in Appendice D (Tabella D.6).

3.4.2.6. Fase convergente: Evaluation&Selection

Infine, la Tabella 3.14 sintetizza i principali contributi dell'intelligenza artificiale nella fase di Evaluation & Selection, distinguendo tra valutazioni qualitative e quantitative, simulazioni fisiche e ingegneristiche nelle applicazioni a maggiore contenuto tecnico, e attività di validazione orientate al mercato. In quest'ultimo caso, l'AI è impiegata per anticipare le reazioni e i feedback dei clienti in vista dell'immissione del prodotto sul mercato, contribuendo a ridurre il numero delle successive iterazioni di perfezionamento post lancio.

CoA		Attività/sottofase svolta da AI	Paradig.	Tecniche/Algoritmi/Modelli/Domini dell'AI/Framework/Architetture	SUP/ AUG/ AUT	Fonti
Conceptual Design	CNTR	Valutazione delle caratteristiche qualitative	DL	LLM: analisi qualitativa delle alternative, modelli vision-language (VLM) e altri multimodali per interpretare congiuntamente immagini e testo; CNN: per estrarre informazioni dagli sketch; BERT, NLP: comprendere testo relativo alle descrizioni dei concept da valutare; Multimodal Learning: fondere informazioni multimodali modellando relazioni incrociate (cross attention)	SUP	[189] [196] [189] [212] [164]
		Valutazione delle caratteristiche quantitative	ML trad	Machine learning supervisionato (RF, SVM, GB, etc) e reti neurali semplici ANN, Neuro-Fuzzy (per predizioni di variabili incerte): misurazione rapida di KPI quantitativi (es. analisi LCA per impatto ambientale)	AUG/ SUP	[191] [213]
Detailed Design	CNTR	Verifica e validazione finale di requisiti, vincoli e performance attese	Simulaz. numer. e analisi fisiche	CFD (Computational Fluid Dynamics) per analisi aerodinamiche, termiche e di scambio fluido-struttura Multibody Dynamics (MBD) per cinematica e dinamica di sistemi meccanici complessi FEM per verificare il comportamento strutturale di un componente o di un sistema sotto condizioni di carico definite, quando la geometria e i materiali sono ormai noti e ben specificati Co-simulazioni multi-fisiche (strutturale-termico-fluido-elettromagnetico)	AUG/ SUP	

Detailed Design/ Conceptual Design di prodotti ingegnerist.	CNTR	Verifica e validazione finale di requisiti, vincoli e performance attese	AI simb.	Rule-based compliance checking (se definite esplicitamente le regole e le relazioni nella fase di strutturazione del problema)	AUG	
		Valutazioni degli output grafici, numerici ecc.	DL gen	Modelli vision-language (VLM) es. GPT-4V e LLaVA 1.6 34B per comprendere sketch, disegni tecnici, risultati di ottimizzazione topologica, immagini di difetti di problemi ingegneristici e produrre valutazioni qualitative di questi LLM fine-tuned: interpretazione degli output di simulazione basato su apprendimento di progetti passati	SUP	[189]
	COM/ CNTR		AI agentiv.	Agenti basati su LLM, chiamano tool dedicati su cui impostano prove di simulazione e analizzano i risultati ottenuti		

CNTR	Selezione	N/A	Selezione a carico del progettista	-	
	Validazione rispetto alle aspettative percettive dell'utente	DL	DL supervisionato usato come modello predittivo per stimare la preferenza implicita dell'utente (positiva, neutra o negativa) verso ciascun concept generato, dopo aver appreso la relazione tra caratteristiche dei prodotti e preferenze, usando come input anche segnali ECG	SUP	[214]
			CNN: per estrarre automaticamente le feature visive dall'immagine MLP: prende in input le feature estratte e svolge regressione per predire il valore di preferenza estetica, sulla base del rapporto likes/views dei dati sul quale viene allenato.	SUP	[215]
		MLtrad	ML supervisionato (regressione logistica, SVM, un semplice perceptron, Random Forest, XGBoost, LightGBM, con la Random Forest che ottiene le migliori prestazioni): classificazione binaria dei prodotti di successo / insuccesso basata su dati storici di vendita e caratteristiche di prodotto.	SUP	[216]

Tabella 3.14: Mappatura tra attività/sottofasì e strumenti di Intelligenza artificiale nel Concept Evaluation&Selection.

Analogamente alle altre fasi del processo di progettazione, anche la valutazione e validazione delle alternative progettuali è supportata da tecniche di AI, che si differenziano in funzione del livello di specializzazione e del rigore tecnico richiesti dalla specifica attività progettuale.

Nel caso del design concettuale, si fa riferimento a valutazioni di tipo qualitativo e, quando è possibile tradurre variabili concettuali in valori numerici, anche a valutazioni di tipo quantitativo.

La valutazione qualitativa, in quanto riferita a dimensioni soggettive e astratte, è tradizionalmente affidata al giudizio di designer esperti. Tuttavia, se condotta mediante approcci convenzionali, essa può comportare costi elevati e significative discrepanze tra i valutatori. Tali limiti risultano ulteriormente accentuati quando, come accade nei processi divergenti supportati da AI generativa, viene prodotto un numero elevato di alternative in tempi ridotti. Infatti, in questi casi, ciò che inizialmente costituisce un potenziamento della creatività efficace nella fase di generazione può trasformarsi in un sovraccarico in quella di valutazione. Qualora lo screening venga svolto interamente in modo manuale, lo sforzo e il tempo richiesti per la valutazione aumentano significativamente a causa dell'elevato numero di alternative prodotte, spesso tra loro simili; di conseguenza, risultano maggiori anche i costi associati alla fase convergente.

Per questi motivi, i ricercatori stanno esplorando l'impiego di modelli generativi di grandi dimensioni (LLM) per simulare capacità di valutazione tipicamente umane, in grado di stimare la novità e la qualità dei concept di prodotto, con particolare riferimento agli aspetti estetici e funzionali.

Per quanto riguarda la novità, mentre gli approcci tradizionali calcolano la distanza semantica nello spazio dei concetti, trascurando la complessità contestuale, gli LLM sono in grado di valutare l'originalità in modo contestualmente informato, raggiungendo correlazioni molto elevate con le valutazioni esperte umane (fino a 0,81 di Pearson, contro 0,12–0,26 dei metodi convenzionali). Tali modelli possono inoltre valutare descrizioni testuali e visive del concept e assumere prospettive differenti (ad esempio cliente, product manager o designer), fornendo giudizi più completi. In alternativa, la stessa attività può essere svolta combinando una rete CNN che estrae feature da sketch e immagini, e modelli BERT che svolgono task di NLP per elaborare le descrizioni testuali delle rappresentazioni grafiche, ma in maniera più frammentata.

Per quanto riguarda la valutazione della qualità, l'AI generativa è impiegata per stimare la soddisfazione dei bisogni degli utenti e la fattibilità delle soluzioni, sfruttando varianti multimodali capaci di cogliere le dipendenze e gli aspetti complementari tra caratteristiche visive, funzionali ed emozionali, modellando le relazioni incrociate tra input diversi.

Nonostante l'approccio basato su LLM si sia dimostrato promettente, mostra ancora dei limiti. Da un lato, fatica a cogliere le novità introdotte tra versioni differenti, tendendo a sottovalutare piccole variazioni o a distorcere la valutazione in base allo stile linguistico delle descrizioni. Dall'altro, incontra difficoltà nel gestire decisioni complesse che richiedono il bilanciamento di requisiti spesso in conflitto. Per questi motivi, le attuali tecniche basate su LLM restano poco idonee a garantire valutazioni affidabili e complete senza un elevato grado di supervisione e guida del processo da parte di un designer esperto [196], [189], [189], [212], [164].

Un'altra proposta incentrata su LLM applicato al design concettuale, in un'ottica più integrata e collaborativa è quella rappresentata dal framework Knowledge Augmented Generalizer Specializer (KAGS) [164]. L'LLM, che identifica il motore di ragionamento linguistico centrale, viene proposto in una configurazione in cui è rappresentato da agenti con ruoli diversi, ma che costituiscono istanze dello stesso modello. Tra i ruoli interpretati emergono quello di Generalizer, che si occupa della fase di strutturazione del problema e idea generation, seguendo il framework FBS; Specializer che valuta, critica e rifinisce le idee generate; Scoring Agent che valuta i concept usando criteri pesati, quindi svolgendo una interpretazione simbolico-linguistica guidata da criteri; Infine il Research Agent con RAG che si occupa della ricerca delle informazioni e dei documenti rilevanti, viene impiegato per integrare il contesto informativo e la conoscenza tecnica esterna all'LLM, aumentando l'attendibilità della valutazione e riformulazione del problema.

Per quanto riguarda la valutazione quantitativa, vengono utilizzate tecniche di ML supervisionato tradizionale e reti neurali, addestrate su dati di progetti precedenti, per stimare indicatori quantitativi come ad esempio metriche di sostenibilità, prestazioni funzionali o costi. In [213] viene proposto l'uso di modelli in grado di apprendere la relazione tra variabili di input (dati di processo, di prodotto o di progetto) e output ambientali, così da stimare rapidamente gli impatti senza eseguire ogni volta una LCA completa per ogni modifica del progetto. Le ANN vengono impiegate principalmente per compiti di regressione, cioè per predire valori continui come il Global Warming Potential e le emissioni di CO₂, modellando relazioni fortemente non lineari tra molte variabili di input,

tipiche dei sistemi analizzati con la LCA. Un'altra famiglia di tecniche è rappresentata da Random Forest, Decision Tree, Gradient Boosting e XGBoost anche essi impiegati per la predizione degli impatti ambientali, ma con un valore aggiunto importante, ossia quello di consentire l'analisi dell'importanza delle variabili di input. Questo li rende particolarmente utili non solo per stimare gli impatti, ma anche per capire quali parametri di progetto, materiali o fasi del ciclo di vita contribuiscono maggiormente alle emissioni o agli altri impatti ambientali. In contesti incerti, emerge nuovamente l'uso dell'Adaptive Neuro-Fuzzy Inference System (ANFIS), che combina reti neurali e logica fuzzy. La componente fuzzy permette di rappresentare relazioni vaghe e approssimate, mentre la parte neurale apprende tali relazioni dai dati.

Altri approcci invece impiegano reti neurali profonde per la valutazione del concept tramite metriche semi-quantitative, ossia metriche che tentano di quantificare aspetti qualitativi per rendere il confronto più oggettivo. Secondo questa prospettiva, CNN viene utilizzata per analizzare gli sketch dei concept di design, estraendo feature visive (linee, forme, strutture grafiche); BERT svolge un task di NLP per estrarre informazioni semantiche linguistiche a partire dalle descrizioni dei concept; infine modelli multimodali apprendono come modellare relazioni complesse tra rappresentazioni di progetto (sketch e descrizioni) e giudizi qualitativi forniti da esperti, per poi formulare il problema come una regressione supervisionata, in cui vengono predetti valori continui associati a metriche di design (drawing quality, uniqueness, elegance, usefulness, creativity) [212].

Nelle fasi di design di dettaglio, l'AI si integra con strumenti di simulazione numerica e analisi fisica per la verifica finale dei requisiti, vincoli fisici e delle performance attese. Le valutazioni si basano su simulazioni CFD per fenomeni fluidodinamici e termici, modelli di Multibody Dynamics per l'analisi cinematica e dinamica, e FEM per la verifica strutturale, quando geometria e materiali sono ormai definiti.

I risultati generati dagli strumenti di analisi e simulazione possono essere interpretati da LLM, sia come modelli singoli sia integrati in architetture agentive, nelle quali gestisce in modo autonomo la richiesta degli input e l'acquisizione degli output dei tool dedicati (simulatori, tool CAE ecc.). Modelli vision-language generativi (VLM) ed altre estensioni multimodali allenati su progetti passati consentono di interpretare in maniera simultanea alcuni output grafici e documentali di progettazione, risultanti da processi di ottimizzazione topologica, generative design, disegni tecnici o modelli 3D, fornendo diagnosi e sintesi comparative di alto livello, senza sostituire il giudizio ultimo dell'esperto [189].

Un ultimo ambito riguarda la validazione di mercato, tradizionalmente condotta tramite valutazioni dirette con gli utenti, oggi parzialmente automatizzabile mediante modelli di ML o DL supervisionato. Tali approcci stimano la reazione degli utenti ai concept apprendendo la relazione tra caratteristiche di prodotto e risposte dell'utente, a partire sia da segnali fisiologici (es. ECG), sia da dati testuali provenienti da recensioni online e social media. A partire da questi dati, la rete neurale apprende una funzione di mapping che consente di predire la preferenza implicita dell'utente verso ciascun concept, classificandola in termini di gradimento positivo, neutro o negativo. Il K-means clustering, che svolge un ruolo di supporto, serve esclusivamente a strutturare i dati e a ridurre la complessità prima della fase di predizione vera e propria [214].

In parallelo, si utilizzano architetture di DL supervisionato di tipo regressivo per predire le preferenze estetiche degli utenti, come mostrato in [215] con un caso pratico riferito alla validazione del layout di interfacce utente (UI). Le reti DCNN (DeepCNN) sono impiegate per l'estrazione automatica di feature visive che vengono poi fornite in input a una rete MLP per il compito regressivo, con cui è possibile simulare il giudizio collettivo degli utenti a partire dal rapporto tra numero di "like" e numero di "view" raccolti su piattaforme di design online. Infine, anche modelli di ML tradizionale (Random Forest, XGBoost, LightGBM) rappresentano un'alternativa valida per la predizione del successo commerciale sulla base di dati storici di vendita e delle caratteristiche del prodotto.

La mappatura tra le attività di Concept Evaluation & Selection e i paradigmi di Intelligenza Artificiale è presentata in una versione tabellare alternativa in Appendice D (Tabella D.7).

3.4.2.7. Contestualizzazione dei contributi recenti dell'AI nei domini applicativi della progettazione

La trattazione sviluppata nelle sezioni precedenti ha adottato un approccio volutamente trasversale, finalizzato ad associare paradigmi e tecniche di Intelligenza Artificiale alle attività tipiche delle fasi di design concettuale, architetturale e di dettaglio, mantenendo tale associazione il più possibile indipendente dallo specifico settore applicativo e facendo ricorso, al limite, all'area ingegneristica come riferimento per il design di dettaglio. Tale scelta metodologica ha consentito di delineare una visione comparabile del contributo dell'AI alla progettazione in contesti differenti, ma ha inevitabilmente trascurato le specificità che caratterizzano i singoli ambiti disciplinari.

In particolare, quando l'analisi si sposta dal piano metodologico generale a quello delle applicazioni concrete, emerge con chiarezza come l'efficacia e l'idoneità dei diversi strumenti di AI siano fortemente condizionate dai vincoli propri di ciascun dominio.

In contesti reali, infatti, fattori quali: la natura dei dati disponibili, le possibilità di integrazione di nuovi strumenti con software esistenti, il grado di formalizzazione della conoscenza specifica, i requisiti normativi, di sicurezza o riservatezza possono limitare l'applicabilità di alcuni strumenti associati nella mappatura precedente e rendere indispensabile il ricorso a soluzioni altamente specializzate.

Al fine di evidenziare la natura vincolata delle applicazioni degli strumenti di AI in funzione del dominio, si propongono alcune associazioni esemplificative riferite a specifici ambiti disciplinari, selezionate tra quelle che la letteratura riconosce come potenzialmente promettenti nei rispettivi contesti.

Ingegneria meccanica

Sebbene l'ingegneria sia già stata assunta come riferimento per il Detailed Design nella mappatura generale, essa presenta applicazioni dell'Intelligenza Artificiale ancora più specifiche, soprattutto quando le considerazioni sono svolte nel merito delle singole aree disciplinari, come l'ingegneria meccanica piuttosto che quella elettronica o informatica. In questa sezione viene preso in esame, a titolo esemplificativo, il caso dell'ingegneria meccanica.

In questo campo, gli esempi più classici dimostrano l'impiego di alcuni modelli specificatamente adatti per la feature recognition automatica, il suggerimento e la prioritizzazione delle operazioni da svolgere nella modellazione CAD, il riconoscimento di errori geometrici, l'auto completamento di sketch e feature. Tali applicazioni si basano su tecniche di machine learning o deep learning supervisionato, spesso applicati a task tipici di Computer Vision su geometrie CAD, affiancate da modelli linguistici per migliorare la comprensione delle funzioni e dell'utilizzo di software complessi.

Un utilizzo più all'avanguardia dei modelli linguistici viene mostrato in [199], che introduce una architettura Transformer encoder-decoder attraverso un modello generativo autoregressivo denominato GearFormer che, invece di generare testo come i classici LLM, applica lo stesso principio di modellazione delle parole tramite token, per produrre sequenze di componenti meccanici e delle loro relazioni spaziali, supportando la progettazione di assiemi meccanici complessi, in particolare treni di ingranaggi. Lo strumento opera secondo due modalità: una Explore mode, orientata alla generazione automatica di numerose configurazioni che rispettano vincoli funzionali (quali rapporti di velocità, posizione dell'output e direzione del moto), e una Copilote mode, che supporta la progettazione passo-passo suggerendo il componente successivo e la sua posizione al progettista.

In maniera simile, [200] esplora il potenziale dei LLM nella progettazione di sistemi ingegneristici complessi, estendendo l'idoneità che tipicamente dimostrano per il Conceptual Design anche per fasi più specifiche come System-Level e Detail Design. In questo contesto, gli LLM vengono interpretati come interfacce intelligenti capaci di tradurre intenzioni progettuali espresse in linguaggio naturale in rappresentazioni tecniche strutturate. Nel primo caso studio, relativo alla progettazione di architetture di sistema, un LLM genera regole di configurazione a partire da requisiti funzionali, producendo descrizioni architetture formalizzate tramite diagrammi UML e tradotte in codice Python riutilizzabile e validabile con diversi input.

In un altro caso analizzato invece, l'attenzione si sposta sulla generazione geometrica e sul CAD, dove l'LLM viene impiegato per modificare la geometria di un componente aeronautico (una Turbine Rear Structure) attraverso istruzioni verbali, che vengono tradotte in codice di Knowledge-Based Engineering (KBE). L'aspetto rilevante è

che il modello non genera una semplice rappresentazione grafica, ma produce codice parametrico che interagisce con il kernel CAD e consente, in successione, la generazione automatica di modelli FEM.

Un'ulteriore applicazione riguarda l'ottimizzazione di progetto basata sull'affidabilità (Reliability-Based Design Optimization, RBDO) [217] dove i Large Language Models vengono integrati come alternativa meno costosa ai metodi tradizionali basati su analisi di affidabilità probabilistica, simulazioni Monte Carlo e algoritmi genetici.

L'approccio sfrutta le capacità di In-Context Learning degli LLM come operatori generativi di nuovi punti di progetto all'interno dell'algoritmo di ottimizzazione, guidati da prompt strutturati, contenenti informazioni sulle iterazioni precedenti, sulla funzione obiettivo e sulle penalità di affidabilità. L'LLM opera in un ciclo iterativo simile a quello di un algoritmo evolutivo, con comportamento controllato tramite prompt engineering, seppur mostrando limiti quando applicato a problemi ad alta dimensionalità.

Nel complesso emerge dunque che gli LLM presentano un vantaggio rilevante rispetto ai classici approcci di machine learning per quanto riguarda la capacità di adattarsi rapidamente a nuovi problemi senza richiedere dataset di addestramento specifici. Tuttavia, i risultati prodotti non sono intrinsecamente affidabili e la responsabilità progettuale resta in capo all'essere umano, che deve avvalersi di strumenti di calcolo, simulazione e verifica indipendenti. Inoltre, l'assenza di consapevolezza dei contesti aziendali, normativi e di certificazione ne limita l'uso diretto, in particolare in ambiti critici come quello aerospaziale dove la regolamentazione è molto stringente.

Progettazione software e generazione di nuovo codice

Anche nell'ambito della progettazione software per lo sviluppo di codice, in modo più consolidato rispetto all'ingegneria meccanica, gli LLM vengono riconosciuti per ricoprire un ruolo fondamentale di supporto.

Infatti, in [218] gli LLM vengono utilizzati come generatori di nuove varianti di codice, agendo come operatori di ricombinazione semantica. A partire da versioni precedenti della stessa funzione incluse nel prompt, l'LLM produce nuove implementazioni che esplorano lo spazio dei programmi, sfruttando pattern algoritmici appresi. Le soluzioni generate sono sottoposte a un valutatore deterministico, che ne verifica la correttezza, scartando i programmi non validi. Su questa base opera una componente di AI evolutiva che seleziona i programmi più performanti e li riutilizza per generare nuovi prompt, consentendo un miglioramento cumulativo delle soluzioni.

Un ambito alternativo ma affine riguarda l'uso degli LLM nel dominio della software architecture [181] dove vengono usati come supporto alle decisioni attraverso suggerimenti di alternative basate su pattern comuni, spiegazioni di architetture esistenti e affiancando il progettista anche in attività di reverse engineering e architectural reconstruction. Nel complesso emerge che gli LLM risultano particolarmente adatti ad essere utilizzati nelle fasi iniziali del Software Architecture Life Cycle, nel passaggio dai requisiti alla definizione concettuale dell'architettura e nella generazione di codice, una volta che le specifiche di funzionamento sono note.

Infine, un'altra attività particolarmente importante nel contesto software è il testing, dove un tema critico che spesso viene identificato è quello della test case prioritization (TCP), che, se non svolta efficacemente, può rendere l'esecuzione completa delle test suite troppo costosa in termini di tempo e risorse. Per questi motivi, il lavoro [219] si concentra sull'ordinamento intelligente dei test, confrontando algoritmi evolutivi, come i Genetic Algorithm (GA), e algoritmi di swarm intelligence, rappresentati dall'Ant Colony Optimization (ACO), sulla base di metriche quali Average Percentage of Fault Detected (APFD), tempo di esecuzione e complessità computazionale. I risultati mostrano che ACO ottiene valori di APFD leggermente superiori, soprattutto all'aumentare delle iterazioni, a fronte però di un costo computazionale maggiore, mentre GA converge più rapidamente mantenendo prestazioni di APFD comparabili.

R&S: Scoperta e miglioramento di molecole per i materiali e l'industria farmaceutica

L'articolo [220] affronta il tema della progettazione sostenibile dei materiali attraverso l'uso dell'intelligenza artificiale, concentrandosi sulla rappresentazione latente delle strutture chimiche e sull'idea che la qualità con cui una molecola viene codificata influenzi in modo decisivo la capacità predittiva, soprattutto in contesti caratterizzati da scarsità di dati sperimentali.

Viene presentato un caso studio relativo alla predizione della temperatura di transizione vetrosa (T_g) dei molecular glass formers, proprietà complessa e cruciale perché condiziona direttamente prestazioni meccaniche, termiche e di durabilità dei materiali polimerici. I risultati mostrano che reti neurali addestrate specificamente sulla proprietà di interesse, manifestano prestazioni superiori rispetto a quelle di architetture encoder-decoder basate su LSTM, che risultano invece più adatti per la ricostruzione di strutture, piuttosto che per task di isolamento delle caratteristiche rilevanti, da utilizzare per la predizione successiva di proprietà specifiche come la T_g .

In aggiunta, il paper [221] propone un contributo metodologico innovativo nella progettazione dei materiali, mostrando come un LLM possa essere inserito nel ciclo di ottimizzazione della composizione di leghe metalliche. Senza utilizzare nessun modello fisico esplicito, l'LLM analizza i trend delle simulazioni di dinamica molecolare precedenti per generare nuove composizioni, rispettando vincoli fisici di base appresi. Negli esperimenti condotti sul sistema ternario Fe-Cr-Mn, la *proof of concept* riportata nello studio individua composizioni significativamente migliorative, fino alla lega $\text{Fe}_{71}\text{Cr}_{25}\text{Mn}_4$, caratterizzata da una resistenza di circa 18,7 GPa, corrispondente a un incremento di quasi il 50%.

In questo modo viene dimostrata la capacità degli LLM di cogliere associazioni tra composizione e proprietà utili nei processi di esplorazione molecolari, che grazie alla sua generalizzabilità, risulta estendibile anche ad altri domini di ricerca scientifica.

Un ulteriore studio propone GraphINVENT [222], un modello autoregressivo basato su Graph Neural Networks che costruisce le molecole passo dopo passo come sequenze di azioni discrete, a partire da una trasformazione di ogni molecola del dataset, in una sequenza ordinata di azioni di costruzione, dipendente dall'ordine con cui i nodi vengono visitati. In questo contesto, vengono confrontati due approcci, Breadth-First Search (BFS) e Depth-First Search (DFS), che definiscono l'ordine di visita e costruzione dei nodi durante il processo di training e generazione. I risultati mostrano che l'uso di BFS porta sistematicamente a una percentuale più alta di molecole valide rispetto a DFS e a una migliore copertura dello spazio chimico del dataset di riferimento. Dal punto di vista qualitativo, BFS tende a costruire le molecole in modo più compatto, chiudendo anelli in tempi minori e mantenendo strutture più dense, generando una popolazione più diversificata e più ricca di strutture circolari e sferiche, mentre DFS privilegia l'estensione di catene lunghe.

Nel contesto del Drug Design [223], la generazione molecolare con deep learning viene valutata in base alla capacità di esplorare realmente lo spazio chimico oltre i dati di addestramento, scendendo anche a livello strutturale mediante l'analisi di ring systems (RS) e functional groups (FG), considerati i veri elementi in grado di determinare proprietà, reattività e rilevanza farmacologica delle molecole. Vengono confrontati sette modelli generativi deep, rappresentativi delle principali famiglie architetture: modelli RNN basati su SMILES (CharRNN, REINVENT), autoencoder e GAN sempre su SMILES (VAE, AAE, ORGAN, LatentGAN) e un modello graph-based. REINVENT emerge come il modello con la migliore copertura molecolare complessiva del dataset, mentre la classifica cambia se si considera la copertura dei ring systems o dei functional groups, con AAE migliore sui ring systems e REINVENT dominante sui gruppi funzionali. Il confronto evidenzia che modelli diversi esplorano lo spazio chimico in modi differenti e che i modelli GAN-based tendono a generalizzare peggio in termini di copertura dello spazio chimico, penalizzando l'esplorazione. Al contrario, i modelli RNN e alcuni autoencoder mostrano una maggiore capacità di ricombinare frammenti rari e coprire regioni meno frequenti dello spazio chimico, portando alla conclusione che la scelta del modello deve dipendere dall'obiettivo del task specifico, piuttosto che dall'individuazione di un modello migliore in assoluto.

Nel capitolo successivo, la trattazione verrà riletta attraverso una prospettiva più applicativa, mediante una contestualizzazione degli strumenti di AI utilizzati in casi studio aziendali. Tale impostazione consentirà di superare il livello prevalentemente teorico dell'analisi, mostrando come gli strumenti di intelligenza artificiale vengano effettivamente integrati nei processi di sviluppo prodotto in contesti industriali reali. In alcuni casi, l'esame delle applicazioni permetterà di derivare indicatori quantitativi di prestazione, mettendo in evidenza l'impatto dell'adozione di specifici strumenti di AI in termini di benefici misurabili per le imprese.

4. Applicazione empirica del framework: analisi dei casi studio attraverso la Matrice degli Orientamenti Progettuali (U-oD/S&E-oD)

A questo punto della trattazione, l'obiettivo diventa quello di segnare il passaggio dalla mappatura teorica verso un livello di analisi maggiormente applicativo, fondato sull'esame di casi studio aziendali, che giustificano empiricamente le associazioni tra gli strumenti di intelligenza artificiale e le fasi del processo di progettazione.

L'analisi empirica evidenzia come i casi studio possano essere interpretati come istanze specifiche dei processi di progettazione, dove le associazioni tra strumenti e fasi progettuali vengono considerate in relazione ai domini disciplinari, aspetto che era stato volutamente generalizzato nella mappatura teorica precedente, concepita per essere il più possibile trasversale e valida rispetto a contesti applicativi differenti.

A tale scopo, si è reso necessario introdurre uno strumento di supporto, denominato *Matrice degli Orientamenti Progettuali*, in grado di posizionare i casi di studio in funzione dell'orientamento dello sforzo cognitivo coinvolto nella progettazione di ciascun ambito disciplinare.

Tale orientamento può essere prevalentemente indirizzato, da un lato, verso l'ottimizzazione ingegneristica e la ricerca scientifica, assumendo un'impostazione di tipo tecnico e razionale; dall'altro, può risultare maggiormente orientato alla soddisfazione delle esigenze di interazione dell'utente con il prodotto, coinvolgendo differenti dimensioni cognitive del progettista, quali la creatività e l'intuizione nella comprensione delle dimensioni percettive dell'utilizzatore.

L'adozione del concetto di *orientamenti*, anziché di *categorie*, è coerente con il fatto che i prodotti appartenenti ai rispettivi domini applicativi, difficilmente si collocano in prossimità di uno solo di questi estremi, anzi, più frequentemente essi integrano entrambi gli orientamenti in proporzioni variabili, in funzione delle loro caratteristiche e degli obiettivi progettuali e aziendali specifici.

Una nota importante riguarda il fatto che la matrice è concepita, innanzitutto, come uno spazio di analisi dei processi di progettazione, indipendente dall'adozione di strumenti tecnologici di supporto. In prima istanza, essa intende costituire un riferimento per il posizionamento congiunto dei prodotti e dei processi progettuali sottostanti, in funzione della combinazione di bisogni cognitivi di diversa natura che intervengono nel corso del loro sviluppo. Successivamente, la matrice consente di esaminare la relazione tra gli strumenti di intelligenza artificiale e gli orientamenti progettuali che, nei casi analizzati, tali strumenti contribuiscono ad affiancare.

In questo senso, ai fini della tesi, i casi studio costituiscono il mezzo attraverso cui è possibile motivare l'associazione tra strumenti di intelligenza artificiale e orientamenti progettuali, tenendo conto delle specificità e delle sfumature proprie dei diversi ambiti disciplinari applicativi.

4.1. *Matrice degli Orientamenti Progettuali (U-oD/S&E-oD)*

Prima di esaminare nel dettaglio gli orientamenti che definiscono gli assi della matrice, è utile fare una chiarificazione concettuale per comprenderne appieno il significato. I due assi, User-oriented Design (U-oD) e Science and Engineering-oriented Design (S&E-oD), non sono concepiti per delimitare categorie chiuse e caratterizzate da confini mutuamente esclusivi all'interno di una classificazione rigida dei processi progettuali; essi mirano piuttosto a descrivere una direzione prevalente assunta nel corso dell'attività di progettazione.

Questa direzione riflette due dimensioni complementari:

- Da un lato, riguarda il grado con cui le caratteristiche del prodotto devono rispondere a determinati requisiti, siano essi orientati all'esperienza dell'utente oppure agli aspetti tecnici e al behaviour del sistema. Tale distinzione non è tuttavia netta, poiché le specifiche tecniche di sistema sono spesso definite per produrre effetti sui requisiti esperienziali e funzionali dell'utente e, in altri casi, la progettazione concettuale deve essere sviluppata entro vincoli tecnici stringenti, affinché risulti compatibile con la fase di dettaglio.

Pertanto, tale distinzione si focalizza sulla finalità prevalente con cui una specifica caratteristica del prodotto viene progettata: soddisfare i bisogni di interazione dell'utente o garantire prestazioni tecniche del sistema.

- D'altro canto, rimanda al processo progettuale e alla natura delle facoltà cognitive impiegate dal progettista, rispetto ai quali si intende stimare l'entità dello sforzo progettuale necessario per garantire l'implementazione di quella determinata caratteristica di prodotto, con quella finalità specifica. La natura di tale sforzo cognitivo impegnato può variare sia in funzione delle finalità con cui si vuole garantire una certa caratteristica, sia in funzione del tipo di caratteristica da garantire. A tal proposito, possono verificarsi alcune circostanze che richiedono alcune precisazioni:

Un primo caso consiste nel fatto che, a parità di caratteristica da modellare, se cambia la finalità della progettazione, può cambiare anche la natura dello sforzo cognitivo impiegato, e quindi anche l'orientamento progettuale coinvolto.

Per esempio, considerando come caratteristica di prodotto il cerchione di un'auto, la finalità progettuale può essere quella di rendere il cerchione dotato di forme più creative e all'avanguardia, oppure quello di snellire gli assi per renderlo più leggero, per diminuire complessivamente il peso dell'auto e renderla più efficiente. La stessa caratteristica coinvolge da una parte una facoltà creativa del progettista che punta a migliorare l'appeal estetico del cerchione, soddisfacendo un bisogno di interazione visiva e percettiva dell'utente, dall'altra una facoltà più razionale e ingegneristica del progettista, che vuole ottimizzare il consumo energetico dell'auto. Ne deriva una diversa disposizione rispetto ai due orientamenti progettuali, sebbene si stia trattando la medesima caratteristica di prodotto.

Un'altra possibilità riguarda la circostanza in cui, a parità di finalità da garantire, la natura dello sforzo cognitivo impegnato dal progettista può variare, al variare della caratteristica di prodotto considerata. Ciò avviene perché caratteristiche diverse possono essere razionalizzate in modo differente in funzione degli elementi che le compongono, i quali possono risultare trattabili prevalentemente mediante facoltà creative e intuitive, tipiche della figura del designer, oppure essere affrontabili mediante calcoli e ragionamenti di ottimizzazione.

Per esempio, assumendo come finalità progettuale quella di rendere l'interfaccia di un dispositivo digitale comprensibile, è essenziale che la progettazione si sviluppi su fronti di natura diversa. Da un lato, occorre garantire l'intuitività dell'interfaccia, affinché l'utente comprenda la disposizione delle sezioni e la semantica dei colori adottati, aspetti che sono solitamente curati dai designer. Dall'altro, il miglioramento della risoluzione dello schermo, di competenza ingegneristica, consiste nell'ottimizzazione di aspetti tecnici finalizzati a facilitare la nitidezza visiva. In questo caso variano le caratteristiche di prodotto considerate e, sebbene ad alto livello la finalità ultima resti la stessa, l'entità dello sforzo cognitivo coinvolto cambia.

Considerazioni di questo tipo, che implicano la riconduzione dei casi a orientamenti differenti, risultano ancora più evidenti quando si esaminano caratteristiche diverse di prodotti differenti e, ancor più, quando caratteristiche diverse vengono affrontate in funzione di finalità progettuali differenti.

Questa impostazione consente di collocare la progettazione rispetto alla sua tendenza prevalente, sia questa verso l'utente o verso il sistema, verso l'esperienza o verso l'ottimizzazione, piuttosto che verso l'esplorazione o verso il controllo, oppure lungo combinazioni intermedie di questi estremi.

Proprio la possibilità di riferire i processi a posizionamenti intermedi rispetto agli orientamenti è garantita dall'adozione di assi continui, anziché discreti, definiti mediante una scala ordinale (basso, medio, alto) in cui ciascun livello ammette gradi differenti, con l'intento di descrivere una propensione più che l'appartenenza a categorie fisse.

Ne consegue che un processo di progettazione viene descritto attraverso la matrice in modo tale da:

- Riuscire a semi-quantificare lo sforzo impiegato dal progettista (basso, medio alto) in ciascuna delle due facoltà cognitive rappresentate dagli assi, ammettendo anche aree ibride tra i due orientamenti, con un'attenzione rivolta in parte verso l'utente, in parte verso la dimensione scientifico-ingegneristica.
- Spiegare la dipendenza dell'orientamento progettuale dal mutamento dei vincoli e degli obiettivi aziendali, dalle specifiche caratteristiche del prodotto da sviluppare e dai cambiamenti dell'ambiente circostante. In tal senso, la matrice recepisce il carattere dinamico dell'evoluzione tecnologica, ambientale e organizzativa, riconoscendo che tali trasformazioni possono determinare, nel tempo, una variazione del posizionamento del medesimo processo e prodotto rispetto agli assi considerati.
- Consentire il posizionamento ravvicinato di prodotti appartenenti a domini disciplinari differenti quando essi condividono caratteristiche e finalità progettuali simili. In tal modo, prodotti provenienti da ambiti diversi possono risultare prossimi all'interno della matrice perché riconducibili a livelli comparabili del medesimo orientamento, oppure a combinazioni analoghe dei due orientamenti, pur riferendosi a contesti applicativi distinti. La matrice non è quindi concepita per delimitare aree corrispondenti a domini separati, bensì per mettere in relazione ambiti differenti sulla base di affinità tra caratteristiche e finalità progettuali, che riflettono sforzi cognitivi di progettazione della stessa natura.
- Rappresentarne il livello di progettazione associato, sia questo concettuale, architetturale o di dettaglio. Ciò avviene poiché, in genere, alcune aree della matrice risultano più frequentemente associate a determinati livelli progettuali rispetto ad altri e, di conseguenza, l'inquadramento di un caso al suo interno consente di riconoscerne anche tale dimensione.

In particolare, il design concettuale tende a collocarsi prevalentemente verso la dimensione user-oriented, mentre il design di dettaglio si posiziona più frequentemente lungo l'asse science & engineering-oriented. Il livello architetturale assume invece una posizione intermedia, potendo orientarsi maggiormente verso l'uno o l'altro asse in funzione dell'istanza specifica.

Tali considerazioni devono essere lette tenendo conto della natura del prodotto. Nei prodotti a forte contenuto ingegneristico, anche il design concettuale tende, infatti, ad avvicinarsi maggiormente all'asse S&E-oD rispetto a quanto accade nei prodotti commerciali di largo consumo. Ciò avviene perché alcuni aspetti, come le forme, possono dipendere direttamente da parametri tecnici che, pur essendo sviluppati con maggiore rigore nella fase di progettazione di dettaglio, costituiscono già un vincolo nella fase concettuale. Tuttavia, se il confronto è limitato allo stesso prodotto, la progettazione concettuale si colloca comunque su un livello più user-oriented rispetto alla progettazione di dettaglio corrispondente.

Ne consegue che, anche considerando due casi riferiti a prodotti simili e alla medesima caratteristica da progettare, essi possano collocarsi in posizioni distanti all'interno della matrice, anche lungo orientamenti progettuali diversi, qualora si riferiscano a livelli progettuali distinti.

In alcuni casi può accadere invece che, prodotti con caratteristiche tali da apparire profondamente diversi se considerati nella loro globalità, risultino collocati in posizioni ravvicinate all'interno della matrice, quando analizzati rispetto a specifiche caratteristiche e al medesimo livello progettuale.

Ad esempio, l'automobile, pur essendo nel suo complesso un prodotto di natura prevalentemente ingegneristica, può presentare un livello elevato di user-oriented design (U-oD) quando la progettazione concettuale riguarda caratteristiche relativamente indipendenti dalla dimensione tecnica del prodotto, come il design dei dettagli degli interni. In questi casi, tale progettazione concettuale può

collocarsi nella matrice in prossimità di quella di un prodotto cosmetico, tipicamente associata all'asse user-oriented, nonostante la natura molto diversa dei due prodotti.

Queste differenze sono strettamente connesse alla diversa natura delle caratteristiche trattate e alla diversa finalità dell'intento progettuale associata a ciascun livello, dalla quale, come già discusso, deriva il posizionamento dei casi all'interno della matrice

Tale assetto risulta coerente con l'intenzione di posizionare gli strumenti di intelligenza artificiale sulla matrice. Infatti, l'orientamento del processo progettuale predispone, senza determinarla in modo univoco, la scelta di determinati strumenti di AI rispetto ad altri, implicando che non esiste una corrispondenza rigida tra categorie di processo e tecniche di intelligenza artificiale, ma piuttosto una maggiore o minore coerenza tra specifici strumenti e determinati orientamenti.

In Figura 4.1 è riportata la struttura della matrice, in cui gli orientamenti progettuali sono rappresentati su più livelli e la cui combinazione consente di individuare aree di collocamento, inizialmente riferite ai casi studio e, successivamente, agli strumenti di intelligenza artificiale ad essi associati.




Figura 4.1: Rappresentazione della Matrice degli Orientamenti Progettuali, articolata in livelli ordinali lungo gli assi U-oD e S&E-oD, con quadranti etichettati da lettere per identificare aree di posizionamento.

Con riferimento a ciascuno dei due orientamenti progettuali, è opportuno precisare che, sebbene le scale ordinali definite riflettano, da un lato, l'intensità dello sforzo progettuale investito lungo una specifica facoltà cognitiva del progettista e, dall'altro, il grado con cui le caratteristiche dei prodotti sviluppati devono rispondere a determinate finalità progettuali, tali aspetti vengono solo apparentemente sintetizzati attraverso una scala monodimensionale.

In realtà, essi risultano dalla combinazione di molteplici sotto-fattori, i quali possono essere visti come una rilettura delle tre dimensioni definite da Gero nel modello FBS [122], ma adattate agli orientamenti progettuali della matrice.

In questo senso, ogni livello della scala ordinale rappresentato sugli assi della matrice (basso, medio, alto) può essere interpretato come l'esito aggregato dei contributi di diversi sotto-fattori influenzanti, ciascuno dotato della propria scala di valutazione. Considerati simultaneamente, tali fattori possono inoltre influenzarsi reciprocamente, rendendo il processo di collocamento dei casi intrinsecamente non lineare.

Questa complessità è emersa non solo in relazione al diverso grado di articolazione con cui uno stesso prodotto può essere progettato, anche all'interno del medesimo dominio disciplinare, ma soprattutto nel tentativo di estendere l'analisi a un contesto multi-dominio, nel quale si è reso necessario cogliere sfumature molto diversificate.

Di seguito si procede alla descrizione dei due assi e dei sotto-fattori che concorrono alla loro definizione.

4.1.1. User-oriented Design (U-oD)

La dimensione User-oriented Design (U-oD) rappresenta il livello di intensità con cui l'attività progettuale del designer è guidata dal bisogno cognitivo di rispondere alle esigenze di interazione strutturale (interna e delle forme), funzionale ed esperienziale dell'utente con il prodotto. Essa mira pertanto a quantificare il diverso grado di sforzo cognitivo, di natura sia pratica sia creativa, che il designer investe nel processo di progettazione, quando è guidato da questo scopo.

Tale sforzo cognitivo risulta particolarmente affine al modo di operare di architetti e designer industriali, i quali manifestano la capacità di osservare opere, edifici e prodotti secondo una prospettiva out of the box, più trasversale rispetto alla visione verticalizzata degli ingegneri.

Questa attitudine consente loro di cogliere, in parte in modo intuitivo e in parte sulla base dell'esperienza professionale maturata, le modalità attraverso cui instaurare un contatto efficace con la sfera percettiva dell'utente, riuscendo così a soddisfarne sia i bisogni espliciti sia quelli latenti. In questo senso, la progettazione orientata all'utente contribuisce a guidare l'utente stesso verso la scelta di acquisto o di utilizzo del prodotto.

È opportuno precisare che, i concetti di user e acquirente non coincidono necessariamente, pur potendo talvolta riferirsi alla medesima persona. Tuttavia, ai fini della presente trattazione, entrambi i ruoli sono stati considerati all'interno della terminologia *user-oriented*.

Quando la progettazione viene analizzata secondo questa prospettiva, un concetto che assume un ruolo centrale è quello di interazione. Essa coinvolge tre attori fondamentali: il prodotto, il soggetto che entra in relazione con il prodotto nelle fasi di acquisto, utilizzo e dismissione, e l'ambiente, all'interno del quale queste relazioni si sviluppano. Le scelte progettuali incidono simultaneamente su tutti e tre questi elementi lungo l'intero ciclo di vita del prodotto.

Con riferimento alla dimensione user-oriented, l'attenzione si concentra in particolare sull'interazione tra il soggetto e il prodotto, nonché sulla capacità di quest'ultimo di soddisfare le aspettative che l'utente ripone nell'esperienza di interazione stessa, anche quando queste aspettative si estendono sugli effetti che l'uso del prodotto produce sull'ambiente circostante.

Un progetto di sviluppo prodotto può dunque essere considerato orientato all'utente quando persegue il soddisfacimento di aspettative legate all'interazione con il prodotto lungo tre ambiti principali che costituiscono i tre sotto-fattori chiave dell'asse U-oD:

- Funzionale (F): riguarda la soddisfazione delle aspettative e dei bisogni pratici di uso e di acquisto dell'utente durante l'interazione con il prodotto lungo l'intero ciclo di vita. Esso include l'efficacia delle funzionalità richieste, l'adeguatezza del prezzo, la durabilità, la compatibilità con altri sistemi e l'impatto ambientale. Il fattore funzionale rappresenta quindi il grado con cui la progettazione è orientata a fornire, attraverso il prodotto, una risposta a una necessità pratica concreta.
- Strutturale/Forma (S): si riferisce alla forma del prodotto, alla sua identità visiva e all'armonia complessiva, contribuendo alla riconoscibilità e al valore simbolico attribuito dall'utente. Essa comprende inoltre il grado di integrazione o di modularità dei componenti all'interno dell'architettura interna del sistema, combinando sia aspetti più espressivi, sia più pratici connessi alla configurazione strutturale.
- Esperienziale (E): comprende il piacere percettivo, emozionale e ludico, inteso anche come intrattenimento, ad esempio attraverso meccanismi di gamification, oltre che l'usabilità e l'immediatezza dell'interazione esprimibile in termini di Affordance. Valorizza quindi la dimensione sensoriale, intuitiva e coinvolgente dell'esperienza d'uso e di acquisto, andando oltre la mera funzionalità del prodotto.

Queste tre dimensioni costituiscono i sotto-fattori che concorrono a determinare il livello di orientamento del progetto lungo l'asse User-oriented Design (U-oD) e vengono rappresentate schematicamente in Figura 4.2.




Figura 4.2: Sotto-fattori che determinano l'orientamento U-oD: Funzionale (F), Esperienziale(E) e Strutturale (S).

Si osservi infine che, sebbene tali sottofattori siano qui rappresentati come elementi distinti, essi non possono essere considerati pienamente indipendenti. È infatti ragionevole ritenere che possano esistere relazioni di interdipendenza, potenzialmente osservabili attraverso l'analisi di un insieme sufficientemente ampio di prodotti. Le diverse combinazioni dei tre sotto-fattori che caratterizzano ciascun prodotto potrebbero essere rappresentate in un grafico utile a esplorare come ciascuna dimensione vari in relazione alle altre. Tale possibilità interpretativa non viene tuttavia approfondita in questa sede poiché richiederebbe una specifica validazione empirica, che si rimanda a eventuali sviluppi futuri.

4.1.2. Science & Engineering-oriented Design (S&E-oD)

L'orientamento Science & Engineering-oriented Design (S&E-oD) esprime il grado di sforzo cognitivo di natura scientifico-ingegneristica impiegato nel processo progettuale. Tale orientamento può essere interpretato in modo differente a seconda che si assuma una prospettiva prevalentemente ingegneristica oppure una prospettiva legata alla ricerca scientifica, sia essa di ambito accademico o industriale (R&D).

Questa distinzione dipende non solo dallo stadio di maturità dell'innovazione o del prodotto considerato, ma anche dallo specifico dominio applicativo. In generale, quando le invenzioni si trovano in una fase embrionale, la progettazione riguarda soprattutto ambiti accademici e di ricerca pura; solo successivamente viene individuata un'applicazione, che può tradursi in un prodotto di consumo, in un'applicazione ingegneristica oppure in un output destinato a configurare l'input per ulteriori ricerche scientifiche. Ne consegue che l'applicabilità tende a manifestarsi in fasi più avanzate dell'evoluzione della scoperta e che, in funzione del dominio in cui tale applicabilità prende forma, possono variare sia i percorsi che conducono dall'invenzione al mercato sia gli orientamenti progettuali mobilitati nel processo di traduzione in un'applicazione concreta.

Ad esempio, se a partire da una nuova molecola si intende formulare un nuovo tipo di packaging, il percorso muove dal laboratorio, alla sua declinazione ingegneristica in un nuovo materiale e giunge infine all'integrazione nel packaging di un prodotto di consumo.

In altri casi il punto di partenza può essere la scoperta di un enzima da identificare come ingrediente per lo sviluppo di prodotti cosmetici, senza attraversare la dimensione ingegneristica. Vi sono infine settori nei quali l'avanzamento verso fasi di sviluppo più mature non comporta una netta separazione dalla dimensione scientifica, che continua a orientare in modo determinante le scelte progettuali successive, come nell'industria farmaceutica, dove vincoli normativi e necessità di validazione scientifica mantengono la ricerca come elemento strutturante dell'intero processo.

Sebbene le attività di R&D possano quindi dar luogo a prodotti caratterizzati da un diverso bilanciamento tra dimensione user-oriented e dimensione engineering-oriented, esse condividono in principio un'impostazione procedurale fondata sul rigore, sulla metodologia e sulla validazione, tale per cui la natura dello sforzo cognitivo coinvolto risulta in larga misura affine a quella propria della dimensione puramente ingegneristica.

Per questa ragione, pur trattandosi di concetti non perfettamente sovrapponibili, le attività riconducibili alla ricerca scientifica vengono collocate all'interno del medesimo orientamento progettuale della dimensione

ingegneristica, mantenendo tuttavia apprezzabile la loro distinzione attraverso l'associazione a sotto-fattori determinanti specifici.

Prospettiva ingegneristica

In questo caso l'elemento che guida l'orientamento progettuale si identifica nella complessità del problema ingegneristico, intesa come lo sforzo di risolvere un problema di ottimizzazione vincolata, nel quale una o più funzioni obiettivo, definite da un insieme di variabili progettuali, devono essere massimizzate o minimizzate al fine di garantire determinate prestazioni del prodotto. In questo senso la complessità ingegneristica è determinata dal numero di variabili che costituiscono il problema progettuale, il tipo di relazione che le lega e la rigidità dei vincoli a cui sono soggette.

Nel caso in cui tale ottimizzazione coinvolga più funzioni obiettivo simultaneamente (problema multi-obiettivo), eventualmente tra loro in competizione, la complessità si manifesta anche nella gestione dei trade-off, in cui il miglioramento di una prestazione può avvenire a discapito di un'altra, introducendo ulteriori vincoli di contorno da coinvolgere.

Queste considerazioni si traducono nel fatto che, sul versante ingegneristico, lo sforzo progettuale è determinato principalmente da due sotto-fattori: il behaviour del sistema e il behaviour del componente.

- **Behaviour del sistema (Bs):** rappresenta la complessità ingegneristica strutturale del prodotto, intesa come il livello di ottimizzazione multidisciplinare richiesto per garantire la coerenza funzionale e strutturale tra i componenti che interagiscono all'interno del sistema. Tale complessità cresce all'aumentare del numero di elementi che partecipano all'ottimizzazione complessiva, dove ciascun elemento svolge un ruolo funzionalmente diverso (problema di ottimizzazione multi-obiettivo con obiettivi funzionali differenti).

Questi ruoli possono essere espressi, ad esempio, in termini di strumenti operativi (tool), meccanismi di trasmissione (transmission), unità di generazione di potenza (engine) e sistemi di controllo (control) che devono essere messi tra loro in comunicazione all'interno del sistema (Figura 4.3).




Figura 4.3: Schematizzazione di elementi funzionali distinti che interagiscono all'interno di un sistema per realizzare una funzionalità pratica di livello superiore. Fonte: slide del corso *Gestione dell'innovazione e sviluppo prodotto*, Prof.ssa Francesca Montagna, 2025.

- **Behavior del componente (Bc):** Si riferisce alla complessità ingegneristica interna dei singoli componenti appartenenti al sistema, oppure del singolo elemento qualora questo coincida con l'intero prodotto, circoscritta a uno specifico dominio funzionale (meccanica, elettronica, nautica, ecc.). In altre parole, esprime la complessità matematica del problema di ottimizzazione vincolata, anche multi-obiettivo, quando questo è applicato a un unico componente funzionale.

Queste due dimensioni costituiscono i sotto-fattori che concorrono a determinare il grado di sforzo cognitivo che definisce l'orientamento progettuale lungo l'asse *Science & Engineering-oriented Design (S&E-oD)*, con specifico riferimento alla prospettiva ingegneristica, e vengono rappresentate schematicamente in Figura 4.4.




Figura 4.4: Sotto-fattori che determinano l'orientamento S&E-oD dalla prospettiva ingegneristica: Behaviour del sistema (**Bs**) e Behavior del componente (**Bc**).

Prospettiva della ricerca scientifica (R&D)

In questo contesto, l'intento progettuale può assumere due forme principali: da un lato l'ottimizzazione di un sistema o di una configurazione esistente, dall'altro la generazione di nuove conoscenze attraverso l'esplorazione di soluzioni inedite, dando luogo rispettivamente a forme di innovazione incrementale o radicale.

Lo sforzo progettuale, sia esso orientato all'ottimizzazione sia alla scoperta di nuove soluzioni, può essere interpretato in termini di rigore metodologico impiegato nel processo di progettazione di un nuovo prodotto o concetto. Con tale espressione si intende il grado con cui l'attività di ricerca e sviluppo deve essere condotta in modo sistematico, controllato e affidabile, secondo principi scientifici consolidati, al fine di garantire la validità e l'attendibilità dei risultati.

Analogamente a quanto avviene nel metodo scientifico, il processo richiede l'attraversamento di una serie di fasi sequenziali, ciascuna delle quali deve essere superata con esito positivo. I risultati intermedi devono inoltre soddisfare specifici valori critici di riferimento, definiti in funzione del dominio applicativo, affinché l'intero processo possa essere considerato valido.

Il livello di rigore metodologico richiesto dipende principalmente da due fattori:

- Il numero di fasi che il processo di ricerca deve attraversare, che a sua volta è funzione del grado di novità dell'invenzione. Un'innovazione incrementale, infatti, si fonda su risultati e conoscenze già acquisite e richiede pertanto un numero minore di fasi rispetto a un'innovazione radicale, che invece implica un percorso di ricerca più lungo e complesso, come nel caso della scoperta di un nuovo materiale o di una nuova sostanza.
- Il secondo fattore riguarda il valore critico delle soglie di validazione, che include parametri quali la significatività statistica dei risultati, il rischio accettabile di errore di prima e seconda specie, la dimensione minima del campione o del dataset necessario a garantire la robustezza delle evidenze sperimentali.

Sia il numero di fasi sia la severità delle soglie di validazione dipendono infine dal grado di rigidità dei vincoli regolatori, che a sua volta varia in funzione del dominio applicativo e del livello di rischio associato ai potenziali effetti sull'ambiente o sulle persone. I settori considerati critici presentano infatti vincoli particolarmente stringenti, legati a standard elevati di sicurezza, come avviene ad esempio nei domini farmaceutico e aerospaziale.

Ne consegue che i sotto-fattori che concorrono a determinare il grado di sforzo cognitivo lungo l'orientamento *Science & Engineering-oriented Design (S&E-oD)*, con specifico riferimento alla prospettiva della ricerca, coincidono con le determinanti sopra esposte e graficamente riportate in Figura 4.5.




Figura 4.5: Sotto-fattori che determinano l'orientamento S&E-oD dalla prospettiva scientifica: numero fasi e criticità delle soglie.

4.2. *Analisi dei casi studio aziendali e posizionamento sulla Matrice degli Orientamenti Progettuali*

In questa sezione si intende esaminare la ricerca condotta mediante l'analisi di casi aziendali relativi all'impiego dell'intelligenza artificiale nei processi di progettazione, con particolare attenzione alle fasi divergenti. L'obiettivo è verificare se l'AI generativa, attualmente al centro dell'attenzione nel panorama tecnologico, possa effettivamente sostenere la fase divergente o altre fasi del processo progettuale. È inoltre necessario valutare se altre tecniche di intelligenza artificiale risultino più idonee a tale fase o ad altre, in funzione delle caratteristiche e delle finalità specifiche del prodotto nel relativo dominio applicativo. Un'ulteriore linea di indagine consiste nel verificare se l'idoneità degli strumenti dipenda, oltre che dalla formulazione del problema progettuale, anche dai vincoli propri dei domini associati ai casi. Tale evidenza potrebbe emergere, a livello generale, dalla distribuzione dei casi nella matrice, pur richiedendo successivi approfondimenti settoriali per essere confermata.

Per esaminare i risultati dell'allocazione dei casi sulla matrice e le relative associazioni tra orientamenti progettuali e strumenti di intelligenza artificiale, si farà riferimento alle categorie di collegamento già utilizzate nella mappatura teorica, coincidenti con la tipologia di task (CoA) e il livello di autonomia e ruolo operativo dello strumento (SUP, AUG, AUT). Si considererà che i vincoli di compatibilità di tali strumenti rispetto alla criticità della fase e alla supervisione umana richiesta siano implicitamente garantiti dal fatto che le aziende integrano effettivamente tali strumenti nelle loro pratiche aziendali.

Come già chiarito, indipendentemente dallo strumento impiegato, l'inquadramento nella matrice dipende dalla finalità con cui una caratteristica viene progettata e dalla natura della caratteristica stessa e, quindi, dal tipo di sforzo cognitivo richiesto al progettista nel trattarle. Ne consegue che ciascun caso viene collocato con riferimento a elementi locali del prodotto, e non al prodotto nel suo complesso. Per questo, uno stesso prodotto può risultare associato a punti diversi della matrice se l'analisi considera caratteristiche differenti; prodotti complessivamente dissimili possono risultare vicini, anche lungo il medesimo orientamento, in presenza di caratteristiche o finalità analoghe; e, viceversa, prodotti apparentemente simili possono risultare distanti quando cambiano le caratteristiche o le finalità considerate.

Ciò è ancora più vero quando la matrice viene impiegata anche per analizzare la relazione tra caratteristiche, finalità progettuali e lo strumento di AI associato, poiché lo strumento costituisce una variabile aggiuntiva la cui compatibilità dipende dalle altre due. In particolare, in funzione di come è stato costruito, lo strumento può incidere sul livello e sulla natura dello sforzo cognitivo richiesto per progettare quella caratteristica con quella specifica finalità.

Ciò può comportare che due caratteristiche di prodotto, se considerate in relazione allo strumento di AI impiegato per progettarle, risultino associate a posizioni lievemente diverse rispetto a quelle che emergerebbero senza includere lo strumento nell'analisi. Infatti, pur selezionando lo strumento più idoneo per una data istanza, esso non è in genere concepito per modellare una singola caratteristica di un prodotto specifico, piuttosto, per svolgere diverse tipologie di compiti affini, applicabili anche a caratteristiche differenti di prodotti diversi. Ne

deriva che il grado di specificità dello strumento, legato in parte al tipo di addestramento, può variare sensibilmente, poiché non sempre è previsto un training dedicato e, in alcuni casi, i modelli sono generalisti e riutilizzabili per scopi simili ma non coincidenti.

Di conseguenza, l'AI tende a esaltare sotto-fattori dell'orientamento che possono differire lievemente da quelli richiesti dalle finalità specifiche della progettazione di una certa caratteristica, a cui invece la mente umana si adatterebbe in modo più flessibile.

Questa dinamica risulta ulteriormente accentuata quando si impiegano strumenti di AI differenti per affrontare la stessa istanza progettuale. Infatti, operando secondo logiche diverse, essi tendono necessariamente a mettere in rilievo sotto-fattori distinti.

Di seguito si procede alla presentazione dei casi e delle relative associazioni con le categorie di collegamento adottate per la mappatura teorica (CoA; SUP/AUG/AUT), inquadrandoli rispetto al settore di appartenenza, al livello, alla fase e alla sottofase del processo di progettazione e del contesto di sviluppo prodotto cui fanno riferimento. L'esposizione è organizzata per quadranti della matrice identificati da lettere, come illustrato in Figura 4.1.

4.2.1. Quadrante A e B

I due quadranti A e B, si collocano entrambi in un'area della matrice caratterizzata da un basso livello di U-oD. Nel passaggio da uno all'altro si osserva un incremento del livello di S&E-oD, che passa da basso a medio. In particolare, il quadrante A risulta privo di casi, mentre il quadrante B ospita un unico caso studio, relativo a General Motors.

General Motors

In una collaborazione con Autodesk, gli ingegneri di General Motors hanno applicato la tecnologia di design generativo di Fusion 360 alla progettazione di una nuova staffa del sedile automobilistico. Partendo dalla definizione di obiettivi e vincoli di progetto quali materiale, resistenza meccanica, processi produttivi e limiti di costo, il software, tramite algoritmi evolutivi supportati dal cloud computing, ha generato e valutato simultaneamente oltre 150 alternative progettuali. Queste soluzioni, caratterizzate da geometrie organiche, hanno consentito, al termine del processo progettuale, di convergere verso un unico componente metallico, in sostituzione della staffa tradizionale composta da otto parti saldate.

Il processo ha consentito un'esplorazione progettuale ampia, basata su vincoli realistici di produzione e requisiti prestazionali, lasciando agli ingegneri la decisione finale tra numerose opzioni già ottimizzate e pronte per la produzione.

I risultati dimostrano che il design generativo permette di ottenere soluzioni difficilmente concepibili tramite progettazione manuale, riducendo significativamente i tempi di sviluppo del prodotto. In particolare, la staffa finale risulta realizzata in un unico pezzo di acciaio inossidabile, più leggera del 40% e più resistente del 20% rispetto alla versione precedente.

L'estensione di questo approccio a un numero elevato di componenti all'interno di un veicolo apre prospettive rilevanti in termini di riduzione del peso complessivo, dei costi e dei consumi energetici. Secondo la visione di GM, tali benefici si traducono non solo in un risparmio di carburante e materiali, ma anche in un aumento dell'autonomia dei veicoli elettrici e in una migliore ottimizzazione dello spazio interno.

Nel contesto della progettazione di componenti quali le staffe, il design generativo si affianca frequentemente alla manifattura additiva, assumendo un ruolo complementare. La sinergia tra queste due tecniche, in cui ciascuna abilita e valorizza l'altra, rappresenta una rilevante fonte di creazione di valore per l'industria automobilistica.

Come osserva Kevin Quinn, direttore della Additive Manufacturing di General Motors, in passato il settore era fortemente vincolato da tecnologie produttive tradizionali, come la fresatura e lo stampaggio a iniezione, caratterizzate da costi elevati e da una limitata libertà geometrica. Oggi, invece, la combinazione di design generativo e manifattura additiva consente un'elevata flessibilità di risposta a requisiti sia funzionali sia strutturali

e delle forme, permettendo a un singolo software e a una stampante 3D di realizzare una molteplicità di componenti, incluse strutture organiche e reticolari interne, con investimenti più contenuti.

General Motors		Strumento AI	Fonti
Settore	Manifatturiero per automotive	Generative Design-AI evolutiva	[224] [225]
Fase di prog.	Divergente		
Livello di prog.	Conceptual + High Level System Architecture + Detailed Design		
Sottofase/i	Idea generation, combination, concept visualization e optimization		
CoA	DEV, CNTR		
SUP/AUG/AUT	AUG		

4.2.2. Quadrante C

IBM e Red Hat

IBM, in collaborazione con Red Hat, ha sviluppato Watsonx Code Assistant, un foundation model di AI generativa basato su LLM, progettato specificamente per Red Hat Ansible Lightspeed, strumento open-source di automazione IT per la configurazione di sistemi, la distribuzione di applicazioni e la gestione delle infrastrutture di rete.

Watsonx Code Assistant è finalizzato, in questo contesto, ad aumentare la produttività degli sviluppatori nella creazione e nel refactoring degli Ansible Playbooks, ossia script utilizzati per automatizzare processi IT complessi quali l'installazione di database e infrastrutture, l'aggiornamento software, la configurazione di server e reti, nonché la gestione di sicurezza, backup e permessi. Il modello è addestrato su dati provenienti da Ansible Galaxy e su competenze specialistiche di esperti Red Hat, al fine di garantire suggerimenti coerenti con le best practice aziendali.

Il sistema consente agli utenti di formulare richieste in linguaggio naturale, a partire dalle quali l'AI genera automaticamente il codice Ansible corrispondente. Il codice prodotto può essere verificato, modificato e utilizzato direttamente all'interno dell'ambiente di sviluppo, grazie all'integrazione con Visual Studio Code tramite estensione dedicata. L'AI agisce come assistente alla programmazione, supportando la generazione di codice personalizzabile e facilmente adattabile a diversi domini (cloud, networking, sicurezza, IT service management), la correzione e il miglioramento di script esistenti, l'analisi del funzionamento di playbook già scritti e l'individuazione di contenuti simili a quelli di interesse preesistenti.

I risultati riportati indicano un aumento della produttività nello sviluppo del codice compreso tra il 30% e l'80%, una riduzione fino al 60% del tempo necessario alla scrittura dei playbook e un miglioramento significativo della qualità del codice, con una diminuzione degli errori critici. Inoltre, la soluzione contribuisce ad ampliare l'autonomia degli sviluppatori meno esperti, riducendo la curva di apprendimento.

Nei progetti pilota di IBM, l'adozione dell'AI nella creazione dei playbook ha consentito di automatizzare oltre il 60% dei contenuti, riducendo significativamente l'impegno umano e aumentando la produttività fino al 45%, con benefici anche in termini di tempi di onboarding. Nel settore finanziario, l'automazione basata su Ansible Lightspeed ha inoltre stimato risparmi per 80 milioni di dollari in tre anni.

IBM e Red Hat		Strumento AI	Fonti
Settore	Informatica e sistemi IT	LLM (gen)	[226] [227]
Fase di prog.	Divergente		
Livello di prog.	Detailed Design		
Sottofase/i	Idea combination e concept optimization		
CoA	DEV, CNTR		
SUP/AUG/AUT	SUP		

JetBrains

Analogamente al caso precedente, JetBrains ha annunciato l'introduzione di AI Assistant per la propria suite di IDE, integrando una chatbot basato su intelligenza artificiale generativa che utilizza l'API di OpenAI. Lo strumento supporta gli sviluppatori nella scrittura, comprensione e miglioramento del codice, riconoscendo il contesto del progetto (linguaggi, framework e file) e generando frammenti di codice a partire da prompt in linguaggio naturale. Le funzionalità includono la creazione di funzioni e test, il completamento e il refactoring del codice, l'individuazione di potenziali errori e la spiegazione del comportamento del codice, risultando utile anche per la documentazione tecnica di progetto.

A differenza di casi orientati a codice prevalentemente machine-facing, come Red Hat, l'AI Assistant di JetBrains è impiegato nello sviluppo di software applicativo e di interfacce destinate all'uso da parte di utenti umani, pur rimanendo l'oggetto della progettazione a questo livello essenzialmente tecnico.

Secondo JetBrains, l'AI Assistant rappresenta il prodotto a più rapida crescita dell'azienda, il 77% degli sviluppatori segnala un incremento della produttività e il 55% riporta una maggiore disponibilità di tempo per attività a più alto valore aggiunto. L'integrazione dello strumento ha complessivamente semplificato il processo di sviluppo, rendendo più efficienti le attività di programmazione e problem solving.

JetBrains		Strumento AI	Fonti
Settore	Informatica	LLM (gen)	[228] [229]
Fase di prog.	Divergente		
Livello di prog.	Detailed Design		
Sottofase/i	Idea combination e concept optimization		
CoA	DEV, CNTR		
SUP/AUG/AUT	SUP		

General Electric Aviation

Autodesk Research ha collaborato con GE Aviation nell'ambito del programma europeo Clean Sky 2 per sviluppare componenti di motori a reazione più efficienti e sostenibili attraverso l'impiego congiunto di design generativo e manifattura additiva avanzata. Il progetto, inserito in un programma di ricerca e sviluppo triennale condotto all'interno di un consorzio europeo, mirava a migliorare l'efficienza energetica dei motori riducendo consumi ed emissioni di CO₂ e NO_x, mantenendo al contempo elevate prestazioni in termini di spinta propulsiva per diverse tipologie di velivoli.

L'attività si è concentrata sul Turbine Centre Frame (TCF), un componente critico che collega le turbine a bassa e alta pressione che, fino ad allora, veniva realizzato tramite processi sottrattivi e di formatura caratterizzati da elevati costi energetici e da uno spreco di materiale fino al 95%.

Per superare tali limiti, Autodesk Research ha applicato tecniche di design generativo multi-fisico, progettando una struttura reticolare a doppia conformazione e densità variabile, inserita tra le pareti interne ed esterne del TFC. Questa soluzione ha migliorato il rapporto rigidità/peso, la stabilità e l'isolamento termico tra flussi di gas caldi e freddi.

Dai risultati emerge che, le linee di raffreddamento progettate generativamente sono in grado di garantire una riduzione della pressione del fluido fino al 91% rispetto ai valori di riferimento, confermata sperimentalmente con le simulazioni CFD, che riporta flussi perfettamente bilanciati grazie alle funzioni di vincolo fisico integrate nel design.

Le tecnologie adottate hanno inoltre consentito di ottenere un miglioramento del consumo specifico di carburante, di ridurre l'assieme del TCF da 150 componenti a un unico pezzo monolitico e di passare alla produzione fisica tramite manifattura additiva metallica con stampante 3D, comportando una riduzione dei costi e del peso complessivo del 30% rispetto alla tecnica di fusione tradizionale, con uno spreco di materiale inferiore all'1% che ha dimostrato maggiore sostenibilità rispetto ai metodi precedenti.

Il progetto ha raggiunto il TRL 4 e nel 2022 ha ottenuto l'Autodesk Excellence Award nella categoria Engineering the Impossible for Product Design & Manufacturing.

General Electric Aviation		Strumento AI	Fonti
Settore	Aerospaziale	Generative Design multi-fisico-AI evolutiva	[230]
Fase di prog.	Divergente		
Livello di prog.	Conceptual + High Level System Architecture + Detailed Design		
Sottofase/i	Idea generation, combination, concept visualization e optimization		
CoA	DEV, CNTR		
SUP/AUG/AUT	AUG/SUP		

Tesi su supporto motore per Cessna 172

Nel suo lavoro di ricerca, Santiago Mañé Ubalde propone un approccio metodologico per la progettazione di un supporto motore destinato a un Cessna 172, basato sull'impiego del Generative Design (GD) integrato in Autodesk Fusion 360.

Il metodo ricalca le fasi canoniche della progettazione ingegneristica, sostituendo tuttavia l'iterazione manuale con la generazione automatica di molteplici soluzioni da parte dell'algoritmo.

Il flusso di lavoro si articola nella comprensione del problema strutturale, nella definizione delle geometrie "preserve e obstacle", nell'impostazione di carichi, vincoli e obiettivi prestazionali (massa target pari a 9 kg e fattore di sicurezza minimo di 1,5), nella selezione dei materiali e dei processi produttivi e infine nell'analisi e selezione dei risultati. L'obiettivo principale del GD in questo caso coincide con la massimizzazione della rigidità a parità di vincoli su peso e sicurezza.

L'autore evidenzia tuttavia limiti significativi del software, che consente di modellare esclusivamente carichi e vincoli semplificati, escludendo altri tipi di fenomeni rilevanti quali la fatica, le vibrazioni e i carichi distribuiti. Di conseguenza, l'impiego del GD risulta appropriato soprattutto nelle fasi esplorative e concettuali, più che in quelle di ottimizzazione finale, qualora l'approccio sia rivolto a componenti strutturalmente critici come quelli del settore aeronautico.

Dopo un'ora di calcolo, il sistema ha prodotto 17 soluzioni alternative, derivate da differenti combinazioni di materiali e processi produttivi, molte delle quali non rispettavano pienamente i requisiti di progetto.

La selezione è avvenuta interamente a carico del progettista tramite una matrice di ponderazione basata su tre criteri (peso, fattore di sicurezza ed estetica della forma). La soluzione ritenuta più promettente (Outcome 12), realizzata in alluminio AlSi10Mg, presentava una massa di 9,97 kg e un FoS pari a 4,94 secondo Fusion 360.

Una successiva verifica indipendente mediante analisi agli elementi finiti con ANSYS ha restituito un FoS più realistico pari a 2,23, anche se comunque superiore alla soglia minima richiesta (1,5).

Inoltre, nel caso specifico analizzato, l'applicabilità della manifattura additiva, generalmente considerata una tecnologia produttiva complementare al GD, risulta limitata per componenti complessi e di grandi dimensioni, poiché maggiormente esposta a costi elevati, difetti microstrutturali e tensioni residue interne.

Per questi motivi, l'autore propone un approccio ibrido in cui il GD non sostituisce la progettazione convenzionale, ma funge da strumento di ispirazione formale e strutturale. A tal proposito, le geometrie organiche generate vengono reinterpretate in strutture tubolari in acciaio saldato, più compatibili con i requisiti di producibilità e riparabilità. A partire da uno degli outcome generativi, è stato sviluppato un modello in acciaio AISI 4130 con massa pari a 8,57 kg e FoS di 1,55, risultando strutturalmente valido e più leggero rispetto al design tradizionale.

Il confronto tra tre approcci (tradizionale, solo GD e ibrido) evidenzia che: i tempi di sviluppo del metodo convenzionale e di quello generativo sono sostanzialmente equivalenti (58 ore contro 55 ore), ma con una produttività completamente diversa; infatti, il GD consente la generazione simultanea di 17 concetti progettuali, a fronte di un singolo risultato ottenuto con il metodo classico. Inoltre, i risultati mostrano come il Generative Design produca strutture più efficienti dal punto di vista della distribuzione del materiale e della resistenza, ma non necessariamente più leggere, poiché il software in questa versione genera esclusivamente sezioni solide. Il design ibrido, invece, permette una riduzione di peso dell'ordine del 13% mantenendo livelli di sicurezza accettabili.

Nel complesso, lo studio conferma che il Generative Design rappresenta uno strumento particolarmente efficace per l'esplorazione concettuale e l'individuazione di soluzioni strutturalmente efficienti, ma anche che l'integrazione con metodologie progettuali tradizionali rimane essenziale per garantire fattibilità produttiva, costi sostenibili e adeguata riparabilità del componente.

Tesi su supporto motore per Cessna 172		Strumento AI	Fonti
Settore	Aeronautica	Generative Design-AI evolutiva	[231]
Fase di prog.	Divergente		
Livello di prog.	Conceptual + High Level System Architecture		
Sottofase/i	Idea generation, combination, concept visualization		
CoA	DEV, CNTR		
SUP/AUG/AUT	AUG/SUP		

GKN Aerospace, GKN Fokker, SKF e C3

La tesi si basa su un tirocinio svolto nel 2023 presso GKN Aerospace e analizza il contributo dei metodi di intelligenza artificiale e machine learning nel supporto ai progettisti durante la fase di sviluppo concettuale, in linea con il paradigma Zero Defect tipico dell'industria aerospaziale.

Nell'elaborato si precisa che, al momento del tirocinio, all'interno dell'azienda erano già operative diverse applicazioni avanzate di AI e ML. In particolare, strumenti basati su LLM, quali Office Copilot e GitHub Copilot, vengono impiegati per assistere utenti e sviluppatori nella redazione di testi e nel coding, automatizzando attività ripetitive, suggerendo traduzioni, porzioni di codice e test unitari. Nel coding, ad esempio, questi strumenti combinano e ottimizzano frammenti di codice esistenti per svolgere funzioni note, accelerando le attività e riducendone gli errori commessi, senza operare in modo autonomo poiché interamente guidati dal progettista attraverso i prompt.

Inoltre, l'AI generativa viene impiegata anche nella redazione dei report HSE (Health, Safety, Environment), dove supporta la standardizzazione e il miglioramento della qualità documentale, trasformando dati grezzi in report coerenti e completi e riducendo significativamente i tempi di preparazione.

Un ulteriore esempio è rappresentato dall'utilizzo di OptiSlang, piattaforma che integra tecniche di machine learning e metodi statistici per l'ottimizzazione dei concept. In questo contesto, il ML agisce come modello surrogato delle simulazioni numeriche, supportando la valutazione preliminare delle soluzioni e orientando i cicli di ottimizzazione verso configurazioni più promettenti, bilanciando parametri spesso in conflitto quali peso, resistenza e costi. Questo approccio consente di ridurre i cicli di tentativi ed errori e di accelerare lo sviluppo del prodotto, senza sostituire le simulazioni nella fase di validazione finale.

La tesi include uno studio di benchmarking su diverse aziende per analizzare le tendenze del settore nell'uso dell'intelligenza artificiale. Tra queste, GKN Fokker, SKF e C3.

GKN Fokker, divisione di GKN Aerospace, impiega l'AI per automatizzare l'ottimizzazione nella progettazione dei cablaggi. Attraverso moduli Python e una combinazione di algoritmi di ottimizzazione, design of experiments e machine learning, il sistema instrada i segnali ottimizzando peso, costo e sicurezza. L'AI mantiene un ruolo di supporto decisionale e ha consentito di rendere i processi fino all'80% più rapidi, permettendo l'esplorazione di un numero maggiore di soluzioni in tempi ridotti.

SKF e C3 invece, adottano l'intelligenza artificiale prevalentemente come strumento di supporto all'ottimizzazione dei processi produttivi, più che alle attività di progettazione. Le applicazioni principali riguardano la gestione della qualità, la manutenzione predittiva tramite modelli di machine learning e il miglioramento della produttività documentale e della gestione della conoscenza, con l'obiettivo di rendere le informazioni più accessibili e fruibili tramite LLM interni, con dati confinati all'infrastruttura aziendale. Grazie a questi sistemi, aziende come SKF registrano incrementi di produttività compresi tra il 50% e l'80%, mentre realtà come C3 riportano una riduzione dell'80% dei tempi nei processi di predictable quality, un'accelerazione significativa nell'analisi dei dati di test (risultati in circa 3 minuti) e una diminuzione dei costi grazie alla predizione precoce dei guasti.

GKN Aerospace, GKN Fokker, SKF e C3		Strumento AI	Fonti
Settore	Aerospaziale	Surrogate Model - Machine Learning, algoritmi predittivi, algoritmi di ottimizzazione (valutazione multicriterio, suggerimento nuovi valori)	[232]
Fase di prog.	Divergente		
Livello di prog.	Conceptual /Detailed Design		
Sottofase/i	Concept optimization		
CoA	CNTR		
SUP/AUG/AUT	SUP		
Livello di prog.	Detailed Design→ Coding	LLM (gen)	
Sottofase/i	Idea combination e optimization		
CoA	DEV, CNTR		
SUP/AUG/AUT	SUP		
Fase:	Planning + Progettazione divergente	LLM (gen)	
Livello di prog.	Conceptual/Detailed Design		
Attività	Produttività e reportistica (es. documentazione di progetto, report HSE), gestione e recupero della conoscenza		
CoA	STR, COM		
SUP/AUG/AUT	AUG/SUP		

NASA

Il Generative Design ha mostrato un potenziale rilevante anche nell'ambito dell'esplorazione spaziale. Nel 2018, durante Autodesk University di Las Vegas, il Jet Propulsion Laboratory della NASA ha presentato un prototipo di lander interplanetario progettato generativamente, capace di trasportare carichi scientifici a distanze superiori ai 350 milioni di miglia dalla Terra. Il prototipo, tra le strutture più complesse mai realizzate con questo approccio fino a quel momento, misura circa 2,5 m di diametro e 1 m di altezza.

Il progetto nasce dalla necessità di esplorare ambienti estremi e remoti, come le lune di Giove e Saturno, ritenute, oltre a Marte, tra i luoghi più promettenti per la ricerca di tracce di vita. Tali missioni pongono vincoli ingegneristici stringenti tra cui lunghe distanze, basse temperature, alti livelli di radiazione e soprattutto un requisito critico di riduzione della massa. Infatti, il peso al decollo è uno dei fattori più critici. Ogni chilogrammo di massa ridotto dalla struttura permette di aumentare il carico scientifico utile, relativo agli strumenti e i sensori per la ricerca di vita extraterrestre.

Nel caso del lander del JPL, il metodo è stato applicato sia alla struttura interna di supporto sia alla struttura esterna di collegamento delle gambe al corpo principale. L'impiego del Generative Design ha consentito una rapida esplorazione di soluzioni strutturali leggere e al contempo robuste, ottenendo una riduzione della massa del 35% rispetto ai design convenzionali e comprimendo i tempi di iterazione progettuale da diversi mesi a poche settimane. Tali risultati sono stati raggiunti mantenendo gli elevati requisiti di affidabilità tipici di questo dominio, grazie a un processo interamente guidato dai progettisti e limitato a finalità prettamente esplorative.

NASA		Strumento AI	Fonti
Settore	Aerospaziale	Generative Design-AI evolutiva	[233]
Fase di prog.	Divergente		
Livello di prog.	Conceptual + High Level System Architecture Design		
Sottofase/i	Idea generation, combination, concept visualization		
CoA	DEV, CNTR		
SUP/AUG/AUT	AUG/SUP		

LEO AI

Leo AI è una startup fondata nel 2023 da Maor Farid e Moti Moravia con l'obiettivo di trasformare la progettazione meccanica in un processo centrato sull'intelligenza artificiale. La piattaforma si basa su un Large Mechanical Model (LMM), concettualmente analogo ai LLM, ma addestrato su milioni di prodotti e su componenti meccanici (bulloni, cuscinetti, leve, ecc.) in versione tokenizzata, in modo da risultare in un formato gestibile dall'algoritmo.

Il modello è addestrato su fonti ingegneristiche affidabili (oltre un milione di testi tecnici, articoli e standard), comprende file CAD e integra dati PDM aziendali. È in grado di gestire input multimodali, come descrizioni testuali dei requisiti, schizzi, immagini 2D e modelli CAD 3D, ed è integrato direttamente nell'editor CAD. A partire dagli input, Leo costruisce una rappresentazione interna del componente o dell'assieme, identificandone funzione, vincoli fisici e requisiti DFMA (Design For Manufacturing & Assembly), per poi generare e proporre più soluzioni progettuali coerenti, ottimizzate rispetto ai vincoli di produzione e assemblaggio.

L'obiettivo dello strumento non è supportare direttamente la creatività ingegneristica, quanto automatizzare attività tecniche ripetitive, spesso tediose per i progettisti, quali calcoli, verifica di requisiti funzionali e vincoli produttivi, selezione dei componenti e ottimizzazione di costi e producibilità, consentendo all'ingegnere di concentrarsi sugli aspetti a maggiore contenuto creativo del progetto. Inoltre, fornisce supporto alla conoscenza specialistica rispondendo a domande tecniche del dominio.

Nel settembre 2025 la startup ha completato un round da 9,7 milioni di dollari. Oltre 20.000 ingegneri hanno già utilizzato la piattaforma, che dichiara un'accuratezza del 96%. Secondo Bertrand Sicot, ex CEO di SolidWorks, l'utilizzo di Leo AI può far risparmiare circa 5 ore di lavoro a settimana per ingegnere.

LEO AI		Strumento AI	Fonti
Settore	Ingegneria meccanica	LMM (Large Mechanical Model, gen)	[234] [235]
Fase di prog.	Divergente		
Livello di prog.	High Level System Architecture + Detailed Design		
Sottofase/i	Problem structuring, idea combination, concept visualization		
CoA	STR, DEV, CNTR, COM		
SUP/AUG/AUT	SUP		

Siemens

La divisione industriale di Siemens ha recentemente integrato funzionalità di AI generativa all'interno dei propri software avanzati di progettazione, con l'obiettivo di ampliare significativamente il numero di utenti in grado di interagire con sistemi di simulazione complessi, tramite gli LLM impiegati come interfacce intuitive.

Tra questi sistemi rientra Simcenter, un pacchetto di simulazione consolidato che consente agli ingegneri di modellare con elevata accuratezza il comportamento fisico di prodotti e processi, permettendo la sostituzione di prototipi fisici e banchi prova con digital twin. Nonostante la sua elevata potenza, Simcenter è tradizionalmente riconosciuto per la necessità di una formazione specialistica approfondita, sia per l'utilizzo sia per l'interpretazione dei risultati prodotti. Per ridurre tali barriere, Siemens ha integrato Simcenter con un'interfaccia basata su AI generativa, dando origine a HiSimcenter.

Attraverso un'interfaccia testuale basata su LLM, il sistema può, ad esempio, guidare l'utente nella selezione dello strumento di ingegneria assistita più appropriato per uno specifico compito oppure avviare processi di design generativo maggiormente automatizzati. Tali processi prendono avvio dalla definizione dei requisiti di prodotto, forniti tramite linguaggio naturale attraverso l'interfaccia di prompting, e si concludono con la configurazione ed esecuzione, da parte del progettista, di modelli di simulazione complessi, consentendo un incremento dell'efficienza nella fase di modellazione superiore al 50%.

Un aspetto centrale nello sviluppo del sistema esperto ibrido di Siemens riguarda l'affidabilità e la qualità dei dati. Considerando il ruolo sempre più critico che i dati di addestramento rivestono nello sviluppo di applicazioni basate su AI generativa, l'azienda ha avviato programmi di formazione rivolti a personale selezionato nei principali ambiti ingegneristici, con l'obiettivo di renderlo capace di valutare criticamente la qualità dei dati associati ai diversi compiti prima del loro impiego nell'addestramento dei modelli LLM. Parallelamente, Siemens ha adottato un approccio centralizzato nello sviluppo di HiSimcenter, finalizzato a garantire un rigoroso controllo di qualità sugli output della GenAI e ad assicurare la piena conformità alle politiche aziendali e agli standard ingegneristici interni.

Siemens		Strumento AI	Fonti
Settore	Ingegneria	LLM (gen) + Generative Design-AI evolutiva + simulazioni fisiche	[236]
Fase di prog.	Divergente e Convergente		
Livello di prog.	Detailed Design		
Sottofase/i	Concept optimization, Concept Evaluation e Validation		
CoA	DEV, CNTR, COM		
SUP/AUG/AUT	SUP (LLM), SUP/AUG (GD)		

Evozyne con NVIDIA

Evozyne, una startup biotecnologica statunitense, ha collaborato con NVIDIA, specializzata in AI computing e semiconduttori, per sviluppare il modello ProT-VAE, un sistema di intelligenza artificiale generativa progettato per scoprire proteine innovative.

Utilizzando il framework BioNeMo di NVIDIA, ProT-VAE combina modelli transformer con Variational Autoencoder per generare milioni di sequenze proteiche in pochi secondi. Alterando la posizione degli amminoacidi, questo approccio consente l'esplorazione di funzioni proteiche completamente nuove. I transformer, che sono modelli molto potenti per analizzare delle sequenze di testo, sono stati adattati all'analisi di sequenza di amminoacidi nelle proteine, dove viene sfruttata la loro capacità di catturare pattern complessi e relazioni a lungo raggio nelle sequenze. Invece, nel caso dei VAE, viene impiegata la capacità di generare sequenze simili a quelle di addestramento, ma con variabilità controllata, consentendo la creazione di milioni di varianti proteiche plausibili.

In questo modo si riescono a realizzare nuovi prodotti basati sulla sintesi proteine inedite, elaborate in laboratorio tramite la gen AI. Trattandosi di un settore altamente specifico, e vedendo lo sviluppo prodotto in chiave di innovazione, la progettazione concettuale e di dettaglio di prodotti rilasciati da una azienda biotecnologica come Evozyne, tendono a mescolarsi sotto un'unica disciplina, che poi è quella della ricerca e sviluppo.

Secondo Evozyne, questo metodo ha accelerato il processo di prototipazione da mesi a settimane, facilitando lo sviluppo di proteine con potenziali applicazioni nel trattamento di malattie e nella risoluzione di sfide ambientali.

Evozyne con NVIDIA		Strumento AI	Fonti
Settore	Bioteconologie	Transformer; VAE	[237] [238]
Fase di prog.	Divergente		
Livello di prog.	Detailed Design (R&D)		
Sottofase/i	Problem structuring, idea generation, combination.		
CoA	ID, STR, DEV		
SUP/AUG/AUT	AUG/SUP		

FlecheTech

FlecheTech è una startup svizzera che utilizza l'intelligenza artificiale generativa per progettare in modo rapido schede a circuito stampato (PCB) e renderne disponibili i prototipi. La piattaforma si rivolge a hobbisti, imprenditori e a chiunque abbia bisogno di una PCB personalizzata per un prototipo hardware o per piccole produzioni, anche in assenza di una solida competenza in ingegneria elettronica.

Per raggiungere questo obiettivo, FlecheTech ha perfezionato un LLM pre-addestrato su un ampio database di progetti PCB e relative descrizioni, sviluppando un'interfaccia che consente di interagire in linguaggio naturale. L'utente può così specificare i requisiti funzionali della scheda con richieste del tipo: "Ho bisogno di misurare questo valore fisico", "fai ruotare X alla velocità Y" oppure "comunica con questo protocollo". Il sistema riceve tali input e li traduce automaticamente in soluzioni.

Quando un requisito risulta particolarmente complesso e non immediatamente traducibile in una singola soluzione, viene scomposto in una serie di sotto compiti più semplici, ciascuno risolvibile con un proprio schema funzionale. In questo modo l'insieme delle funzionalità richieste, aggredite una per volta, viene trasformato in un concept di scheda funzionante, direttamente traducibile in un prototipo fisico.

I concept generati possono inoltre essere visualizzati e le loro caratteristiche possono essere combinate tra loro attraverso l'interfaccia dello strumento. Per i progetti più articolati, i clienti hanno la possibilità di richiedere una

revisione del design da parte del team di FlecheTech, che interviene a supporto dell'IA prima di procedere alla realizzazione del prototipo.

Dal punto di vista delle prestazioni, l'azienda dichiara che questo approccio ha ridotto i tempi di progettazione da sei-otto settimane a una media inferiore dell'80% rispetto a quelli richiesti a un progettista umano, con benefici ancora più marcati per gli utenti meno esperti a cui si deve un significativo ampliamento del mercato potenziale. Infine, FlecheTech ottiene inoltre un rilevante vantaggio in termini di costi, poiché il proprio staff non deve interagire direttamente con i clienti per comprendere nel dettaglio le loro esigenze, essendo che gran parte di questo processo viene delegato alla chatbot basata su IA generativa.

FlecheTech		Strumento AI	Fonti
Settore	Elettronica (prototipazione hardware)	LLM (gen)	[236] [239]
Fase di prog.	Divergente		
Livello di prog.	Conceptual, High level system architecture Design		
Sottofase/i	Problem structuring, idea generation, idea combination, concept visualization		
CoA	STR, DEV		
SUP/AUG/AUT	SUP/AUG		

4.2.3. Quadrante D

Eaton

Eaton Corporation plc è un fornitore di soluzioni intelligenti per la gestione dell'energia, con sede a Dublino, attivo in numerosi settori industriali e manifatturieri, tra cui aerospazio, edilizia, data center, mobilità, trasporti e servizi pubblici. L'azienda sviluppa soluzioni che spaziano dai dispositivi elettronici portatili ai veicoli elettrici, fino ai sistemi di comunicazione di emergenza.

Una delle principali criticità affrontate da Eaton riguarda i tempi di sviluppo dei nuovi prodotti, spesso eccessivamente lunghi. I clienti richiedono frequentemente componenti altamente personalizzati, come valvole specifiche per autovetture o nuovi sistemi di illuminazione. Tradizionalmente, la progettazione manuale di soluzioni economicamente sostenibili e conformi ai vincoli produttivi richiede diversi mesi. A ciò si aggiunge la necessità di coordinare competenze multidisciplinari, per rispondere a esigenze specifiche. Ad esempio, la progettazione di un sistema di illuminazione coinvolge ingegneri termici, elettrici, meccanici, ottici e di produzione che richiedono un forte coordinamento per risultare allineati ai nuovi obiettivi. Il tutto è ulteriormente complicato dalla crescente complessità dei prodotti e dai requisiti legati alla sostenibilità.

Per affrontare tali sfide, Eaton ha introdotto tecnologie di intelligenza artificiale generativa nei propri processi di progettazione, con l'obiettivo di accelerare lo sviluppo prodotto mantenendo elevati standard di qualità e prestazioni. L'adozione è avvenuta in modo complementare ai flussi esistenti, nei quali era già integrato il software aPriori negli ambienti CAD/PLM per analisi di costi, producibilità, approvvigionamento e sostenibilità, supportate da componenti di AI deterministica.

In questo contesto, l'AI generativa viene addestrata su un ampio patrimonio di dati storici di progettazione e su informazioni provenienti dai software di simulazione aziendali, inclusi i risultati generati da aPriori. Tali informazioni comprendono simulazioni di costo e producibilità, analisi fisiche (fluidodinamiche, termiche, strutturali) e dell'impatto ambientale. Ne deriva un processo di generazione guidato da criteri produttivi e prestazionali, in cui le soluzioni progettuali risultano coerenti con i successivi processi di fabbricazione.

Attraverso questo approccio, il sistema genera in pochi minuti migliaia di alternative presumibilmente già conformi ai vincoli che verranno successivamente verificati.

Infatti, le soluzioni vengono successivamente valutate mediante aPriori che esegue valutazioni automatiche sui modelli CAD, conducendo analisi numeriche e simulazioni finalizzate alla stima delle variabili sopra menzionate.

Sulla base di tali valutazioni, il sistema supporta il progettista nella selezione automatica delle cinque soluzioni maggiormente promettenti. La validazione finale rimane comunque in capo ai progettisti, che garantiscono il rispetto dei requisiti tecnici e ingegneristici.

In poco tempo, Eaton ha conseguito risultati significativi dalla propria iniziativa come dimostrato da diversi casi d'uso di successo. Tra questi, la riduzione dell'80% della massa di uno scambiatore di calore liquido-aria, la diminuzione del 65% dei tempi di progettazione di un ingranaggio ad alta velocità e la riduzione dell'87% dei tempi di sviluppo di un sistema di illuminazione automatizzato.

Eaton		Strumento AI	Fonti
Settore	Industriale ed Energetico	AI generativa (tipo non spec.), apprende da simulazioni passate	[240]
Fase di prog.	Divergente		
Livello di prog.	Conceptual/detailed Design		
Sottofase/i	Idea generation, combination		
CoA	DEV		
SUP/AUG/AUT	AUG/SUP		
Fase di prog.	Convergente	AI deterministica (tipo non spec.)	
Livello di prog.	Conceptual/detailed Design		
Sottofase/i	Concept evaluation		
CoA	CNTR		
SUP/AUG/AUT	SUP		

Moderna e OpenAI

Moderna, Inc. è un'azienda biotecnologica specializzata nello sviluppo di terapie e vaccini basati sulla tecnologia mRNA, il cui risultato più noto è il vaccino contro il COVID-19. Dal 2023 collabora con OpenAI che tramite i modelli GPT sta contribuendo a trasformare il modo in cui l'azienda opera trasversalmente in tutte le funzioni. Moderna punta a portare sul mercato fino a quindici nuovi prodotti nei prossimi cinque anni, tra cui il vaccino contro il virus respiratorio sinciziale (RSV) e terapie oncologiche personalizzate.

Per raggiungere questi obiettivi, l'azienda ha adottato un approccio people-centric e technology-forward, sperimentando tecnologie in grado di amplificare le capacità di ricercatori e progettisti e di migliorare le performance cliniche.

Il CEO Stéphane Bancel ha manifestato l'intenzione di rivedere e rimodulare ogni processo aziendale, dal legale alla ricerca, dalla produzione alle attività commerciali, in funzione dell'uso dell'AI.

Nell'ambito della ricerca iniziale (Early R&D), Moderna ha sviluppato uno strumento pilota denominato Dose ID, progettato per supportare la verifica dei dosaggi dei vaccini selezionati dal team clinico prima dell'avvio dei trial.

La scelta del dosaggio, infatti, rappresenta una delle decisioni più critiche della sperimentazione clinica, poiché testare numerose combinazioni su larga scala risulterebbe eccessivamente lungo e costoso.

Nelle fasi preliminari, il team clinico raccoglie grandi volumi di dati, inclusi risultati preclinici su modelli animali, dati storici su vaccini analoghi e report di studi precedenti, ma tutte queste informazioni spesso sono distribuite su migliaia di documenti.

Dose ID analizza questi dati per fornire raccomandazioni sui dosaggi più promettenti, estraendo automaticamente le informazioni rilevanti, confrontando i dosaggi già testati e individuando pattern tra dosaggio e risultati clinici. In questo modo, lo strumento consente uno screening preliminare che riduce il numero di combinazioni da portare avanti, giustificando le raccomandazioni sulla base dei dati analizzati, nel rispetto di requisiti di sicurezza e privacy.

L'integrazione dell'AI in Moderna non si è tuttavia limitata a singoli casi d'uso. L'azienda ha avviato un programma volto a incorporare sistematicamente l'intelligenza artificiale generativa nei processi e nelle attività quotidiane, con l'obiettivo di costruire una cultura organizzativa fondata sull'uso diffuso dell'AI. Un primo risultato è stato mChat, un chatbot interno basato sulle API di OpenAI, adottato da oltre l'80% dei dipendenti.

Il team legale è stato il primo ad adottare GPT personalizzati per l'analisi di contratti complessi. Tra le soluzioni introdotte figura Contract Companion GPT, che consente di riassumere in modo chiaro e accurato documenti articolati.

Infine, l'implementazione estesa di ChatGPT Enterprise ha ridotto il tempo dedicato alle attività amministrative, permettendo al personale di concentrarsi su attività a maggiore valore strategico. In pochi mesi sono stati creati oltre 750 GPT personalizzati, con il 40% degli utenti attivi settimanalmente coinvolto nella loro creazione e una media di 120 conversazioni per utente a settimana.

Secondo Brad Miller, CIO di Moderna, il successo dell'iniziativa risiede nel costruire i meccanismi organizzativi e culturali che permettono davvero di adottare la GenAI, mentre il CEO Stéphane Bancel sottolinea come l'uso strategico dell'intelligenza artificiale consenta di ottenere lo stesso impatto sui pazienti che un tempo avrebbe richiesto 100.000 persone, con poche migliaia di dipendenti altamente supportati dalla tecnologia.

Moderna e OpenAI		Strumento AI	Fonti
Settore	Biotecnologie (Bioingegneria) farmaceutiche	LLM (gen)	[241] [242]
Fase di prog.	Convergente		
Livello di prog.	Detailed Design (R&D)		
Sottofase/i	Concept evaluation		
CoA	CNTR		
SUP/AUG/AUT	SUP/AUG		
Fase	Planning	LLM (gen)	
Attività	Analisi contratti, vincoli regolatori		
CoA	ID, STR, COM		
SUP/AUG/AUT	SUP/AUG		

P&G e Basecamp Research

Basecamp Research, leader nella mappatura della biodiversità genetica applicata alla progettazione di proteine tramite intelligenza artificiale, ha collaborato in una partnership con Procter & Gamble (P&G) con l'obiettivo di accelerare lo sviluppo di enzimi ad alte prestazioni per il lavaggio in acqua fredda.

Gli enzimi sono catalizzatori biologici in grado di accelerare le reazioni chimiche negli organismi viventi e di svolgere funzioni essenziali anche in ambienti estremi. Partendo da questa caratteristica, la collaborazione mira a progettare nuovi enzimi che, integrati nei detersivi, consentano di ottenere prestazioni superiori nei lavaggi a freddo, migliorando la rimozione delle macchie da tessuti e superfici. Ciò permetterebbe di ridurre il ricorso all'acqua calda, con benefici diretti in termini di risparmio energetico e riduzione delle emissioni di CO₂.

Il cuore della soluzione sviluppata da Basecamp Research è ZymCTRL, un modello di intelligenza artificiale generativa basato su tecniche di deep learning, progettato specificamente per applicazioni di bioingegneria

enzimatica. Il modello è in grado di generare nuove proteine caratterizzate da proprietà funzionali mirate, integrando conoscenze biologiche di natura sperimentale con rappresentazioni apprese dall'analisi di milioni di sequenze esistenti. Tale approccio consente la progettazione diretta di nuove combinazioni, senza la necessità di partire da una struttura preesistente.

Il funzionamento è concettualmente analogo a quello di un LLM ma applicato alle catene amminoacidiche invece che al testo. Gli amminoacidi vengono trattati come token, il modello apprende le regole e le relazioni della biologia molecolare e propone nuove combinazioni plausibili e funzionali attraverso un approccio interamente data-driven. La piattaforma di Basecamp Research, infatti, si fonda su grandi dataset enzimatici, che includono risorse pubbliche come BRENDA, contenente decine di milioni di sequenze, oltre a dataset proprietari come il BaseGraph e ai dati raccolti direttamente dall'azienda attraverso programmi di esplorazione della biodiversità genetica in collaborazione con paesi ad alta biodiversità.

Questa integrazione di dati eterogenei consente alla piattaforma di progettare enzimi avanzati con funzioni altamente specifiche, ottimizzati per operare in condizioni ambientali molto diverse, dai climi glaciali fino ad ambienti estremi ad alta temperatura, come i geysers.

P&G e Basecamp Research		Strumento AI	Fonti
Settore	Biotechnologie (Bioingegneria)	LLM (gen) per la bioingegneria enzimatica	[243]
Fase di prog.	Divergente		
Livello di prog.	Detailed Design (R&D)		
Sottofase/i	Idea generation e combination		
CoA	ID, STR, DEV		
SUP/AUG/AUT	SUP/AUG		

IBM e Nestlé-materiali

Nestlé R&D, in collaborazione con IBM Research, ha sviluppato uno strumento di intelligenza artificiale generativa per l'identificazione di nuovi materiali per imballaggi ad alta barriera, con l'obiettivo di accelerare l'innovazione mantenendo il rispetto dei requisiti di prodotto in termini di funzionalità, sicurezza alimentare, costo e sostenibilità, trasformando un processo che tradizionalmente può richiedere fino ad anni di ricerca per soddisfare simultaneamente tali vincoli.

A partire dalla costruzione di una base di conoscenza sui materiali esistenti, derivata da fonti pubbliche e proprietarie, i ricercatori hanno addestrato un modello linguistico chimico in grado di apprendere rappresentazioni delle strutture molecolari. Su questa base è stato quindi impiegato il Regression Transformer di IBM Research per modellare la relazione tra le caratteristiche molecolari e le proprietà fisico-chimiche, consentendo di accelerare in modo significativo l'identificazione esplorativa di materiali alternativi.

Il Regression Transformer (RT) di IBM è una variante dell'architettura Transformer, progettata per predire valori continui oltre a token discreti. Pur mantenendo invariata la struttura di base, si distingue dai Transformer classici per l'output numerico e per l'impiego di funzioni di loss di regressione, che consentono di estendere la modellazione sequenziale all'inclusione esplicita di variabili continue, riformulando il processo di predizione alla base della generazione. Le proprietà fisico-chimiche sono rappresentate come token continui all'interno della sequenza, permettendo al modello di apprendere direttamente la relazione struttura-proprietà e, in modo inverso, proprietà target-struttura plausibile. Di conseguenza, il modello predice valori numerici relativi alle proprietà molecolari e genera sequenze di molecole condizionate da tali target, consentendo un'esplorazione dello spazio chimico. Questa capacità risulta cruciale nei problemi di design molecolare, in cui l'obiettivo non è solo generare molecole strutturalmente valide, ma anche caratterizzate da proprietà specifiche.

Nestlé ha integrato il sistema ottenendo un modello capace di proporre materiali inediti per imballaggi, in grado di proteggere prodotti sensibili da umidità, sbalzi termici e ossigeno, la cui applicabilità, tuttavia, richiede una

rivalutazione rispetto a vincoli di costo e riciclabilità che non vengono incorporati nel modello, ma rimangono demandati al design concettuale delle applicazioni concrete e alla successiva verifica e validazione da parte dei progettisti.

IBM e Nestlé-materiali		Strumento AI	Fonti
Settore	Bioteecnologie (Bioingegneria, chimica e materiali)	Regression Transformer (RT)	[244] [245] [246]
Fase di prog.	Divergente		
Livello di prog.	Detailed Design (R&D sui materiali) → applicato a Conceptual Design (imballaggi)		
Sottofase/i	Idea generation, combination		
CoA	ID, DEV		
SUP/AUG/AUT	AUG/SUP		

Moodify

Moodify è una startup tech specializzata nell'applicazione dell'intelligenza artificiale allo sviluppo di aromi e alla modellazione dell'esperienza sensoriale. L'azienda si concentra in particolare su gusto e olfatto, offrendo soluzioni a supporto delle imprese impegnate nella progettazione di fragranze e prodotti alimentari.

Fondata da psicologi cognitivi e ricercatori del Weizmann Institute of Science, che hanno dedicato oltre un decennio allo studio della percezione sensoriale, Moodify nasce con l'obiettivo di integrare informatica avanzata, scienza dei materiali e design delle fragranze nello sviluppo di un software proprietario di comunicazione olfattiva. Nel tempo, l'azienda ha costruito un'infrastruttura basata su un database di circa 1.500 composti odorosi, sviluppato grazie a oltre quindici anni di ricerca e sviluppo accademica.

Questa base dati ha consentito di descrivere gli odori attraverso un linguaggio percettivo brevettato, rendendo possibile la costruzione di una vera e propria mappa digitale dello spazio olfattivo. Su tale infrastruttura si innesta un algoritmo di machine learning, sviluppato e brevettato nel 2018 dal Noam Sobel, che apprende le correlazioni tra molecole, strutture chimiche e risposte olfattive percepite dal cervello umano.

Su questa base tecnologica, Moodify propone due soluzioni, Moodify White e Moodify (Re)formulation, che, pur rispondendo a finalità differenti, condividono l'obiettivo di integrare l'intelligenza artificiale all'interno dei processi di progettazione, a supporto delle aziende impegnate nello sviluppo di aromi e fragranze.

La prima soluzione, Moodify White, oggetto di una collaborazione strutturata con Procter & Gamble nel 2023, consiste in un modello di machine learning specificamente progettato per supportare la progettazione delle fragranze del gruppo e accelerare i processi di sviluppo prodotto, riducendo i tempi di immissione sul mercato. Il modello, di natura predittiva, è concepito per valutare e suggerire combinazioni molecolari finalizzate al controllo dei cattivi odori, intervenendo sulla trasmissione della percezione olfattiva negativa a livello cerebrale per indurre una risposta percettiva neutra o gradevole nel soggetto. Tale capacità si fonda sulle correlazioni apprese in fase di addestramento tra molecole, strutture chimiche e risposte olfattive percepite dal cervello umano. Le formulazioni proposte sono inoltre sviluppate nel rispetto dei vincoli regolatori, garantendo il livello di conformità necessario per una loro integrazione diretta nei prodotti industriali.

Moodify (Re)formulation, invece, si basa sul medesimo modello di machine learning addestrato sul vasto dataset olfattivo proprietario, ma è specificamente orientato al supporto dei processi di riformulazione delle fragranze, ottimizzando le combinazioni di ingredienti rispetto a un insieme di requisiti e vincoli esplicitamente definiti.

La necessità di ricorrere a riformulazioni è comune alle aziende operanti nel settore delle fragranze, che devono confrontarsi con requisiti normativi in continua evoluzione, variazioni nella disponibilità delle materie prime, fluttuazioni dei costi degli ingredienti e mutamenti nelle preferenze dei consumatori. In tale contesto, risulta spesso

cruciale introdurre modifiche compositive preservando al contempo un profilo percettivo coerente con quello originale, al fine di mantenere l'identità olfattiva del prodotto.

L'algoritmo di Moodify (Re)formulation analizza la formulazione esistente e identifica le molecole più idonee a sostituire l'ingrediente da rimpiazzare, generando un insieme di alternative valide. Ciascuna proposta viene valutata in base alla similarità percettiva rispetto alla molecola originale e ottimizzata rispetto ai vincoli definiti, quali i nuovi requisiti regolatori, la disponibilità di inventario delle materie prime e i costi di approvvigionamento, consentendo una riformulazione conforme alle normative e al contempo efficiente dal punto di vista economico e operativo.

Moodify		Strumento AI	Fonti
Settore	Flavor & Fragrance Tech	ML predittivo	[247] [248]
Fase di prog.	Divergente e Convergente		
Livello di prog.	Conceptual Design		
Sottofase/i	Idea combination, concept optimization		
CoA	ID, CNTR		
SUP/AUG/AUT	AUG/SUP		

4.2.4. Quadrante E

Dassault Systèmes

Dassault Systèmes, multinazionale francese specializzata nella progettazione, simulazione e gestione del ciclo di vita di prodotti elettronici complessi destinati all'interazione con l'utente, presenta la metodologia Generative MBSE, una soluzione avanzata che integra strumenti di intelligenza artificiale all'interno di un ambiente collaborativo.

Questo ambiente facilita la comunicazione tra competenze differenti, favorisce l'integrazione e il coordinamento tra progettazione di sistema e di dettaglio e, attraverso una strategia data-driven, guida lo sviluppo del sistema sulla base di insight derivanti sia dalle performance tecniche di prodotti passati sia dai feedback degli utenti.

In particolare, adotta strumenti di intelligenza artificiale eterogenei a supporto di attività specifiche nelle diverse fasi del processo progettuale.

Nella fase di problem definition & structuring, il software viene inizialmente utilizzato per la gestione dei requisiti e della documentazione di sistema, definiti a partire da dati storici di prodotti passati, come log di sensori, dati di utilizzo e segnalazioni di guasto.

Queste informazioni permettono di individuare componenti o funzionalità critiche da risolvere o evitare nel nuovo prodotto. Parallelamente, i dati provenienti dai canali di feedback consentono di identificare le aspettative degli utenti in termini di funzionalità, prestazioni e modalità di interazione, da cui è possibile impostare la definizione di requisiti per il nuovo prodotto. La componente di AI data-driven analizza e categorizza tali informazioni, rendendole utilizzabili in forma strutturata per guidare le successive fasi di progettazione.

Un'altra componente di AI, basata sul reasoning e sull'analisi semantica, consente di formalizzare le correlazioni tra i sistemi tecnici da progettare e le aspettative degli utenti emerse dai feedback, nonché tra i sistemi tecnici e le performance attese.

Il suo utilizzo in questa fase permette di individuare contraddizioni tra prestazioni, affidabilità e usabilità, guidando la definizione di nuovi requisiti finalizzati alla risoluzione di tali trade-off.

Inoltre, le simulazioni intelligenti consentono di esplorare come il sistema si comporterà in varie condizioni, facilitando ai progettisti la possibilità di prevedere e verificare potenziali problemi di interazione tra i componenti,

rilevando in modo precoce eventuali harmful effects da prevenire mediante definizione di appositi requisiti risolutivi.

In aggiunta, modelli generativi grafici e del linguaggio forniscono un contributo allo sviluppo sia della fase divergente, sia di quella convergente, intervenendo a diversi livelli della progettazione, da quella concettuale e architetturale di sistema fino a quella di dettaglio delle singole discipline.

Questi modelli sono impiegati sia per rappresentare modelli funzionali specifici dei singoli componenti (elettrici, software, meccanici), sia per costruire modelli di sistema a livello architetturale, nei quali emergono le interazioni tra moduli. In tale impostazione, i blocchi funzionali risultano espliciti nel loro contenuto e si configurano come moduli white box, consentendo di comprendere il funzionamento interno e di superare l'approccio tradizionale black box che, pur chiarendo le interazioni tra moduli separati, limitava la visibilità degli effetti delle scelte progettuali sui componenti interni.

La fase generativa è inoltre guidata da input che orientano la progettazione in modo coerente con i requisiti del cliente e del sistema, sulla base delle correlazioni apprese sia tra configurazione strutturale e feedback degli utenti, sia tra configurazione strutturale e prestazioni tecniche del sistema.

Infine, anche nelle fasi convergenti l'AI fornisce un supporto decisionale fondamentale. Pur rimanendo la scelta finale al progettista, le simulazioni consentono di osservare il comportamento dei modelli generati, rendendo evidenti malfunzionamenti e incongruenze del sistema.

Parallelamente, la componente di AI semantica supporta la validazione verificando il rispetto dei vincoli derivanti dalle correlazioni apprese tra configurazioni di sistema, bisogni degli utenti e performance tecniche. In caso di non conformità, tali verifiche guidano l'ottimizzazione delle architetture verso soluzioni migliorative.

Il tutto è collocato in un'unica piattaforma MBSE, che offre una rappresentazione condivisa del sistema e consente ai team multidisciplinari una visione collaborativa, in cui le modifiche apportate alle progettazioni di dettaglio si integrano in tempo reale con quelle degli altri domini, all'interno di un'architettura capace di adattarsi dinamicamente ai cambiamenti.

Dassault Systèmes		Strumento AI	Fonti
Settore	Sistemi elettronici complessi (alcuni destinati all'interazione con l'utente)	Reasoning semantico, ML, AI generativa (modelli linguistici e grafici)	[249]
Fase di prog.	Divergente e Convergente		
Livello di prog.	High Level System Architecture e Detailed Design		
Sottofase/i	Problem structuring, Idea generation, combination, concept visualization e optimization		
CoA	ID, STR, DEV, CNTR, COM		
SUP/AUG/AUT	SUP		

4.2.5. Quadrante F

Ferrari e AWS

Negli ultimi anni Ferrari ha avviato un profondo percorso di trasformazione digitale, scegliendo Amazon Web Services come partner tecnologico strategico per potenziare l'infrastruttura IT e le capacità di calcolo, analisi e gestione dei dati.

L'adozione di servizi cloud completamente gestiti, come AWS Fargate, ha permesso di ridurre il costo totale di proprietà dell'infrastruttura dal 70% al 40%, aumentando al contempo scalabilità e affidabilità.

Questa collaborazione ha abilitato l'integrazione di soluzioni avanzate di intelligenza artificiale e machine learning tramite Amazon Bedrock, che offre accesso a diversi foundation model di AI generativa, e Amazon SageMaker, utilizzato per sviluppare e addestrare modelli personalizzati su una base dati comune.

Una delle applicazioni più rilevanti riguarda la personalizzazione delle vetture, elemento chiave dell'esperienza cliente. Attraverso il car configurator, gli utenti possono progettare virtualmente la propria Ferrari scegliendo tra milioni di combinazioni. Lo strumento sfrutta LLM tramite Amazon Bedrock e si integra con Amazon Personalize per suggerimenti personalizzati basati su dati proprietari. Il cliente esplora il modello in 3D e diventa parte attiva della fase di concept combination e visualization, allineando il progetto alle proprie aspettative.

Parallelamente, l'AI supporta anche i processi interni di progettazione, dalle vetture di Formula 1 ai modelli di serie. Nella fase concettuale, i designer sperimentano modelli text-to-image per generare e modificare rapidamente rendering, accelerando l'iterazione creativa. Inoltre, l'AI generativa consente di supportare la conduzione di simulazioni e test virtuali nel cloud, riducendo il ricorso a prototipi fisici e permettendo migliaia di simulazioni in parallelo a costi contenuti.

La collaborazione ha portato risultati concreti per Ferrari che, grazie al car configurator basato su AI ha aumentato i lead di vendita e ridotto del 20% i tempi di configurazione, mentre le simulazioni in cloud hanno portato a una riduzione del 60% dei tempi di test e del 30% dei costi di sviluppo.

Ferrari e AWS		Strumento AI	Fonti
Settore	Automobilistico	AI generativa condizionale, text- to-image	[250]
Fase	Personalizzazione auto		
Livello di prog.	Conceptual Design (configurazione auto clienti)		
Sottofase/i	Idea combination e concept visualization		
CoA	DEV		
SUP/AUG/AUT	SUP/AUG		
Fase di prog.	Divergente	AI generativa condizionale, text- to-image	
Livello di prog.	Conceptual Design (Ideazione designers)		
Sottofase/i	Idea generation, concept visualization		
CoA	DEV		
SUP/AUG/AUT	AUG/SUP		
Fase di prog.	Convergente	AI generativa (non spec.) + ML + strumenti di simulazione e prototipazione virtuale (con dati cloud)	
Livello di prog.	Detailed design (simulazioni)		
Sottofase/i	Concept optimization		
CoA	CNTR		
SUP/AUG/AUT	SUP		

Final Aim e Yamaha Motor

Final Aim e Yamaha Motor hanno combinato competenze complementari in una collaborazione finalizzata allo sviluppo di un prototipo di veicolo elettrico (EV) destinato all'uso agricolo. Da un lato, Yamaha Motor ha apportato la propria esperienza e i propri dati nella progettazione di soluzioni di mobilità ad alte prestazioni; dall'altro, Final Aim ha contribuito con una piattaforma di design avanzata basata su blockchain, in grado di garantire tracciabilità e protezione dei dati tramite smart contract. La sinergia tra le due realtà ha permesso di integrare strumenti di Generative AI e software 3D cloud-based, come Autodesk Fusion, sin dalle prime fasi di design concettuale, consentendo di esplorare rapidamente molteplici alternative progettuali in cui risultassero incorporate funzionalità innovative, un'impronta estetica futuristica, e la coerenza con i vincoli di producibilità e industrializzazione dell'azienda automobilistica.

Nell'ambito della progettazione concettuale, il design degli esterni di un veicolo ad uso agricolo è generalmente orientato al soddisfacimento di requisiti prevalentemente funzionali, più che estetici o esperienziali, soprattutto se confrontato con il design automobilistico, al quale è spesso attribuito un valore simbolico per l'utente. Nel caso del Concept 451, tuttavia, Yamaha Motor ha scelto di valorizzare anche la dimensione estetica, pur mantenendo un approccio progettuale guidato dalle funzionalità da implementare, ricorrendo all'impiego di strumenti di Generative AI per introdurre forme e strutture più audaci.

In realtà, il Concept 451 si inserisce in un'iniziativa più ampia di Yamaha Motor volta allo sviluppo di una piattaforma di prodotto che rende i veicoli elettrici adattabili a settori differenti. La flessibilità della piattaforma, capace di supportare configurazioni di prodotto eterogenee, risulta compatibile, anche in termini di vincoli produttivi, con la natura esplorativa e divergente delle soluzioni generate dall'AI generativa.

A livello operativo, lo strumento è stato impiegato trasversalmente in diverse fasi del processo di sviluppo prodotto, con modalità differenti.

Fin dalla fase di planning, i modelli generativi sono stati utilizzati in modalità text-to-text come strumenti di supporto alla ricerca e alla strutturazione delle informazioni per analizzare dati testuali, sintetizzare insight relativi a trend di settore, bisogni sociali, fattori ambientali e requisiti tecnologici, favorendo una comprensione sfaccettata del contesto agricolo.

A differenza dei processi tradizionali, le attività di ricerca e generazione concettuale si sono svolte in modo fortemente iterativo, grazie all'impiego di prompt che hanno consentito di esplorare e affinare progressivamente il concept.

Nelle fasi di problem structuring e idea generation, l'AI ha contribuito alla definizione dei requisiti funzionali del veicolo a partire dalle informazioni precedentemente elaborate, suggerendo soluzioni coerenti con le esigenze operative del contesto agricolo, quali terreni complessi, condizioni climatiche avverse e utilizzo in aree remote. Tali soluzioni sono state successivamente rese visualizzabili attraverso l'impiego di modalità text-to-image, che ha reso possibile la traduzione dei requisiti funzionali in idee preliminari concrete, ulteriormente raffinate tramite image-to-image. Le descrizioni delle diverse configurazioni e caratteristiche da inserire nella documentazione di progetto sono state infine supportate da image-to-text. Questo approccio ha consentito di affiancare non solo la definizione funzionale del concept, ma anche l'esplorazione creativa delle forme e dell'estetica, permettendo di imprimere una forte identità giovanile e futuristica, in linea con l'obiettivo progettuale di bilanciare dimensione estetica e praticità operativa. Come risultato sono state elaborate più di 2.000 idee progettuali, da cui è emerso un concept di veicolo distintivo e caratterizzato da alta visibilità e capacità di carico.

Nel passaggio dalla fase concettuale alla progettazione tecnica e successivamente al processo produttivo, Yamaha Motor e Final Aim hanno fatto ricorso ad Autodesk Fusion, sfruttandone l'infrastruttura cloud per integrare i dati di processo e ricomporre in modo coerente gli output provenienti dalle fasi di design, ingegneria e produzione. Il software ha consentito di introdurre le modifiche necessarie a garantire la compatibilità dei concept generati dall'AI con la piattaforma EV di Yamaha, facilitando al contempo la collaborazione in tempo reale tra team distribuiti geograficamente.

Il progetto ha portato a una riduzione del 50% dei tempi di planning e concept design, completati in circa tre mesi rispetto ai sei-dodici mesi tipici dei processi tradizionali. L'impiego della Generative AI ha inoltre consentito di generare oltre 2.000 concept in 2-3 settimane, permettendo l'esplorazione parallela di più direzioni progettuali e la combinazione delle caratteristiche più promettenti.

La rapida traduzione tra testo e immagine, e dell'implementazione delle modifiche tramite la modalità image-to-image, ha reso possibile un'iterazione continua sui feedback degli stakeholder, rendendo il processo progettuale più dinamico. Infatti, la disponibilità di visualizzazioni dettagliate fin dalle prime fasi ha migliorato la comunicazione con i clienti e favorito un allineamento tra i team, offrendo un linguaggio condiviso a supporto del coordinamento tra design, ingegneria, marketing e produzione.

Final Aim e Yamaha Motor		Strumento AI	Fonti
Settore	Mobilità elettrica agricola	AI generativa (non spec. ma LLM prob.) text-to-text	[251]
Fase	Planning		
Attività	Ricerca e organizzazione delle informazioni nel contesto		
CoA	ID, STR		
SUP/AUG/AUT	SUP/AUG		
Fase di prog.	Divergente	AI generativa (non spec. ma LLM prob.) text-to-text, text-to-image, image-to-image, image-to-text	
Livello di prog.	Conceptual Design (funzioni, struttura e forme)		
Sottofase/i	Problem Definition&Structuring, Idea generation, combination e concept visualization		
CoA	STR, DEV		
SUP/AUG/AUT	SUP/AUG		

L'Oréal e IBM

L'Oréal e IBM hanno avviato una collaborazione strategica per sviluppare un modello di intelligenza artificiale generativa dedicato alla formulazione degli ingredienti, con l'obiettivo di trasformare i processi di ideazione, ottimizzazione e industrializzazione dei prodotti cosmetici.

La partnership combina la competenza scientifica di L'Oréal nella chimica cosmetica con le tecnologie di AI generativa di IBM, dando vita a uno strumento in grado di generare nuove formulazioni o di ricombinare soluzioni esistenti sulla base degli insight estratti dai dati storici di training, costituiti dal patrimonio di formule e ingredienti accumulato da L'Oréal nel tempo. Il tutto è vincolato all'obiettivo di favorire l'impiego di materie prime sostenibili e di ridurre gli sprechi di energia e materiali lungo l'intero ciclo di sviluppo del prodotto, in linea con il programma "L'Oréal for the Future", che punta a utilizzare entro il 2030 materiali bio-based e derivati dall'economia circolare.

Il modello supporta processi di ideazione e riformulazione guidati dai dati e consente l'ottimizzazione delle formulazioni in funzione della producibilità su larga scala. In questa prospettiva, l'AI non si limita a fornire suggerimenti sulle combinazioni di ingredienti, ma integra direttamente vincoli e parametri progettuali concettuali, quali la sostenibilità delle materie prime, i costi produttivi e le prestazioni funzionali di prodotto.

Si tratta di uno dei primi foundation model esplicitamente adattati al settore cosmetico, collocato all'intersezione tra il rigore della ricerca e sviluppo in chimica e scienza dei materiali e i requisiti funzionali ed esperienziali dei prodotti cosmetici di consumo, in cui la progettazione riflette un equilibrio tra ottimizzazione scientifica e massimizzazione del valore percepito dall'utilizzatore.

L'Oréal e IBM		Strumento AI	Fonti
Settore	Cosmetica	AI generativa (non spec.)	[252]
Fase di prog.	Divergente		
Livello di prog.	Conceptual Design (R&D sulle formulazioni e concezione del prodotto)		
Sottofase/i	Idea generation, combination, concept optimization		
CoA	DEV, CNTR		
SUP/AUG/AUT	SUP/AUG		

Oreo

Le aziende che si occupano di prodotti di consumo alimentare, come quelle operanti nel settore degli snack e dell'industria dolciaria, stanno accelerando la sperimentazione dell'IA in tutta la catena del valore per competere in un mercato sempre più saturo. In questo scenario, Mondelez ha introdotto uno strumento di machine learning (ML) che velocizza l'ottimizzazione e la valutazione delle ricette, accorciando i tempi di sviluppo, dal laboratorio alla produzione. Il sistema nasce nel 2019 dalla collaborazione con la società finlandese Fourkind, acquisita nel 2021 da Thoughtworks, ed è oggi integrato nel flusso di lavoro R&D di Mondelez dove gli scienziati alimentari lo usano per progettare ricette che rispettino specifiche sensoriali e tecniche. Thoughtworks ha descritto pubblicamente l'approccio come un esempio di "IA come catalizzatore creativo" poiché sebbene necessiti di diversi cicli iterativi per completare l'ottimizzazione, consente di accelerare il processo, e di farlo nel rispetto delle aspettative del cliente.

Secondo questa metodologia, vengono forniti al software i requisiti relativi alle variabili da controllare nella composizione degli ingredienti quali gusto, aroma e appearance, in modo che il composto sia in grado di riflettere in ultima istanza l'immagine e la simbologia del brand.

L'algoritmo di machine learning, operando sui dati proprietari dell'azienda, in particolare sulle ricette e sull'ampio patrimonio di conoscenze specialistiche nel settore degli snack, apprende e affina nel tempo le proprie capacità predittive sulla base delle informazioni disponibili. Ciò consente al sistema di suggerire ingredienti da integrare nelle ricette che risultano compatibili con le correlazioni apprese, sia in termini di gusti dei clienti abituali, sia di identità del brand.

Un ulteriore utilizzo dello strumento prevede che le diverse combinazioni generate vengano valutate attraverso parametri e metriche che ne definiscono la conformità rispetto ad altri vincoli e obiettivi. In particolare, la valutazione tiene conto di aspetti quali il costo, la disponibilità degli ingredienti, l'impatto ambientale, il profilo nutrizionale e la fattibilità produttiva.

Questo utilizzo non coincide con la valutazione finale, ma si configura come una fase di screening. In pratica, il modello di machine learning agisce come modello surrogato, con l'obiettivo di ridurre i cicli di validazione e limitare il numero di alternative da sottoporre alla valutazione esperta. La decisione finale resta infatti affidata ai panel sensoriali interni e ai brand steward, responsabili degli assaggi e della selezione della ricetta definitiva.

Inoltre, dall'analisi specifica del caso emerge come Mondelez imponga limiti chiari all'applicazione degli strumenti di AI, qualora vengano impiegati per la generazione di soluzioni eccessivamente divergenti. L'azienda osserva infatti che i consumatori tendono ad accogliere positivamente le novità solo quando queste non si discostano troppo da ciò che è familiare, motivo per cui le estensioni di brand risultano spesso le più apprezzate. Un'ulteriore problematica che è stata osservata riguarda la qualità e la quantità dei dati disponibili. Infatti, nelle fasi iniziali di utilizzo dello strumento, quando il sistema disponeva di un dataset limitato, alcune proposte si sono rivelate fuorvianti. In particolare, l'algoritmo aveva suggerito l'introduzione di ingredienti più economici per ridurre i costi, come il bicarbonato di sodio, generando biscotti che, pur conformi dal punto di vista economico, presentavano un gusto non più gradevole.

Nonostante le criticità riportate, Mondelez afferma che l'utilizzo dello strumento ha ormai raggiunto una massa critica per biscotti e prodotti da forno in Nord America e per le bevande in polvere a livello globale, venendo impiegato in oltre 70 progetti differenti. I risultati includono sia estensioni di linea, come il Golden Oreo Gluten Free, sia l'aggiornamento di ricette di prodotti classici. Nel complesso, l'adozione dello strumento ha consentito di accelerare l'accesso alle fasi di prova pilota o di produzione di un fattore compreso tra quattro e cinque volte, contribuendo inoltre a un incremento delle vendite globali pari al 5,4% rispetto all'anno precedente alla sua introduzione.

Oreo		Strumento AI	Fonti
Settore	Alimentare di consumo	ML predittivo	[253] [254] [255]
Fase di prog.	Convergente		
Livello di prog.	Conceptual Design (R&D, ricette e prodotti)		
Sottofase/i	Concept optimization, Concept Evaluation		
CoA	ID, CNTR		
SUP/AUG/AUT	SUP		

Nestlé (ricette e prodotti)

Un ulteriore caso d'uso in Nestlé, oltre all'impiego del Regression Transformer per la ricerca di nuovi materiali per imballaggi già discusso nel quadrante D, concerne l'adozione dell'intelligenza artificiale nella progettazione concettuale di prodotto, sia a supporto dell'ottimizzazione delle ricette in ambito R&D, sia per l'abilitazione dell'idea generation di concept innovativi.

Nel primo caso, vengono adottati strumenti di machine learning a scopo predittivo, utilizzati come modelli surrogati ai tradizionali cicli di validazione sperimentale, per valutare le ricette rispetto a molteplici variabili con cui si identificano gli obiettivi progettuali.

Il sistema supporta i progettisti nel valutare il bilanciamento tra combinazioni di ingredienti, profili nutrizionali, costi e criteri di sostenibilità, preservando al contempo gli standard qualitativi e le preferenze dei consumatori, e suggerendo modifiche mirate quali sostituzioni di ingredienti, aggiustamenti percentuali e riformulazioni, con cui guidare gli step divergenti delle iterazioni successive di ottimizzazione.

Nel secondo caso, Nestlé impiega uno strumento proprietario di Intelligenza Artificiale generativa integrato nel processo di innovazione di prodotto end-to-end. La tecnologia svolge un ruolo chiave nelle fasi iniziali della concettualizzazione, accelerando la generazione di idee che risultano guidate dagli insight raccolti.

Tali strumenti, infatti, vengono utilizzati dall'azienda anche a supporto della fase di pianificazione, che precede la definizione dei concept di prodotto, permettendo di analizzare e sintetizzare insight sui consumatori, individuare nuovi trend di mercato e integrare il know-how aziendale congiuntamente con i valori cardine del brand, abilitando un processo di sviluppo guidato dai dati. L'obiettivo è rendere il processo decisionale più informato, riducendo al contempo il tempo dedicato ad attività manuali e ripetitive, come la ricerca di informazioni e la produzione di documenti di sintesi. Lo strumento impiegato a tal fine è NesGPT, un modello linguistico generativo proprietario, ispirato a ChatGPT e progettato per fornire supporto ai team all'interno di un ambiente sicuro. A partire da pochi prompt, il sistema è in grado di fornire ai team un'ampia gamma di informazioni e proposte creative di concept, guidate dai dati provenienti da numerosi brand di Nestlé USA e dai trend emersi dalla fase di planning. Test interni indicano una riduzione dei tempi di sviluppo del processo che include tali attività da circa sei mesi a sei settimane rispetto agli approcci tradizionali.

Nestlé (ricette e prodotti)		Strumento AI	Fonti
Settore	Industria alimentare	ML predittivo	[244] [245]
Fase di prog.	Convergente		
Livello di prog.	Conceptual Design (R&D, ricette)		
Sottofase/i	Concept optimization		
CoA	CNTR		
SUP/AUG/AUT	SUP		

Fase di prog.	Divergente	AI generativa (non spec, ma LLM probab.)	[244] [245]
Livello di prog.	Conceptual Design (prodotto)		
Sottofase/i	Idea generation		
CoA	DEV		
SUP/AUG/AUT	SUP/AUG		

Colgate-Palmolive

Colgate-Palmolive è un'azienda di beni di consumo storicamente orientata all'analisi dei dati, che da anni utilizza l'intelligenza artificiale analitica e il machine learning tradizionale per attività predittive come pricing, promozioni, assortimento, valutazione dell'efficacia di marketing e media. Come molte grandi imprese, ha recentemente integrato anche la Generative AI, con l'obiettivo di aumentare la produttività interna e stimolare la creatività nello sviluppo di nuovi prodotti.

All'interno dell'azienda, l'intelligenza artificiale generativa è oggi impiegata in diverse fasi del processo di sviluppo prodotto, a partire dal planning, dove viene utilizzata per sintetizzare insight sui consumatori derivanti dall'elaborazione del patrimonio informativo aziendale globale, integrato con fonti esterne autorevoli, e per fornire risposte rapide a quesiti di business.

I team utilizzano grandi modelli linguistici (LLM) supportati da sistemi di Retrieval-Augmented Generation (RAG), che combinano dati proprietari con trend di ricerca di Google, dati sindacati e fonti specializzate, in un approccio che consente di ridurre significativamente il rischio di allucinazioni tipico dei modelli generativi.

In tal modo, i dipendenti possono interrogare grandi volumi di dati in linguaggio naturale e ottenere risposte rapide, documentate e riferite a fonti specifiche, senza la necessità di analizzare manualmente i report.

Un ulteriore ambito di applicazione riguarda l'impiego della Generative AI nelle fasi creative del processo. Come sottolineato da Kli Pappas, Senior Director of Predictive Analytics e Global Head of AI, l'obiettivo non è unicamente l'aumento dell'efficienza, ma la crescita del business attraverso l'innovazione. In questo contesto, l'intelligenza artificiale risulta utile sia nell'individuazione di bisogni dei consumatori non ancora soddisfatti, sia nella generazione rapida di nuovi concept di prodotto, producendo testi e immagini che ampliano il numero di alternative progettuali da portare avanti.

Infine, un'altra applicazione di rilievo riguarda l'impiego dei Digital Consumer Twins, modelli digitali basati su sistemi predittivi che simulano il comportamento dei consumatori e le loro potenziali reazioni a nuovi prodotti a partire dai dati storici di lanci precedenti. Questi strumenti consentono di valutare rapidamente un numero molto più ampio di proposte, pur richiedendo una successiva validazione tramite test con consumatori reali, e risultano particolarmente efficaci nelle prime iterazioni del processo di sviluppo.

Colgate-Palmolive		Strumento AI	Fonti
Settore	Prodotti di consumo	LLM (gen) + RAG	[256]
Fase	Planning		
Attività	Ricerca e organizzazione delle informazioni nel contesto (trend e bisogni consumatori)		
CoA	ID, STR		
SUP/AUG/AUT	SUP/AUG		

Fase di prog.	Divergente	LLM (gen) + RAG	[256]
Livello di prog.	Conceptual Design		
Sottofase/i	Idea generation, combination e concept visualization		
CoA	DEV		
SUP/AUG/AUT	SUP/AUG		

Estée Lauder

Estée Lauder Companies (ELC) e Microsoft hanno creato un AI Innovation Lab come estensione della loro collaborazione strategica, con l'obiettivo di sviluppare strumenti di intelligenza artificiale generativa basati su Microsoft Azure OpenAI Service in grado di supportare i team interni nell'individuazione e nell'interpretazione più rapida delle tendenze di mercato, orientando lo sviluppo dei prodotti verso le preferenze dei clienti e consentendo, da un lato, una riduzione del time to market e, dall'altro, il rispetto dei requisiti locali dei marchi di bellezza di lusso di ELC.

L'AI Innovation Lab è focalizzato sullo sviluppo di diversi casi d'uso di intelligenza artificiale generativa, da applicare in molteplici aree del business con l'obiettivo di trasformare l'intero processo di sviluppo prodotto dell'industria della bellezza. In questa prospettiva, Estée Lauder Companies ha previsto la possibilità per i propri team di sviluppare modelli GPT personalizzati, addestrati su dati proprietari, ciascuno progettato per rispondere a specifiche esigenze operative e strategiche.

Per esempio, nel dipartimento di ricerca e sviluppo, questi strumenti consentono di analizzare in tempi ridotti gli effetti di nuove combinazioni di ingredienti. Con il Clinical Trial GPT, progettato per analizzare report clinici e dati di efficacia delle formulazioni, il sistema esamina documenti di trial, studi sugli ingredienti e metriche come idratazione, reazioni cutanee o tossicità, estraendo le informazioni rilevanti e generando sintesi utili alla rapida valutazione dei nuovi prodotti di lancio.

Nella pianificazione strategica invece, è stato elaborato ConsumerIQ, un agente conversazionale che interpreta grafici, immagini e dataset complessi, analizza report di mercato, studi sui consumatori e documenti interni per individuare trend emergenti e fornire raccomandazioni strategiche basate sui dati.

Infine, un'ulteriore applicazione di questi strumenti è stata dedicata al supporto della fase di idea generation, attraverso un GPT progettato per la scoperta di ingredienti e per l'elaborazione di formulazioni guidate dalle tendenze emerse dalla raccolta dati.

Tuttavia, ELC non si limita all'uso di modelli preconfigurati, ma consente ai team di creare agenti AI personalizzati tramite Copilot Studio per automatizzare task ripetitivi e standardizzati all'interno delle varie funzioni aziendali.

Questa sperimentazione è incoraggiata anche attraverso gli AI Ideathons, eventi interni in cui i dipendenti progettano nuovi agenti AI applicati a problemi reali, favorendo l'avanzamento tecnologico interno.

In conclusione, il caso di Estée Lauder Companies mostra come le generative AI venga utilizzata principalmente come strumento di supporto alla raccolta e all'analisi dei dati, alla pianificazione strategica e all'automazione di attività ripetitive e standardizzate tramite assistenti e agenti specializzati. Il suo contributo ai processi di ideazione rimane secondario e, piuttosto che assumere un ruolo esplorativo o creativo in senso pieno, ha come obiettivo principale l'aumento dell'efficienza e della rapidità operativa, che riflette una scelta strategica legata alla dimensione dell'impresa e alla sua collocazione nell'ambiente competitivo.

Infatti, nel contesto in cui l'impresa opera, caratterizzato dalla continua emergenza di nuove startup, la riduzione del time to market diventa un fattore cruciale. Per un'azienda consolidata come ELC, questa velocità è resa possibile dalla capacità di elaborare rapidamente il patrimonio di dati raccolti nel tempo e nei diversi mercati, che guida lo sviluppo di prodotti mirati ai bisogni dei consumatori e rappresenta un asset strategico in grado di generare vantaggio competitivo se adeguatamente valorizzato.

In questo senso, la Generative AI si configura come il mezzo attraverso cui il patrimonio informativo aziendale viene tradotto in valore aggiunto, potenziando l'efficienza delle attività che compongono il processo di sviluppo del prodotto e mantenendo al contempo l'allineamento con le preferenze dei consumatori. I risultati ottenuti mostrano come analisi che in precedenza richiedevano settimane vengano oggi completate in pochi minuti, con un impatto significativo sull'intera tempistica di sviluppo di nuovi prodotti.

Estée Lauder		Strumento AI	Fonti
Settore	Cosmetica	LLM (gen), Agent AI- LLM based	[257] [258]
Fase	Planning		
Attività	Analisi dei documenti e dei dati raccolti (trend di mercato e preferenze dei consumatori) e raccomandazioni strategiche		
CoA	ID, STR, DEV, CNTR, COM		
SUP/AUG/AUT	AUG/SUP		
Fase di prog.	Divergente	LLM (gen)	
Livello di prog.	Conceptual Design (R&D)		
Sottofase/i	Idea generation		
CoA	STR, DEV		
SUP/AUG/AUT	AUG/SUP		
Fase di prog.	Convergente	LLM (gen)	
Livello di prog.	Conceptual + Detailed Design (R&D)		
Sottofase/i	Concept Evaluation		
CoA	STR, CNTR		
SUP/AUG/AUT	SUP		
Attività	Task di produttività automatizzati per ciascuna funzione aziendale (productivity)	Agent AI-LLM based	
SUP/AUG/AUT	AUT		

4.2.6. Quadrante G

Figma

Negli ultimi anni, gli strumenti di intelligenza artificiale stanno trasformando il modo in cui le idee vengono generate, modificate e comunicate sul piano visivo. In questo contesto, Figma AI si distingue come piattaforma di design collaborativo che integra creatività e automazione, rivolta principalmente a designer e sviluppatori di interfacce digitali. Grazie all'integrazione con i modelli di intelligenza artificiale generativa di Google Gemini Image, consente di creare e modificare immagini direttamente a partire da prompt testuali, accelerando il processo creativo e garantendo coerenza stilistica all'interno del progetto.

Gemini Image, introdotto con la versione Gemini 2.5 Flash Image (agosto 2025), rappresenta un'evoluzione significativa rispetto alle precedenti versioni del modello, che erano limitate alla generazione testuale e orientate soprattutto ad analisi, ragionamento e supporto alla programmazione. Con questa release, il modello acquisisce per la prima volta la capacità di generare e modificare immagini, stimolando la creatività e permettendo di iterare sui contenuti visivi, testare stili alternativi e supportare efficacemente la fase di concept visualization fino alla definizione dell'immagine finale. Le nuove funzionalità introdotte in questa versione consentono di combinare più immagini, mantenere la coerenza dei personaggi e dello stile visivo tra diverse generazioni ed eseguire operazioni di editing tramite linguaggio naturale. In questo modo, il processo di modifica diventa conversazionale e

immediato, eliminando la necessità di intervenire manualmente su ogni singola variazione all'interno degli schizzi prodotti.

Inoltre, Figma non si limita a offrire strumenti per il design estetico, ma si configura come una piattaforma collaborativa capace di supportare anche sviluppatori e programmatori nella progettazione semplificata di interfacce digitali interattive. La piattaforma consente di concepire interfacce utente (UI) per applicazioni web e mobile, esperienze utente (UX) attraverso flussi, wireframe e prototipi interattivi. In alcuni casi, permette inoltre di modellare aspetti legati alla logica di funzionamento di un'applicazione o di un software mediante strumenti dedicati.

Un esempio recente è Figma Make, uno strumento “prompt-to-code” che consente di implementare codice funzionante a partire da prompt espressi in linguaggio naturale relativi alle funzionalità che il prodotto digitale deve soddisfare.

Per comprendere le aspettative attuali e future di designer e sviluppatori rispetto all'integrazione dell'intelligenza artificiale nei workflow di progettazione, Figma ha condotto un'indagine tra i propri utenti, i cui risultati sono confluiti nel Figma 2025 AI Report, basato su un campione globale di 2.500 rispondenti.

I dati evidenziano come l'AI venga impiegata prevalentemente nelle fasi di ricerca e analisi, più che in quelle strettamente creative. Durante la fase di discovery, il 38% dei designer e il 43% degli sviluppatori la utilizza per attività di desk research, mentre rispettivamente il 40% e il 29% la impiegano per l'analisi dei dati sugli utenti. Nell'ambito del design, il 33% dei designer ricorre all'AI per la generazione di concetti visivi, il 22% per la creazione di bozze e il 21% per l'esplorazione di layout. Gli sviluppatori mostrano complessivamente livelli di adozione più elevati lungo l'intero workflow, con un impatto medio percepito sulla produttività (51%), sulla collaborazione (51%) e sullo sviluppo (59%).

Dal punto di vista dell'efficienza e della qualità, il 78% dei rispondenti riconosce che l'AI contribuisce ad aumentare l'efficienza del lavoro, mentre solo il 58% ritiene che migliori in modo significativo la qualità dei risultati. Il divario tra le due professioni è marcato, il 68% degli sviluppatori valuta positivamente l'impatto qualitativo dell'AI, contro appena il 40% dei designer. Inoltre, meno della metà degli intervistati ritiene che l'AI li renda complessivamente migliori nel proprio ruolo, a conferma del fatto che la supervisione e il giudizio umano restano elementi imprescindibili.

Infine, sul piano formativo, l'85% di designer e sviluppatori considera fondamentale acquisire competenze sull'uso dell'AI in prospettiva futura. Tuttavia, solo il 27% prevede un impatto significativo sugli obiettivi aziendali nel breve periodo e appena il 15% lo giudica realmente trasformativo. Nel complesso, il quadro restituisce l'immagine di una fase di adozione in cui l'AI è percepita nei processi di progettazione soprattutto come uno strumento di supporto operativo e di incremento dell'efficienza, evidenziando una diffusa e ancora limitata consapevolezza del suo potenziale trasformativo.

Figma		Strumento AI	Fonti
Settore	UI/UX e prodotti digitali	Foundation Model Multimodale (Transformer based)	[259] [260] [261]
Fase di prog.	Divergente		
Livello di prog.	Conceptual Design		
Sottofase/i	Idea generation, combination e concept visualization		
CoA	DEV, COM		
SUP/AUG/AUT	AUG/SUP		

Kia Global Design

A partire dal 2022, Kia Global Design ha collaborato per un anno con Autodesk Research allo sviluppo di un prototipo di strumento di intelligenza artificiale generativa per la progettazione concettuale dei cerchi delle auto. Il progetto è nato da una serie di incontri con i designer per comprendere in profondità i loro workflow e integrare lo strumento nelle pratiche progettuali.

Dalle interviste è emerso che la fase più critica è quella di ideazione preliminare, spesso caratterizzata da un blocco creativo iniziale in cui i designer devono essere in grado di bilanciare innovazione e continuità stilistica. In questo contesto l'AI si rivela utile come strumento di ispirazione, capace di generare rapidamente un ampio numero di proposte visive.

Lo strumento sviluppato si basa su Versatile Diffusion, un modello di diffusione open-source che integra input testuali, schizzi e riferimenti visivi. A differenza dei modelli di diffusione tradizionali, come Stable Diffusion, limitati al text-to-image, Versatile Diffusion è detto versatile perché supporta sia text-to-image sia image-to-image, consentendo anche l'editing e le trasformazioni tra immagini diverse.

All'avvio di un nuovo progetto, i designer definiscono una serie di parole chiave in grado di guidare il concetto di prodotto, insieme a materiali visivi di riferimento, come immagini o progetti esistenti coerenti con tale concept, con l'obiettivo di generare una serie di schizzi utili a selezionare rapidamente le idee più promettenti.

Con l'obiettivo di inserirsi in modo compatibile all'interno di questo processo operativo, lo strumento richiede inizialmente al designer l'inserimento di parole chiave guida e di uno schizzo di partenza. Successivamente, l'AI combina tali input per generare diverse proposte visive e consente al designer di perfezionare i risultati direttamente all'interno del software, inserendo immagini concettuali di ispirazione, indicando le aree dell'immagine da considerare come riferimento e regolando parametri visivi quali il numero di simmetrie o la complessità delle forme.

Parallelamente, Autodesk ha dichiarato l'intenzione di rafforzare il supporto ai designer attraverso l'AI generativa, sviluppando Blank AI, uno strumento proprietario per la creazione rapida di concept 3D dotato di controlli semantici e rendering contestuale, pensato in particolare per la modellazione delle superfici nel design automobilistico. Lo strumento è stato testato anche da Kia Motors, che ha riportato la capacità di ottenere modelli 3D sufficientemente realistici a partire dalla sola specificazione testuale del modello Kia, pur in assenza di un addestramento su dati proprietari del brand.

Il sistema si basa su una GAN personalizzata, denominata XDGAN, addestrata su progetti 3D storici e sui relativi metadati. Quando il modello viene addestrato su dati specifici di un marchio, è in grado di apprendere le caratteristiche stilistiche e tradurle in controlli semantici parametrici, consentendo la generazione, la modifica e l'esplorazione di modelli 3D coerenti con l'identità dell'azienda.

Un ulteriore progetto in fase di sviluppo è Bernini, realizzato dall'Autodesk AI Lab. Si tratta di un proof-of-concept sperimentale di AI generativa capace di creare rapidamente forme 3D funzionali a partire da testo, schizzi, immagini o nuvole di punti. Addestrato su circa 10 milioni di forme 3D e oltre 3 miliardi di parametri, il modello è concepito per supportare la fase di ideazione nel design concettuale anche al di fuori del settore automobilistico.

Kia Global Design		Strumento AI	Fonti
Settore	Automobilistico	Diffusion Model (versatile), GAN condizionali	[262] [263] [264]
Fase di prog.	Divergente		
Livello di prog.	Conceptual Design (cerchioni auto)		
Sottofase/i	Idea generation, combination, concept visualization		
CoA	DEV, COM		
SUP/AUG/AUT	AUG/SUP		

Creative Dock

Creative Dock è un'azienda ceca specializzata nello sviluppo di nuove business unit, prodotti e servizi digitali per i propri clienti, destinati all'uso diretto del consumatore finale o, più in generale, dell'utente, operando prevalentemente in contesti di mercato B2C e B2B2C.

L'azienda copre l'intero ciclo di innovazione e sviluppo del prodotto, dall'ideazione al lancio, accelerando i processi attraverso metodologie Lean e l'impiego di tecnologie avanzate come la Generative AI.

Nel workflow di progettazione, i designer di Creative Dock adottano numerosi cicli iterativi basati sul feedback di mercato. In particolare, nella fase di validazione tra un'iterazione e la successiva, la Generative AI viene integrata tramite VenturIA, uno strumento sviluppato internamente per simulare il comportamento dei clienti.

VenturIA consente di potenziare sia la fase preliminare di ricerca di mercato, dedicata alla definizione delle personas, sia la fase di evaluation, intesa come validazione delle soluzioni progettuali attraverso il feedback delle personas digitali create.

A partire da prompt che specificano parametri quali localizzazione geografica, bisogni e preferenze, il sistema genera clienti virtuali con profili identitari diversificati a livello globale, basandosi su dati di ricerche di mercato su larga scala relativi a specifici settori. Tali clienti virtuali possono essere impiegati in simulazioni realistiche, come interviste qualitative, per indagare ulteriormente esigenze e preferenze o per raccogliere feedback su differenti proposte progettuali nelle attività di test e validazione dei prodotti e delle loro funzionalità.

Inoltre, i dati proprietari generati da tali simulazioni vengono successivamente impiegati per l'affinamento di un modello linguistico (LLM) al fine di renderlo in grado di rispondere a quesiti di mercato specifici per ciascun segmento e di supportare analisi di mercato più avanzate.

Questo approccio consente di individuare criticità, opportunità e differenze culturali che difficilmente emergerebbero attraverso metodologie di ricerca tradizionali, spesso limitate a singoli mercati da vincoli di costo e di tempo, consentendo l'accesso costante a insight aggiornati ed eliminando le criticità logistiche e i tempi di attesa tipicamente associati alle ricerche condotte con consumatori reali. Il tutto migliorando l'efficacia delle iterazioni di ottimizzazione successive e favorendo l'attivazione di nuove fasi di idea generation.

Dopo diversi progetti pilota, VenturIA ha mostrato un allineamento del 90% con le risposte dei clienti reali, fornendo al contempo insight più ampi e geograficamente diversificati. Per garantire la qualità dei risultati, l'azienda confronta regolarmente le interviste sintetiche con test reali condotti su clienti di riferimento, verificando la validità dei dati raccolti con l'AI.

Creative Dock		Strumento AI	Fonti
Settore	Prodotti digitali	LLM (gen)	[236] [265] [266]
Fase	Planning (individuazione bisogni) + prog. Divergente-Convergente		
Livello di prog.	Conceptual Design		
Sottofase/i	Problem structuring, concept optimization e concept evaluation (validation)		
CoA	ID, STR, CNTR, COM		
SUP/AUG/AUT	SUP/AUG		

Nike

Il progetto A.I.R. (Athlete Imagined Revolution) rappresenta un caso emblematico di co-creazione tra designer e intelligenza artificiale applicata al design di prodotto. Sviluppato da Nike nel LeBron James Innovation Building di Beaverton (Oregon), il progetto ha coinvolto 13 atleti di quattro discipline (atletica, calcio, basket e tennis) con l'obiettivo di reinterpretare radicalmente la linea Nike Air.

Il processo prende avvio da una fase di ascolto attivo degli atleti, durante la quale vengono raccolti input sulle preferenze estetiche, funzionali e prestazionali del prodotto.

Queste informazioni vengono tradotte in prompt dettagliati per sistemi di AI generativa, attraverso i quali vengono progressivamente affinate mediante sessioni interattive tra il soggetto e lo strumento. In pochi secondi, l'AI genera centinaia di concept visivi, ampliando in modo significativo lo spazio di esplorazione creativa nella fase di idea generation.

Successivamente, l'interazione con il software viene interrotta e i team tornano a una progettazione manuale, utilizzando le forme, le texture e gli universi visivi prodotti dall'AI come fonte di ispirazione per la progettazione concreta.

In questa fase, i designer hanno dovuto contrastare alcuni bias algoritmici, poiché le generazioni prodotte tendevano a risultare esteticamente troppo simili. Questo ha reso necessario che la fase di idea combination e di valutazione delle idee ricadessero esclusivamente a carico dei designer, al fine di differenziare i risultati e definire un'identità visiva chiara per ogni prototipo. Da questo processo emergono tre concept radicali di scarpa per ciascun atleta, capaci di esprimere nuove interpretazioni del concetto di Air.

Dopo la selezione dei concept principali, ha inizio una fase di affinamento guidata dai feedback degli atleti. L'AI viene nuovamente impiegata attraverso sessioni di prompting per implementare adattamenti di natura estetica, funzionale ed esperienziale, all'interno di un processo di ottimizzazione concettuale in cui tali interventi vengono resi disponibili in forma visiva, dando progressivamente origine a un prodotto sempre più allineato alle esigenze dell'utente finale.

Come afferma John Hoke, Chief Design Officer di Nike, se usata senza esperienza l'AI può generare design generici, ma quando è guidata da un ascolto profondo dell'atleta diventa un vero complice creativo.

La fase di visualizzazione e sviluppo del concept è stata infine supportata anche da strumenti digitali tradizionali, come sketching 3D, design computazionale, simulazioni e stampa 3D dei prototipi.

Da questo esperimento, emergono alcuni risultati che evidenziano come l'AI sia in grado di accelerare ed espandere esponenzialmente il processo creativo, generando in pochi secondi spunti che in passato avrebbero richiesto mesi.

Roger Chen, Vice President of NXT Digital Product Creation di Nike, descrive l'AI come una "matita più affilata e intelligente", sottolineando come essa produca valore solo quando guidata e controllata dall'esperienza del designer, dando origine a una sinergia uomo-macchina capace di generare risultati senza precedenti. Sinergia che, a differenza dei processi convenzionali, caratterizzati da un flusso progettuale prevalentemente lineare, si configura mediante un rapporto continuo e iterativo tra il progettista e lo strumento, fondato su un affinamento reciproco e progressivo degli input di progettazione.

Nike		Strumento AI	Fonti
Settore	Moda e Sport	AI generativa condizionale (non spec.)	[267]
Fase di prog.	Divergente		
Livello di prog.	Conceptual Design		
Sottofase/i	Idea generation, concept optimization		
CoA	DEV, COM		
SUP/AUG/AUT	AUG/SUP		

IKEA

Il percorso di IKEA verso l'integrazione dell'intelligenza artificiale nel design e nell'esperienza d'acquisto può essere letto come un processo graduale, articolato in più fasi, che ha combinato inizialmente computer vision e realtà aumentata e, successivamente AI generativa.

L'obiettivo comune è da una parte, offrire al cliente un'esperienza di acquisto intuitiva e personalizzata e dall'altra, attribuirgli un ruolo attivo di progettista del proprio spazio abitativo, massimizzando l'obiettivo di personalizzazione e facendolo sentire parte integrante del processo progettuale stesso.

In una prima fase, con IKEA Kreativ, IKEA utilizza computer vision e realtà aumentata per migliorare l'affordance d'acquisto. L'app consente di ricreare digitalmente la propria stanza tramite la fotocamera del dispositivo, riconoscendo spazi, pareti e oggetti esistenti, permettendo di rimuovere i mobili reali e sostituirli con modelli 3D dei prodotti IKEA tratti dal catalogo.

Il cliente può così esplorare configurazioni d'arredo personalizzate e osservare in modo realistico l'integrazione dei mobili nel proprio ambiente domestico. In linea con le teorie di Norman, l'affordance si traduce qui nella capacità del sistema di rendere immediata la comprensione del prodotto attraverso la sua visualizzazione contestuale, riducendo la distanza tra consumatore e oggetto e trasformando l'utente in progettista del proprio spazio, secondo una visione fortemente user-oriented.

In una seconda fase, IKEA introduce l'IKEA AI Assistant sul GPT Store, segnando l'ingresso della generative AI nel design concettuale. Il ruolo dell'utente non si limita più alla disposizione di opzioni predefinite, ma si estende alla possibilità di descrivere in linguaggio naturale lo spazio desiderato (ad esempio "una camera minimalista con luce calda e mobili scandinavi").

Grazie all'integrazione tra ChatGPT e i dati del catalogo IKEA, l'assistente genera immagini e layout coerenti con lo stile richiesto, accompagnati da suggerimenti di prodotti reali acquistabili. L'AI supporta così pienamente le fasi di idea generation, combinazione e visualizzazione concettuale, rendendo il processo di progettazione accessibile anche a utenti non esperti e rafforzando il coinvolgimento emotivo del cliente, che si percepisce come autore del proprio progetto.

Tali iniziative hanno generato impatti significativi anche sul piano operativo. In particolare, l'aumento della fiducia e della capacità di visualizzazione da parte degli utenti ha contribuito a incrementare il valore medio del carrello, favorendo l'inserimento di prodotti complementari coerenti con il progetto. La riduzione degli errori di valutazione degli oggetti nelle stanze grazie alla visualizzazione aumentata ha inoltre migliorato l'allineamento tra le aspettative e il risultato finale, determinando una diminuzione dei resi. Parallelamente, l'impiego dell'intelligenza artificiale ha reso possibile l'erogazione di consulenze personalizzate su larga scala, affiancando e in alcuni casi sostituendo, il supporto dei commessi umani nei negozi fisici.

Un'ulteriore estensione di questo approccio finalizzato a comprendere gli utilizzi dell'intelligenza artificiale generativa è rappresentata dall'iniziativa lanciata nel 2023 durante la Milan Design Week da SPACE10, il laboratorio di ricerca dedicato all'esplorazione delle tecnologie applicabili al design di IKEA. Il workshop "Exploring the future with vintage designs in AI" ha utilizzato cataloghi IKEA degli anni '70-'80 come dataset per un modello di AI generativa, con l'obiettivo di stimolare la creazione di nuovi concept che fondessero estetica vintage e visioni future.

Pur non essendo ancora matura per un'integrazione diretta nei workflow industriali, l'esperienza ha mostrato il potenziale dell'AI come strumento di supporto al conceptual design. In circa un'ora, gli studenti hanno prodotto un centinaio di concept, riportando una riduzione del senso di intimidazione e una maggiore fiducia nello strumento. Come osservato dalle curatrici del workshop, l'intelligenza artificiale agisce oggi come un vero e proprio "carburante per l'immaginazione", pur richiedendo la competenza del designer per trasformare le idee in risultati concreti e per discernere ciò che debba essere realizzato fisicamente da ciò che può rimanere nel dominio digitale. Inoltre, il lavoro con l'AI sollecita una maggiore esplicitazione dei criteri progettuali, obbligando i designer a verbalizzare le ragioni alla base delle proprie scelte.

IKEA		Strumento AI	Fonti
Settore	Arredamento e articoli per la casa (Industrial Design)	AI generativa condizionale (non spec.)	[268] [269] [270]
Fase di prog.	Divergente		
Livello di prog.	Conceptual Design		
Sottofase/i	Idea generation, combination, concept visualization		
CoA	DEV, COM		
SUP/AUG/AUT	SUP/AUG		

Loft

Loft è una design agency con sede a Boston specializzata in product design e sviluppo creativo. Supporta aziende e brand nell'ideazione di nuovi prodotti attraverso un approccio fortemente user-centred, che integra ricerca sui consumatori, design, prototipazione e validazione finale. Opera su un ampio spettro di applicazioni, dal packaging ai prodotti di consumo elettronici (elettrodomestici, dispositivi smart, cuffie, speaker, smartwatch, accessori tech) fino a soluzioni digitali e UX/UI, arrivando anche a sistemi complessi per il settore sanitario e professionale-industriale.

Nel suo processo, Loft ha sperimentato l'uso della Generative AI con tre finalità principali. In primo luogo, ha utilizzato GPT-4 per suggerire nuove funzionalità di prodotto a partire dalle preferenze note dei clienti, selezionando e raffinando le idee più promettenti tramite iterazioni successive di prompting. In parallelo, i designer hanno sviluppato schizzi concettuali caricandoli su Midjourney per esplorare e affinare rapidamente varianti visive. In questo caso, il rischio di hallucinations tipico di questa tipologia di strumenti non è risultato critico, poiché le immagini non costituivano output finali ma semplici stimoli creativi. Al contrario, l'uso della GenAI è stato volutamente sospeso nelle fasi più avanzate di prototipazione, ritenute troppo sensibili e vincolate alla fattibilità tecnica per essere delegate all'AI.

Un terzo ambito di applicazione ha riguardato l'analisi dei feedback dei consumatori raccolti tramite focus group e sondaggi. La GenAI è stata impiegata per analizzare le trascrizioni delle interazioni, individuare e segnalare aree di miglioramento e identificare le funzionalità più apprezzate, fornendo anche input utili al marketing di lancio. Questi insight sono stati poi reintegrati nelle fasi di sviluppo divergente del concept di design.

A partire da queste sperimentazioni, Loft ha registrato benefici concreti. Ad esempio, per un giocattolo a forma di chitarra il team ha generato rapidamente circa 50 concept alternativi, riducendo drasticamente il tempo necessario per analizzare i feedback, proporre nuove soluzioni e integrarle coerentemente nei concept sviluppati. Nel complesso, l'azienda stima che l'adozione della Generative AI abbia dimezzato i tempi di sviluppo prodotto.

Loft		Strumento AI	Fonti
Settore	Product Design (giocattoli, elettronica di consumo, prodotti digitali, sistemi complessi sanitari o industriali ecc.)	LLM (gen) + Diffusion Model condizionale	[236]
Fase di prog.	Divergente		
Livello di prog.	Conceptual Design		
Sottofase/i	Idea generation, combination, concept visualization		
CoA	DEV, COM		
SUP/AUG/AUT	AUG/SUP		

Fase di prog.	Convergente	LLM (gen)	[236]
Livello di prog.	Conceptual Design		
Sottofase/i	Concept optimization, concept evaluation (validation)		
CoA	STR, CNTR		
SUP/AUG/AUT	SUP		

4.2.7. Quadrante H

Notion's AI

Notion AI, sviluppato da Notion Labs Inc., azienda fondata nel 2013 a San Francisco da Ivan Zhao e Simon Last, è un assistente basato su modelli linguistici di grandi dimensioni (LLM) integrato direttamente nella piattaforma Notion.

Pur essendo concepito per un utilizzo generalista, trova la sua principale applicazione nei settori legati al software, alle applicazioni digitali e ai dispositivi elettronici, dove supporta in particolare i team di sviluppo prodotto nelle fasi di pianificazione e generazione di idee. In questi contesti, svolge soprattutto un ruolo di potenziamento della produttività operativa, efficientando attività ripetitive e organizzative tipiche di tali fasi, pur offrendo talvolta anche stimoli creativi utili.

Durante la fase di planning, Notion AI sintetizza e organizza sia i documenti aziendali, come feedback, insight competitivi, conoscenze interne e trascrizioni di conversazioni tra team e stakeholder, sia le fonti esterne reperite dal web, con l'obiettivo di trasformare le informazioni raccolte in report strutturati.

Oltre alla produzione di report, l'analisi integrata di dati interni ed esterni mira a individuare temi chiave, trend di mercato, bisogni dei clienti e priorità strategiche, fornendo input fondamentali per la successiva fase di generazione delle idee.

Infine, l'AI operante sotto forma di agente basato su modelli linguistici (LLM-based), supporta la pianificazione operativa traducendo le informazioni analizzate in task concreti con scadenze definite e suggerendo strategie volte a cogliere le opportunità emerse sia dai dati interni sia dal contesto di mercato.

Durante la fase di conceptual design, Notion AI supporta la strutturazione del problema attraverso l'organizzazione dei requisiti nel PRD (product requirement document) dentro una struttura standardizzata secondo le modalità aziendali. Dall'analisi delle trascrizioni dei brainstorming e delle informazioni sui clienti e sul contesto, l'AI riesce a individuare possibili rischi e aree critiche che vengono tradotti in nuovi vincoli e requisiti da rispettare. Inoltre, durante la fase di generazione delle idee, categorizza e priorizza le proposte che emergono nelle sessioni di brainstorming tra i membri del team, da utenti o test di prototipo e suggerisce miglioramenti, varianti di funzionalità e nuove architetture di prodotto, contribuendo a svolgere un ruolo simile a quello di un membro aggiuntivo del team.

Integrando l'intelligenza artificiale in modo trasversale nelle diverse fasi dello sviluppo prodotto, Notion contribuisce a migliorare la collaborazione e la comunicazione tra team multidisciplinari. Grazie alle tecniche di NLP, la piattaforma adatta e standardizza i contenuti, rendendoli accessibili a utenti con competenze eterogenee. Parallelamente, i meccanismi di apprendimento automatico consentono al sistema di apprendere dai dati storici e dagli input degli utenti, ottimizzando progressivamente la qualità dei suggerimenti forniti.

I risultati riportati dalle aziende che hanno adottato Notion AI, come Cohere, indicano un risparmio medio superiore alle sette ore settimanali e un'accelerazione dei rilasci pari al 30%, mentre Ramp dichiara una riduzione dei costi operativi pari al 70%.

Notion's AI		Strumento AI	Fonti
Settore	Software Development	LLM (gen) + Agent AI (LLM-based)	[271] [272] [273]
Fase	Planning		
Attività	Raccolta e organizzazione delle informazioni, individuazione dei bisogni, definizione di direzioni strategiche, pianificazione di task operativi		
CoA	ID, STR, COM		
SUP/AUG/AUT	AUG/SUP		
Fase di prog.	Divergente	LLM (gen)+ Agent AI (LLM-based)	
Livello di prog.	Conceptual Design, High Level System Architecture Design		
Sottofase/i	Problem Structuring (standardizzazione dei requisiti e definizione di nuovi), Idea generation, Concept optimization, Concept evaluation (interpretazione dei feedback di progettisti e clienti e suggerimenti di miglioramento)		
CoA	ID, STR, DEV, COM, CNTR		
SUP/AUG/AUT	AUG/SUP		

StackSpot AI

Nel settore dello sviluppo software, la progettazione è tipicamente guidata da metodi di pianificazione riconducibili alle tecniche agili, come ad esempio alla metodologia Scrum. In questo contesto, il product backlog (lista ordinata e prioritaria delle funzionalità da implementare), e le user story (descrizioni sintetiche delle funzionalità dal punto di vista dell'utente) rappresentano strumenti centrali. La loro qualità e precisione incidono direttamente sull'allineamento dei team e sull'efficienza complessiva del processo di sviluppo.

È in questo scenario che si colloca StackSpot AI, una piattaforma di intelligenza artificiale per lo sviluppo software sviluppata da Zup Innovation, azienda tecnologica brasiliana acquisita da Itaú Unibanco tra il 2019 e il 2020.

Inizialmente concepita per rispondere alle esigenze interne di Itaú Unibanco, la più grande banca privata del Sud America, nella creazione rapida e innovativa di nuovi software, la piattaforma è oggi adottata anche da altri team di sviluppo e aziende tecnologiche.

Prima dell'introduzione dell'AI, la banca affrontava un'elevata complessità gestionale, dovuta allo sviluppo simultaneo di più prodotti sulla piattaforma dati, alla migrazione verso una nuova architettura basata su AWS e alla necessità costante di innovare in un contesto altamente competitivo. Questa situazione generava diverse criticità operative: backlog incompleti o non aggiornati che ostacolavano la pianificazione, utilizzo di fogli di calcolo con scarsa visibilità e collaborazione tra i team, sovraccarico dei Product Manager divisi tra compiti operativi e strategici e costi elevati legati a una gestione della pianificazione inefficiente.

L'adozione di StackSpot AI ha consentito di riorganizzare e semplificare la gestione dei backlog e delle user story, aumentando l'efficienza dei team di sviluppo. La piattaforma riduce le attività manuali ripetitive, favorisce il riuso di componenti software esistenti ed evita duplicazioni, garantendo la coerenza tecnica complessiva. Supporta inoltre la definizione e la strutturazione delle user story, rendendole più chiare e uniformi tramite comandi rapidi predefiniti, e integra criteri di accettazione preliminarmente definiti per assicurare il rispetto di requisiti di qualità, prestazioni, sicurezza e usabilità. Un agente AI supervisiona l'intero backlog, occupandosi dell'organizzazione e della prioritizzazione dei task.

Dal punto di vista tecnologico, StackSpot AI combina agenti AI, deputati all'automazione di compiti di supporto, e assistenti AI, che interagiscono iterativamente con gli utenti per aumentare la produttività dei team. Per questo può essere definita una piattaforma multi-agente di intelligenza artificiale generativa iper-

contestualizzata, capace di adattarsi al contesto specifico dell'organizzazione e di supportare l'intero ciclo di sviluppo software, dall'ideazione al deployment.

Sebbene le fonti non specifichino esplicitamente le tecnologie di AI impiegate, è possibile formulare alcune deduzioni. La creazione, riformulazione e standardizzazione delle user story e dei criteri di accettazione, così come l'organizzazione e la prioritizzazione del backlog, suggeriscono l'uso di modelli di linguaggio naturale (NLP/LLM), che sfruttano sistemi di machine learning per apprendere dai dati storici e dalle pratiche di lavoro aziendali e che si collocano all'interno di un'architettura multi-agente, la quale coordina lo svolgimento, da parte degli agenti, di attività di produttività, pianificazione e controllo di task standardizzati.

I risultati ottenuti sono rilevanti sia sul piano tecnico sia su quello di business. Il tempo medio necessario per il refinement delle user story è stato ridotto dell'88%, il numero medio di user story consegnate mensilmente è aumentato del 40% e la qualità delle user story è migliorata del 21%. Sul piano organizzativo, si è registrata una significativa riduzione del tempo dedicato alla pianificazione, una maggiore focalizzazione dei team su attività a valore aggiunto e una liberazione dei Product Manager dai compiti operativi, consentendo loro di concentrarsi su decisioni strategiche di alto livello, riferite a contesti critici, incerti e altamente destrutturati.

StackSpot AI		Strumento AI	Fonti
Settore	Software Development	AI generativa, multi-agent architecture, ML	[274]
Fase	Planning + prog. Divergente (Agile)		
Sottofase/i:	Project management (pianificazione) applicata all' NPD + Problem definition e structuring		
CoA	STR, CNTR, COM		
SUP/AUG/AUT	AUG/AUT		

4.2.8. Quadrante I

Volkswagen (specchietti, volante, cerchioni)

Per celebrare il ventesimo anniversario del suo principale centro di ricerca automobilistica, il Gruppo Volkswagen ha presentato un VW Bus d'epoca reinterpretato attraverso un processo di progettazione basato sul generative design.

Con l'obiettivo di massimizzare la resistenza strutturale e ridurre il peso complessivo, Autodesk ha collaborato con il Volkswagen Innovation and Engineering Center California (IECC) alla riprogettazione di diversi componenti di questo veicolo dimostrativo elettrificato.

La riduzione del peso rappresenta uno degli aspetti più critici nella progettazione dei veicoli elettrici, poiché un'auto più leggera richiede meno energia per muoversi e garantisce quindi una maggiore autonomia per singola ricarica, fattore determinante nelle scelte dei consumatori.

Tra i principali vantaggi del generative design vi è la possibilità di eliminare materiale superfluo, riducendo la massa dei componenti senza compromettere prestazioni, robustezza e vincoli ingegneristici. In questo progetto, la tecnologia è stata applicata ai cerchi del Microbus Type 2 del 1962, ripensandone radicalmente la struttura. Cerchi più leggeri contribuiscono infatti non solo a ridurre il peso totale del veicolo, ma anche la resistenza al rotolamento degli pneumatici, migliorando l'efficienza complessiva. I nuovi cerchi risultano più leggeri del 18% rispetto a quelli standard e il tempo di sviluppo, dalla progettazione alla produzione, è stato ridotto da circa un anno e mezzo a pochi mesi.

Come sottolinea Andrew Morandi, Senior Product Designer del Gruppo Volkswagen, il design generativo consente di creare strutture difficilmente immaginabili con approcci tradizionali, configurandosi come una vera forma di augmentazione delle capacità cognitive del progettista. Oltre ai cerchi, la tecnologia è stata impiegata per riprogettare il volante, la struttura di supporto del sedile posteriore e i supporti esterni degli specchietti retrovisori.

Secondo Erik Glaser, Principal Product Designer di Volkswagen, la scelta di collocare un componente progettato generativamente in un punto direttamente percepibile dagli utenti risponde alla volontà di rendere tangibili la solidità e la resistenza di queste strutture, oltre a permettere di osservarne lo stile e la bellezza delle loro forme complesse e intricate, sebbene richieda un adattamento finalizzato alla coerenza con lo stile del marchio.

Guardando al futuro, Morandi ipotizza che nei prossimi decenni interi telai potrebbero essere progettati tramite generative design, aprendo a un cambiamento radicale nei processi produttivi dell'industria automobilistica.

Volkswagen (specchietti, volante, cerchioni)		Strumento AI	Fonti
Settore	Automobilistica	Generative Design-AI evolutiva	[275]
Fase di prog.	Divergente		
Livello di prog.	Conceptual Design		
Sottofase/i	Concept optimization		
CoA	DEV, CNTR		
SUP/AUG/AUT	AUG/SUP		

Decathlon

Decathlon, azienda francese leader nella produzione e vendita di articoli sportivi, ha avviato l'esplorazione di tecniche di intelligenza artificiale attraverso il progetto React, sviluppando una pinna da immersione capace di coniugare elevate prestazioni e durabilità con un ridotto impatto ambientale. Abbandonando i modelli progettuali tradizionali, l'azienda dimostra come prestazioni ed esigenze di sostenibilità, spesso considerate in contrasto, possano invece coesistere all'interno dello stesso prodotto, grazie al supporto di questa tecnologia.

L'obiettivo del progetto era sviluppare una pinna caratterizzata da una rigidità costante lungo l'asse longitudinale, a differenza dei modelli tradizionali in cui la rigidità tende a diminuire lungo la lunghezza, riducendo al contempo al minimo l'impiego di materiale. Parallelamente, il progetto mirava a integrare, per quanto possibile, materiali riciclati, così da rendere il prodotto smaltibile in modo sostenibile a fine ciclo di vita, senza compromettere durabilità e prestazioni elevate.

L'elemento chiave del progetto è stata l'adozione del Generative Design in Autodesk Fusion, che in questa versione integra anche tecniche di machine learning, oltre agli algoritmi evolutivi e di ottimizzazione già esistenti.

Il sistema ha permesso di rendere l'esplorazione e l'ottimizzazione del processo di design guidato dai dati di progetti precedenti, riducendo la dipendenza dai tradizionali processi di trial and error, aumentando l'efficienza complessiva del processo.

Gli algoritmi hanno generato e valutato soluzioni multi-obiettivo, tenendo conto di materiali, processi produttivi, riduzione del peso, requisiti prestazionali e forze fisiche. Il machine learning ha inoltre supportato la fase di modellazione 3D, suggerendo le configurazioni più efficaci sulla base dell'apprendimento da progetti precedenti, e ha accelerato la produzione della documentazione 2D attraverso l'automazione di viste, quote e annotazioni, con una significativa riduzione dei tempi.

Durante i cicli di ottimizzazione generativa, il team ha effettuato simulazioni su centinaia delle configurazioni prodotte, valutando parametri come distribuzione del peso, flessibilità e risposta idrodinamica. Le simulazioni hanno evidenziato che una semplice deformazione centrale della pala della pinna, sarebbe risultata efficace quanto le rinforzature laterali nel garantire una propulsione ottimale.

Il risultato finale è la pinna React, un prodotto che ha pienamente soddisfatto gli obiettivi di progettazione finali, dimostrando l'idoneità di tale strumento di intelligenza artificiale a supporto di un processo progettuale di questa natura. La pinna utilizza il 50% di materiale in meno rispetto ai modelli precedenti e riduce del 50% l'impronta di carbonio rispetto allo standard di mercato.

Realizzata in materiale riciclato e composta da un unico tipo di plastica, è facilmente riciclabile a fine vita senza necessità di smontaggio. Oltre a essere più leggera e resistente, risulta anche più performante e gradevole dal punto di vista estetico, grazie alle forme organiche impresse con il design generativo.

Test rigorosi ne hanno garantito la conformità ai più elevati standard di qualità e prestazione. L'iniziativa apre inoltre nuove prospettive per il miglioramento di altri articoli sportivi e potrebbe costituire un modello di riferimento per la riduzione dell'impatto ambientale in diversi settori industriali.

Decathlon		Strumento AI	Fonti
Settore	Sport	Generative Design-AI evolutiva, Machine Learning	[276] [277]
Fase di prog.	Divergente, Convergente		
Livello di prog.	Conceptual, Detailed Design		
Sottofase/i	Idea generation, concept visualization e optimization		
CoA	DEV, CNTR		
SUP/AUG/AUT	AUG/SUP		

AI chair

Durante il Salone del Mobile di Milano è stata presentata la A.I. Chair, la prima sedia prodotta industrialmente progettata con il supporto dell'intelligenza artificiale. Il progetto nasce dalla collaborazione tra il designer francese Philippe Starck, l'azienda italiana di arredamento Kartell e Autodesk Research, e rappresenta uno dei primi esempi concreti di applicazione del Generative Design nel design industriale di largo consumo.

Il caso è stato presentato per dimostrare come il design generativo possa andare oltre ambiti strettamente ingegneristici, come la progettazione di staffe o supporti motore, ed estendersi anche all'ambito del design industriale, in cui entrano in gioco aspetti più trasversali, come quelli estetici, accanto a quelli più tecnici di natura funzionale e prestazionale.

Il processo è iniziato con la definizione dei parametri di progetto da parte di Starck, mentre l'algoritmo di design generativo ha elaborato diverse alternative progettuali realizzabili con stampaggio a iniezione, nel rispetto dei vincoli produttivi e funzionali. Successivamente, il ruolo del designer è stato quello di selezionare e rifinire le proposte generate dall'AI, traducendole in un prodotto coerente con l'identità e lo stile di Kartell.

Il progetto si è svolto all'interno di un workflow collaborativo in cui il designer non è stato sostituito, ma affiancato. L'AI ha esplorato le soluzioni guidate dai parametri definiti dal progettista e, successivamente alla fase di generazione, l'essere umano ha selezionato, interpretato e conferito la forma finale al progetto, personalizzandolo in base allo stile e alle esigenze specifiche.

Il risultato ha dato origine a un design organico e inusuale rispetto alle sedie tradizionali, ma al tempo stesso funzionale, producibile in serie ed esteticamente futuristico, rimanendo coerente con il linguaggio progettuale identitario del progettista grazie ai ritocchi finali apportati.

La A.I. Chair è stata prodotta su larga scala, dimostrando la concreta applicabilità del design generativo ai prodotti di design industriale e il suo potenziale nel ridefinire il rapporto tra creatività e ottimizzazione vincolata.

AI chair		Strumento AI	Fonti
Settore	Arredamento	Generative Design-AI evolutiva	[278]
Fase di prog.	Divergente		
Livello di prog.	Conceptual Design		
Sottofase/i	Idea generation, concept visualization e optimization		
CoA	DEV, CNTR		
SUP/AUG/AUT	AUG/SUP		

Britten Inc.

Britten Inc. è un'azienda di progettazione creativa specializzata nella realizzazione di insegne, espositori e soluzioni di branding personalizzate, che integra internamente anche le attività di progettazione e produzione dei componenti destinati alle proprie installazioni. Per questo motivo, accanto a un'impostazione progettuale fortemente orientata al coinvolgimento dell'utente e alla dimensione espressiva, emergono inevitabilmente considerazioni di natura ingegneristica legate alla stabilità e ai vincoli strutturali dei sostegni espositivi. Si tratta di un caso in cui emerge con chiarezza come le finalità di progettazione delle caratteristiche del prodotto siano strettamente legate alle scelte e agli obiettivi strategici aziendali. Sebbene l'azienda nasca come realtà creativa, la decisione di internalizzare la produzione della componentistica complementare ridefinisce in modo significativo le finalità progettuali del prodotto complessivo finale, e determina, coerentemente con il contenuto del presente caso studio, il suo posizionamento sulla matrice.

In tale contesto, Britten Inc. ha intrapreso un'iniziativa di miglioramento di un prodotto esistente in collaborazione con Team D3, partner Autodesk Platinum, facendo ricorso alla tecnologia di Generative Design integrata in Autodesk Fusion 360. Il prodotto oggetto dell'intervento è BannerSaver, un bracket per banner pubblicitari progettato per applicazioni espositive outdoor. Il sistema, basato su un meccanismo a molla caricata, è stato testato in galleria a vento ed è in grado di resistere fino all'87% della forza associata a venti di tipo tornado, incrementando in modo significativo la durabilità e la resistenza strutturale delle insegne pubblicitarie esterne.

In questo caso, le finalità progettuali hanno trovato corrispondenza con le potenzialità offerte dal Generative Design, le quali hanno consentito riduzione di peso e materiale, aumento della resistenza strutturale tramite eliminazione delle aree di debolezza, miglioramento della sostenibilità attraverso la scelta di materiali ecologici, semplificazione dell'assemblaggio e della supply chain mediante la riduzione del numero di componenti e nel rispetto dei vincoli fisici e ingegneristici.

È tuttavia rilevante osservare come tali risultati non siano stati conseguiti in un'unica sessione. Le prime soluzioni generate presentavano infatti geometrie eccessivamente complesse e visivamente poco adeguate. Attraverso iterazioni successive, le configurazioni ottenute si sono dimostrate progressivamente più stabili, caratterizzate da geometrie più efficaci e volumi ridotti, generando al contempo spunti rilevanti per l'esplorazione di processi produttivi alternativi, quali lo stampaggio.

L'impiego del Generative Design ha così attivato una forma di creatività guidata dai requisiti tecnici, potenziando il contributo dei designer, che hanno successivamente integrato tali output con forme ispirate a strutture naturali, come i tentacoli del polpo o la proboscide dell'elefante. Parallelamente, il design generativo ha consentito un processo di rifinitura e ottimizzazione multi-obiettivo delle soluzioni, guidate dai progettisti in funzione degli obiettivi di progettazione.

Complessivamente, il redesign ha determinato un ripensamento radicale del prodotto, con una riduzione del peso pari al 78%. Tale risultato ha aperto nuove opportunità di mercato e di brevettazione in un settore precedentemente caratterizzato da una limitata evoluzione, contribuendo in modo rilevante alla crescita dell'azienda.

Britten Inc.		Strumento AI	Fonti
Settore	Manifatturiero e della comunicazione visiva	Generative Design-AI evolutiva	[279]
Fase di prog.	Divergente		
Livello di prog.	Conceptual + Detailed Design		
Sottofase/i	idea generation, combination, concept visualization e optimization		
CoA	DEV, CNTR		
SUP/AUG/AUT	AUG/SUP		

Di seguito, in Figura 4.6, viene rappresentata la collocazione dei casi di studio aziendali emersi dalla ricerca empirica all'interno della Matrice degli Orientamenti Progettuali, mostrandone la distribuzione nei diversi quadranti.





Figura 4.6: Collocazione dei casi di studio aziendali emersi dalla ricerca empirica all'interno della Matrice degli Orientamenti Progettuali.

4.3. Riflessioni sui risultati del posizionamento dei casi sulla Matrice degli Orientamenti Progettuali

La presente sezione è dedicata all'analisi e all'interpretazione dei risultati derivanti dal posizionamento dei casi di studio all'interno della Matrice degli Orientamenti Progettuali, nonché delle conseguenti applicazioni di strumenti di intelligenza artificiale, idonei a modellare specifiche caratteristiche di prodotto e le relative finalità progettuali.

Le considerazioni sui risultati sono articolate per quadranti, secondo lo schema riportato in Figura 4.1, e si focalizzano su: la collocazione dei casi di studio (Figura 4.6); la distribuzione delle tecniche di intelligenza artificiale associate ai casi nelle aree della matrice (Figura 4.7); e i ruoli operativi attraverso cui tali strumenti intervengono nelle diverse applicazioni (Figura 4.8).



AI generativa condizionale (text-to-text, text-to-image, image-to-image) + ML su dati aziendali-->Diffusion Models, GAN, LLM (GPT, NLP task, generative vision), MLLM, ML per: 1) stimolare la creatività nell'esplorazione concettuale (brainstorming aumentato, generazione di concept visivi, visualizzazione e affinamento delle forme) customizzazione lato cliente; 2) generare soluzioni tecnico-ingegneristiche guidate da relazioni di dominio e vincoli appresi dai dati (simulazioni, inferenza di correlazioni tra requisiti e configurazioni).
AI generativa (image-to-text, text-to-text) + ML su dati aziendali; Agent AI -> LLM (GPT, NLP task) + RAG; ML; LLM-based agents per: 1) Planning (raccolta info, analisi trend, bisogni e vincoli market/supply side, definizione direzioni strategiche, redazione documentazione di progetto), Strutturazione del problema (definizione personas e segmenti, standardizzazione, definizione e controllo di requisiti; user story e product backlog) 2) Analisi di contratti e vincoli regolatori/HSE, redazione documentazione di progetto (es. disegno tecnico, report), traduzione di requisiti in linguaggio naturale in soluzioni tecniche, facilitazione dell'interazione con software complessi, recupero di conoscenza specifica. 1+2) Agent AI per task di produttività e pianificazione operativa trasversali a fasi e funzioni, spesso preliminari alla progettazione.
AI generativa + ML -> LLM (GPT, NLP task), BERT (NLP task), ML per: 1) valutazioni qualitative e reasoning semantico (screening giustificato da analisi della documentazione di progetto, individuazione di correlazioni tra configurazioni del sistema, prestazioni e feedback dei clienti, validazione della soluzione in base ai requisiti di prodotto specificati) 2) Valutazione delle soluzioni tramite analisi dei feedback dei consumatori raccolti tramite focus group e sondaggi, simulazioni di personas virtuali per la validazione di mercato
ML, AI deterministica, AI generativa, Simulazioni basate su metodi numerici -> ML predittivo surrogato, AI deterministica ruled-based, Modelli generativi grafici, simulazioni (FEM,FEA, CFD multi-fisica ecc.) : 1) AI deterministica per simulazioni e analisi numeriche di prestazioni, costi, producibilità e impatto ambientale; modelli generativi grafici in sistemi di simulazione (valutazione behaviour dei moduli e delle loro interazioni); ML predittivo come modello surrogato per valutazioni intermedie (training su simulaz. passate); simulazioni (FEM,FEA, CFD multi-fisica ecc.) 2) ML come modello surrogato per valutazione preliminare di composti (odori, ricette alimentari) e suggerire sostituzioni di ingredienti con obiettivo sensoriale, nel rispetto di vincoli normativi, economici, produttivi e ambientali
ML per : raccolta, analisi dei dati (log di sensori, dati di utilizzo dei prodotti, segnalazioni di guasto) e supporto alla definizione dei requisiti a partire da relazioni apprese dai dati storici raccolti e le configurazioni di prodotto passate
AI evolutiva, calcolo numerico/ottimizzazione, ML-> algoritmi evolutivi (GA, NSGAI), Topology, shape/size, multi-objective optimization (es. multi-fisico), ML allenato sulle simulazioni passate a supporto della valutazione dei cicli di ottimizzazione generativa per: Generative Design
AI generativa-> LLM, Regression Transformer specificatamente addestrati per: modellare sequenze di elementi tecnici tokenizzabili con cui dare origine a generazioni e combinazioni inedite di codice, assiemi meccanici, componenti elettrici su schede PCB, design molecolare (sintesi enzimatica e nuovi materiali)

Figura 4.7: Mappatura degli strumenti e delle tecniche di intelligenza artificiale nei quadranti della Matrice degli Orientamenti Progettuali in relazione ai casi applicativi aziendali analizzati.




Figura 4.8: Mappatura dei ruoli operativi e dei livelli di autonomia degli strumenti e delle tecniche di intelligenza artificiale nei quadranti della Matrice degli Orientamenti Progettuali, in relazione ai casi applicativi aziendali analizzati.

Quadrante A

La prima area della matrice a cui si fa riferimento nello schema di Figura 4.1 è il Quadrante A, che identifica una porzione di limitato interesse progettuale, come attestato dall'assenza di casi di studio. Tale area considera caratteristiche di prodotti prevalentemente già affermati, fortemente standardizzati, privi di interazione significativa con l'utente e caratterizzati da una ridotta esigenza di innovazione. Si tratta di soluzioni che richiedono interventi di riprogettazione minimi o nulli e per le quali risulta pertanto poco significativo, oltre che economicamente non conveniente, l'impiego di strumenti avanzati e specifici, quali quelli basati su tecniche di intelligenza artificiale.

Quadrante B

In posizione adiacente al precedente si colloca il Quadrante B, che delimita una porzione della matrice caratterizzata da un basso livello di U-oD e da un livello intermedio di S&E-oD. Tale area è generalmente riconducibile a prodotti o componenti a bassa o media complessità, non progettati per un'interazione diretta con l'utente, se non in forma indiretta o mediata. Dal punto di vista ingegneristico, essa corrisponde a un grado di complessità medio, derivante da specifiche combinazioni dei livelli dei sotto-fattori, corrispondenti rispettivamente al behaviour del sistema e dei suoi componenti.

In particolare, possono presentarsi due configurazioni principali. Nel primo caso, la complessità di progettazione del behaviour strutturale del sistema si colloca su valori intermedi o moderatamente alti, a fronte di una ridotta complessità del behaviour dei singoli componenti. Ciò implica che il prodotto in esame risulta costituito da una pluralità di elementi, per i quali la principale fonte di complessità progettuale, seppur talvolta moderata, risiede nella definizione di un insieme coerente e funzionante, in cui i moduli o componenti, ciascuno associato a una funzione elementare distinta, interagiscono in modo coordinato al fine di conseguire lo scopo ultimo del sistema.

Nel secondo caso, il prodotto è costituito da un singolo componente o da un numero limitato di elementi, che operano all'interno dello stesso dominio funzionale (ad esempio esclusivamente meccanico o elettronico), in un assetto in cui il behaviour strutturale risulta particolarmente semplice, poiché non è necessario bilanciare funzioni eterogenee e interdipendenti. Da notare come questo non implichi necessariamente la presenza di un unico obiettivo progettuale, il problema può infatti essere sia mono, sia multi-obiettivo, con un livello di difficoltà che varia dal semplice al medio, ma sempre circoscritto a un unico dominio funzionale.

Gli obiettivi di ottimizzazione più ricorrenti in questo quadrante riguardano la riduzione dei costi e dei materiali, il rispetto dei vincoli fisici e strutturali, la diminuzione del numero di componenti per semplificare i processi produttivi e la selezione di materiali in grado di garantire una buona producibilità a costi contenuti ed a

basso impatto ambientale. In questi contesti, l'attività progettuale non è orientata alla massimizzazione di una specifica prestazione, quanto piuttosto all'ottimizzazione delle risorse, alla semplificazione della produzione e al miglioramento della sostenibilità complessiva del componente. Trattandosi generalmente di componenti non core, inseriti all'interno di sistemi o prodotti più complessi, la loro riprogettazione mira a generare un contributo incrementale che, sommato a quello di altri elementi, produce un miglioramento significativo sugli effetti del prodotto finale.

In questo quadrante, gli strumenti di intelligenza artificiale tipicamente impiegati coincidono con algoritmi evolutivi, come algoritmi genetici semplici (GA), algoritmi multi-obiettivo (ad es. NSGA-II), algoritmi di ottimizzazione topologica e approcci affini, generalmente integrati all'interno di framework di Generative Design. Tali metodologie risultano frequentemente associate a tecniche di produzione additiva e stampa 3D, particolarmente compatibili sia con il design generativo sia con la tipologia di componenti riconducibili a questo quadrante, come nel caso della staffa del sedile automobilistico sviluppata da General Motors.

In relazione al ruolo operativo svolto dallo strumento in questo caso, esso si configura prevalentemente come di tipo AUG, in quanto il componente oggetto di progettazione non riveste un carattere core né presenta un elevato livello di criticità rispetto al contesto applicativo previsto. La complessità associata al componente risulta infatti moderata e adeguatamente gestibile dallo strumento, che è in grado di condurre in modo efficace i cicli iterativi di ottimizzazione senza che risulti necessaria una supervisione continua da parte del progettista. Ciò avviene senza introdurre rischi significativi di errore e consente, al contempo, la generazione di geometrie e l'esecuzione di numerosi calcoli difficilmente affrontabili con un approccio manuale e in tempi decisamente più brevi.

Quadrante I

In posizione sovrastante al quadrante B, a parità di livello di S&E-oD e con un valore di U-oD superiore, si colloca il quadrante I, analizzato in questo punto per evidenziare gli elementi di continuità e le differenze rispetto al precedente.

In quest'area della matrice rientrano casi con caratteristiche intermedie, in cui le soluzioni progettuali devono rispondere simultaneamente a requisiti legati al behaviour del sistema e a esigenze di interazione percettiva con l'utente, includendo aspetti estetici e simbolici connessi al brand.

A fronte di un livello di S&E-oD analogo a quello del Quadrante B, risultano valide le medesime considerazioni relative ai sotto-fattori della complessità ingegneristica. La distinzione risiede principalmente nella gestione complessiva del processo progettuale, che in questo caso deve integrare anche le dimensioni connesse all'esperienza dell'utente.

Di conseguenza, pur adottando strumenti simili per la modellazione degli aspetti tecnici, come algoritmi evolutivi all'interno di software di Generative Design, talvolta combinati con moduli di machine learning per rendere l'ottimizzazione guidata da simulazioni e progetti passati, il ruolo operativo dello strumento cambia da AUG a AUG/SUP. Il progettista è infatti chiamato a intervenire in misura maggiore per adattare le soluzioni ottimizzate ingegneristicamente agli aspetti percettivi, stilistici e simbolici del prodotto, che il software non è in grado di modellare.

Nei casi Volkswagen e A.I. Chair, il design generativo è applicato sia a componenti destinati all'interazione diretta con l'utente sia a soluzioni orientate alla produzione in serie. Nel caso Volkswagen, esso consente la riduzione del peso della componentistica secondaria, con effetti sul peso complessivo del veicolo elettrico e, conseguentemente, sul miglioramento dell'efficienza energetica, permettendo al contempo l'esplorazione di forme e configurazioni strutturali all'avanguardia. Nel caso di A.I. Chair, il design generativo supporta similmente un'indagine orientata a linguaggi morfologici non convenzionali, mantenendo la compatibilità con i vincoli di producibilità su larga scala. In entrambi i casi, le soluzioni generate vengono successivamente rielaborate dal designer per garantire coerenza estetica e allineamento con l'identità del marchio.

Considerazioni analoghe valgono per i casi di Britten Inc. e Decathlon, che si collocano leggermente più a destra nella matrice in ragione di una maggiore enfasi sulle prestazioni ingegneristiche su cui la progettazione è indirizzata. Nel caso di Britten, il Generative Design è impiegato per la riprogettazione di un bracket per banner outdoor, ottimizzato per resistere alle sollecitazioni aerodinamiche testate in galleria a vento, riducendo peso e

materiale non funzionalmente necessario, migliorando al contempo la sostenibilità attraverso l'uso di materiali ecologici e semplificando assemblaggio e supply chain. Nel caso di Decathlon, l'obiettivo è la riprogettazione di pinne che combinino elevate prestazioni, finalizzate all'aumento della spinta propulsiva sott'acqua, e un ridotto impatto ambientale, successivamente adattate ai valori e allo stile del brand.

È infine rilevante osservare come, in termini generali, il Generative Design possa essere impiegato sia come strumento di idea generation, assumendo un ruolo divergente e ispirazionale, seppur guidato da requisiti e vincoli tecnici definiti (come verrà approfondito nel caso del quadrante C), sia come strumento di ottimizzazione, quando il concept è solo moderatamente complesso da un punto di vista ingegneristico e l'obiettivo riguarda il miglioramento di aspetti tecnici legati alle prestazioni, alla producibilità o alla sostenibilità.

In quest'ultimo caso, l'ottimizzazione può assumere una natura divergente o convergente a seconda che gli obiettivi di valutazione siano prevalentemente codificabili e modellabili dal software, oppure includano in larga parte dimensioni qualitative non formalizzabili all'interno della funzione di fitness (come lo stile o la simbologia del marchio), associate a livelli più elevati di U-oD. Ne deriva che, qualora il livello di U-oD non sia trascurabile, tali aspetti richiedono una gestione separata nella fase convergente, affidata esclusivamente al progettista senza il supporto diretto del software.

Per questi motivi, nella fase di ottimizzazione il Generative Design può svolgere un ruolo di supporto alla fase divergente quando l'obiettivo è generare un insieme di soluzioni alternative, tutte progettualmente valide, ciascuna ottimizzata rispetto ai requisiti tecnici e caratterizzata da un diverso bilanciamento dei compromessi prestazionali tra le variabili di progetto. Tuttavia, nei casi in cui il livello di U-oD aumenta, l'utilizzo dello strumento si limita ad ampliare lo spazio delle soluzioni ammissibili, mentre la convergenza finale del processo rimane affidata al progettista, poiché dipende in larga parte da valutazioni non formalizzabili all'interno del software. È il caso, ad esempio, della A.I. Chair e degli accessori sviluppati da Volkswagen, nei quali la convergenza finale della fase di ottimizzazione richiede un'analisi critica e un successivo intervento di adattamento e rifinitura manuale, finalizzati a rendere le soluzioni coerenti con l'immagine identitaria del brand. Nonostante la natura divergente di questa fase, l'algoritmo svolge comunque un task di tipo CNTR all'interno del ciclo di ottimizzazione, in quanto genera le alternative attraverso iterazioni alternate di generazione e valutazione, guidate dai vincoli codificabili nella fitness, scartando le soluzioni peggiori e mostrando solo quelle efficaci.

Al contrario, quando gli obiettivi di valutazione progettuale riguardano prevalentemente variabili che il software è in grado di modellare, lo strumento assume un ruolo di supporto anche alla fase convergente. Nel caso delle pinne Decathlon, ad esempio, gli obiettivi principali erano riconducibili a variabili misurabili, come la prestazione propulsiva in acqua e la compatibilità con materiali sostenibili, rendendo il Generative Design adatto anche a supporto della fase convergente, al netto della rifinitura finale da parte del progettista per rendere il prodotto coerente con il profilo aziendale.

Quadrante C

Il Quadrante C si contraddistingue per un'elevata complessità progettuale negli ambiti scientifico e ingegneristico (S&E-oD), a fronte di una marginale rilevanza attribuita ai bisogni di interazione percettiva dell'utente negli obiettivi di progetto. In termini di S&E-oD, si tratta di prodotti o componenti in cui la combinazione dei livelli assunti dai sotto-fattori relativi al behaviour strutturale e a quello dei singoli elementi, determina uno sforzo progettuale complessivamente elevato.

I casi riconducibili a questo quadrante possono riferirsi a componenti monofunzionali la cui ottimizzazione interna risulta altamente complessa, caratterizzati da uno o più obiettivi progettuali da bilanciare, specificatamente riferiti ad un unico dominio funzionale. Rientrano in questa categoria componenti ingegneristici core e critici all'interno di sistemi articolati, che ne costituiscono il cuore funzionale o strutturale, come nel caso della struttura del lander planetario NASA, del supporto motore per Cessna, del Turbine Centre Frame (TCF) per motori a turbina a gas di General Electric, nonché applicazioni in ambito software, come il coding avanzato di JetBrains, IBM e Red Hat o, nella R&S, la prototipazione proteica basata su AI di Evozyne con NVIDIA.

D'altro canto, il quadrante comprende sistemi costituiti da una pluralità di componenti con funzioni eterogenee, nei quali, oltre al corretto funzionamento dei singoli elementi, ciascuno caratterizzato da un proprio livello di

complessità, risulta necessario garantire la compatibilità tra obiettivi funzionali differenti e la coerenza complessiva del sistema, assicurandone il behaviour globale. Rientrano in questa categoria casi quali Siemens, GKN Aerospace e Dassault Systèmes.

Quest'ultimo, pur condividendo un'elevata complessità S&E-oD con gli altri esempi riconducibili al Quadrante C, si colloca nel Quadrante E. Ciò è attribuibile al fatto che l'azienda progetta prevalentemente sistemi complessi destinati all'uso diretto da parte dell'utente, richiedendo pertanto un posizionamento caratterizzato da un livello di U-oD più elevato. Al contrario, nei casi riconducibili al Quadrante C, l'interazione con l'utente è prevalentemente indiretta o mediata; di conseguenza, i requisiti di interazione non assumono il ruolo di obiettivi progettuali primari, ma vengono al più tradotti in specifiche tecniche da modellare al fine di garantirne il rispetto.

Una prima tipologia di AI utilizzata in questo quadrante riguarda, analogamente ai casi dei quadranti precedenti, il Generative Design, che anche in questo caso integra tecniche quali algoritmi evolutivi, ottimizzazione topologica, ottimizzazione multi-obiettivo e multi-fisica, supportate da moduli di machine learning in grado di guidare l'ottimizzazione sulla base delle informazioni apprese da simulazioni e progetti passati. Questo impiego emerge in casi come General Electric Aviation, la tesi sul supporto motore per Cessna 172, NASA e Siemens.

Tuttavia, nonostante tali algoritmi siano teoricamente adatti a modellare le variabili associate agli obiettivi progettuali di questi casi, quando i prodotti diventano di grandi dimensioni, estremamente complessi e critici in termini di impatto sul sistema complessivo o, in modo mediato sull'utente, il Generative Design tende a essere utilizzato prevalentemente come fonte di ispirazione ingegneristica. Il suo ruolo si limita pertanto alle attività di idea generation o, al più, al supporto della fase divergente della concept optimization, mentre il suo contributo alla fase convergente del processo risulta, nella maggior parte dei casi, marginale.

Nei casi limite in cui viene impiegato con finalità convergenti, il suo utilizzo risulta tipicamente circoscritto alle fasi di progettazione concettuale preliminare, e non si estende alle fasi di dettaglio e di sviluppo avanzato. In queste ultime, infatti, le decisioni progettuali devono confrontarsi con vincoli realistici e con modelli di elevata accuratezza che, a questo livello di complessità, tali strumenti non sono in grado di garantire. Ad esempio, software come Autodesk Fusion 360 supportano principalmente vincoli e carichi semplificati e non consentono di considerare fenomeni complessi quali fatica, vibrazioni o carichi distribuiti, fondamentali da considerare nelle fasi più avanzate della progettazione.

Un altro limite di questa tecnica, quando applicata per questa tipologia di prodotti, riguarda la tendenza a generare configurazioni monolitiche e fortemente integrate che, nel caso di strutture grandi e critiche, può risultare sconveniente, data la bassa riparabilità ad esse associata.

Un ragionamento analogo può essere esteso alla produzione additiva, ampiamente adottata nei casi riconducibili al Quadrante B, relativi a prodotti di dimensioni contenute e a minore criticità, ma meno frequentemente impiegata per i prodotti del quadrante in esame. In questi contesti, infatti, la produzione additiva risulta spesso inadatta a causa della presenza di limitazioni vincolanti quali: costi che diventano elevati, potenziali difetti microstrutturali e tensioni residue (soprattutto nel caso di componenti di grandi dimensioni). Di conseguenza, tale tecnologia si dimostra maggiormente idonea alla realizzazione di componenti strutturalmente contenuti e destinati alla produzione in serie, mentre risulta meno efficace per strutture di grandi dimensioni, ad elevata criticità e destinate a contesti applicativi di nicchia.

Per questi motivi, l'adozione di approcci di design generativo come guida del processo progettuale, per questa tipologia di prodotti, introduce alcune problematiche anche in termini di producibilità. Le geometrie complesse e fortemente articolate che ne risultano richiedono infatti l'integrazione di più processi produttivi tradizionali o il ricorso a soluzioni specifiche alternative alla manifattura additiva. Tuttavia, tali processi non risultando adeguati alla realizzazione efficiente di geometrie di questa natura, determinano un incremento dei costi di produzione e incidono negativamente sulla fattibilità complessiva delle soluzioni, quando progettate con il design generativo.

Nel complesso, ne consegue che, per prodotti appartenenti a questo quadrante, l'applicabilità del Generative Design risulta efficace soprattutto nelle fasi esplorative divergenti e preliminari design, caratterizzate da decisioni meno definitive e da requisiti vincolanti meno stringenti, con l'obiettivo di orientare la direzione progettuale

piuttosto che definire soluzioni finali, lasciando successivamente al progettista il compito di adattare e consolidare le proposte in funzione della fattibilità tecnica e produttiva, tramite il ricorso ad altri strumenti.

In questo senso, il ruolo operativo assunto dallo strumento si discosta da quello del Quadrante B adiacente, configurandosi come AUG/SUP anziché come AUG, mentre coincide con quello osservabile nel Quadrante I, sebbene per motivazioni di natura differente. Da un lato, lo strumento mantiene un ruolo di tipo AUG, in quanto è in grado di eseguire calcoli complessi difficilmente affrontabili con approcci manuali e con una rapidità non comparabile, oltre a potenziare la capacità esplorativa del progettista mediante la generazione di soluzioni e geometrie guidate dai vincoli, difficilmente concepibili in modo autonomo. Dall'altro lato, assume un ruolo di tipo SUP, poiché il progettista rimane centrale nella guida del processo progettuale, utilizzando i risultati computazionali e le proposte generate dallo strumento come uno dei molteplici input a supporto delle decisioni. L'intervento umano risulta determinante nelle fasi centrali e finali del processo, in cui il progettista si occupa direttamente dell'ottimizzazione di dettaglio e della verifica della fattibilità e producibilità delle soluzioni, anche attraverso l'impiego di strumenti di simulazione separati. In questo contesto, emergono frequentemente approcci ibridi alla progettazione, dove alcune fasi vengono potenziate dallo strumento, altre rimangono sotto il controllo esclusivo del progettista, come nel caso dell'applicazione aeronautica del motore per Cessna 172.

Qualora, nel processo progettuale, aumenti il numero di obiettivi e vincoli da considerare simultaneamente, come nel caso di componenti soggetti a fenomeni fisici di diversa natura che si influenzano reciprocamente, si fa riferimento al Generative Design multi-fisico. Un approccio che consente a un algoritmo generativo di esplorare automaticamente molteplici soluzioni geometriche, valutandole rispetto a più fenomeni fisici (ad esempio strutturali, termici e fluidodinamici), anziché limitarsi ai soli aspetti strutturali quali peso e resistenza. Tale variante del Generative Design avvicina il design concettuale a riflessioni proprie del design di dettaglio preliminare, grazie a una visione più complessiva e applicativa del componente fin dalle prime fasi di progetto.

All'interno dello stesso quadrante si collocano anche altri strumenti di AI, tra cui i LLM generativi basati su architettura Transformer. Tali modelli vengono impiegati per tokenizzare concetti tecnici, quali ad esempio funzioni e brevi script di codice, amminoacidi o molecole, componenti elettronici, moduli e componenti meccanici, all'interno di sequenze che rappresentano il funzionamento dei sistemi da progettare, come programmi informatici, proteine o composizioni molecolari, schede elettroniche PCB e assiemi meccanici, di cui numerosi esempi costituiscono il dataset di addestramento del modello.

Addestrati su questi dataset, i modelli apprendono la grammatica strutturale dei sistemi e sono in grado di generare nuove soluzioni o ricombinazioni coerenti, in modo analogo a quanto avviene per gli LLM tradizionali nella generazione di frasi grammaticalmente corrette a partire dal training su grandi quantità di dati testuali.

Un esempio è rappresentato dal caso FlecheTech per la progettazione di PCB elettroniche, in cui, a partire da requisiti espressi in linguaggio naturale, il sistema combina componenti associati a specifiche funzioni per dare origine a prototipi di schede in grado di rispondere alle esigenze funzionali complessive richieste.

Analogamente, Leo AI propone combinazioni di componenti meccanici ottimizzate nel rispetto di vincoli fisici, meccanici e di producibilità, in linea con i principi di Design for Manufacturing (DFM) e Design for Assembly (DFA), dando origine a un Large Mechanical Model (LMM), ovvero un LLM adattato al dominio dell'ingegneria meccanica. Automatizzando attività ripetitive e computazionalmente onerose consente ai progettisti di concentrarsi sugli aspetti più esplorativi e creativi della progettazione meccanica.

Casi analoghi si riscontrano anche nell'ambito dello sviluppo software, come nelle applicazioni di JetBrains e nei casi di IBM, Red Hat e GKN Aerospace, che utilizzano LLM per supportare la composizione e l'ottimizzazione di codice informatico. In questi scenari, i modelli assistono nella generazione di programmi completi e nuovi servizi software, ottenuti dalla ricombinazione originale di frammenti di codice preesistenti, sempre sotto la guida di prompt espressi in linguaggio naturale e con la validazione continua da parte dei progettisti.

Nel campo della ricerca scientifica, un esempio significativo è rappresentato da Evozyne in collaborazione con NVIDIA, che attraverso il modello ProT-VAE combina architetture Transformer e Variational Autoencoder per generare milioni di nuove sequenze proteiche in pochi secondi. Variando le sequenze di amminoacidi, questo approccio consente l'esplorazione di funzioni proteiche potenzialmente inedite. I Transformer vengono adattati all'analisi delle sequenze proteiche sfruttando la loro capacità di catturare pattern complessi e relazioni a lungo

raggio, mentre il VAE permette di generare nuove sequenze simili a quelle di addestramento, caratterizzate da una variabilità controllata, all'interno di uno spazio latente continuo delle soluzioni dove è possibile interpolare nuove plausibili configurazioni

Un ulteriore ambito di utilizzo dei LLM riguarda applicazioni riconducibili prevalentemente a task di NLP, declinate in funzione del contesto specifico. In alcuni casi, i modelli sono impiegati come strumenti di produttività, ad esempio per la redazione di reportistica di progetto, come ad esempio i report HSE (Health, Safety, Environment) come evidenziato nelle applicazioni di GKN Aerospace, GKN Fokker, SKF e C3. In altri, vengono utilizzati per semplificare la comprensione e l'utilizzo di software ingegneristici complessi, come in Siemens. Ad esempio, supportano attività di interrogazione tecnica e recupero della conoscenza, facilitano la comprensione del funzionamento degli strumenti, l'individuazione del software più appropriato per uno specifico problema ingegneristico o la traduzione di requisiti espressi in linguaggio naturale direttamente in soluzioni progettuali (FlecheTech), o in valori parametrici utilizzati per inizializzare e guidare processi di Generative Design vincolato. Tali approcci consentono anche a figure meno esperte di partecipare a ruoli progettuali, favoriscono la progettazione assistita e migliorano il coordinamento e la comunicazione all'interno di contesti altamente tecnici.

In altri casi, più strettamente orientati alla fase convergente del processo progettuale, vengono adottati modelli di machine learning predittivi che fungono da surrogati di simulazioni numeriche lunghe e computazionalmente onerose. Questi modelli permettono di indirizzare la valutazione delle soluzioni durante i cicli di ottimizzazione, ad esempio suggerendo nuovi valori delle variabili di progetto per guidare le iterazioni successive o semplicemente svolgendo uno screening preliminare delle opzioni da mandare avanti.

Pur non sostituendo la validazione finale, che resta affidata a simulazioni e analisi fisiche complete, tali modelli consentono di ridurre significativamente il numero di soluzioni da simulare, portando a validare esclusivamente le opzioni più promettenti, come evidenziato nel caso di GKN Aerospace.

Dal punto di vista del ruolo operativo, l'impiego di questi strumenti si divide tra casi di AUG/SUP e altri che si limitano a SUP.

Il ruolo AUG/SUP si manifesta prevalentemente nella fase divergente del processo, in quanto consente la generazione di migliaia di nuove combinazioni, potenziando in modo significativo la capacità esplorativa della ricerca e della progettazione tecnica, in tempi non riproducibili umanamente. Tuttavia, trattandosi di componenti core e altamente critici e complessi, analogamente a quanto osservato per il Generative Design, permane la centralità del progettista nel processo, anche nelle fasi divergenti.

In alcuni casi, pur intervenendo nella fase divergente, lo strumento fornisce un contributo limitato, orientato principalmente all'automazione e all'efficientamento di attività ripetitive e di minor valore. Considerato il suo apporto complessivo all'interno della fase progettuale in cui è inserito, il ruolo operativo si configura come esclusivamente SUP, lasciando al progettista la responsabilità di guidare e pianificare la progettazione della maggior parte della fase.

Lo stesso ruolo viene mantenuto anche nelle fasi convergenti, nelle quali la combinazione tra l'elevata complessità del prodotto e la natura critica della fase rende il processo particolarmente delicato, richiedendo che la responsabilità finale delle scelte resti, come negli altri quadranti e in questo caso in misura ancora maggiore, esclusivamente in capo al progettista.

Quadrante D

Nel Quadrante D si osserva, a parità di livello di S&E-oD, un incremento del livello di U-oD rispetto al Quadrante C. In ragione dell'elevato livello di S&E-oD che permane, in questa sezione si collocano contesti di sviluppo prodotto in cui la progettazione riguarda componenti funzionalmente core o caratteristiche critiche del sistema complessivo, aspetti che orientano la progettazione prevalentemente verso il perseguimento di obiettivi di natura tecnica. In ambito ingegneristico, questi coincidono con il raggiungimento di elevate prestazioni, l'efficientamento energetico e l'ottimizzazione in funzione della producibilità e del DFM, oppure, con l'adozione di un elevato rigore scientifico nella formulazione di nuove molecole o composti in ambito R&D.

Contestualmente, sebbene con priorità minore rispetto alla dimensione tecnica, poiché tali soluzioni sono integrate in prodotti che producono effetti diretti su sotto-fattori connessi all'interazione con l'utente, emerge la

necessità di includere nella progettazione complessiva anche obiettivi riconducibili a requisiti di natura funzionale ed esperienziale, legati alla dimensione percettiva dell'utilizzatore (U-oD).

Un esempio rappresentativo di questo inquadramento prende forma nella mappa sviluppata da Moodify, che correla composti odorosi e dati percettivi degli utenti al fine di supportare la formulazione di nuove fragranze. In modo analogo, Eaton, orienta la progettazione allo sviluppo di soluzioni ad elevata efficienza energetica, nel rispetto di obiettivi di riciclabilità e di riduzione delle emissioni, che incidono sulle aspettative di sostenibilità ambientale degli acquirenti, affiancati da obiettivi di contenimento dei costi che influenzano il prezzo finale del prodotto e, di conseguenza, le aspettative e la disponibilità economica dei consumatori.

Anche in questo caso, risultano supportate diverse fasi che compongono il processo progettuale. Nella fase convergente, ad esempio, i modelli LLM della famiglia GPT sono utilizzati da Moderna come strumenti di screening preliminare nel concept evaluation, a supporto della raccomandazione dei dosaggi più promettenti e della riduzione del numero di alternative da sottoporre a processi di testing spesso lunghi e costosi. Ciò è reso possibile dalla loro capacità di sintetizzare e interpretare documentazione eterogenea e frammentata, grazie a cui possono fornire raccomandazioni giustificate dalle fonti affidabili fornite. Gli stessi modelli, quando specializzati per compiti di strutturazione (STR) piuttosto che di controllo (CNTR) come nel caso precedente, sono impiegati anche per attività di produttività, quali l'analisi di contratti e vincoli regolatori, contribuendo ad accelerare fasi operative e di pianificazione.

Sempre nella fase convergente, agli LLM si affiancano altri strumenti di AI, come modelli di machine learning predittivo, utilizzati come surrogati nei processi di valutazione intermedia tra cicli successivi di ottimizzazione, prima della valutazione finale completa.

Nel caso di Moodify, i modelli analizzano le correlazioni tra le combinazioni di ingredienti nei composti odorosi e gli effetti percettivi sull'utente, suggerendo possibili sostituzioni in base alle relazioni apprese. L'obiettivo è raggiungere una funzione specifica, come la neutralizzazione di un odore o il mantenimento dell'effetto percettivo a fronte di variazioni nella composizione. Le proposte tengono conto anche di requisiti di contorno normativi, di inventario, di costo e di impatto ambientale che, in contesti di mercato dinamici, possono cambiare e richiedere la sostituzione di alcuni ingredienti. Da queste evidenze emerge come alcune variabili concettuali entrino a far parte degli obiettivi progettuali solo successivamente alla soddisfazione delle prestazioni tecniche, il cui adempimento è prioritario per garantire la realizzazione delle funzioni primarie.

Un ulteriore insieme di strumenti valutativi è rappresentato dai modelli generativi grafici integrati nei sistemi di simulazione ingegneristica, impiegati per visualizzare e prevedere il funzionamento dei moduli funzionali e delle loro interazioni. È il caso di Ferrari, dove simulazioni fisiche basate su dati storici aziendali, gestiti tramite infrastrutture cloud IaaS e servizi ML di tipo PaaS offerti da AWS, vengono affiancate da componenti di AI generativa finalizzate a semplificare la visualizzazione e, di conseguenza, la valutazione di sistemi complessi.

Un approccio analogo è adottato da Eaton, che combina software deterministici con simulazioni delle prestazioni fisiche e analisi numeriche di costi, impatto ambientale e producibilità, generando soluzioni compatibili con i principi di DFM e DFA. I risultati di tali simulazioni vengono successivamente utilizzati per l'addestramento di moduli di AI generativa, impiegati per la generazione vincolata di soluzioni tecniche coerenti con gli obiettivi di progetto appresi dai dati.

Di conseguenza, nel quadrante in esame emerge anche una fase divergente supportata dall'AI generativa, resa possibile dall'addestramento dei modelli su progetti e simulazioni pregresse, che incorporano e trasferiscono le logiche di progettazione e di valutazione acquisite a partire da dati pregressi.

In ambito di ricerca e sviluppo, approcci divergenti analoghi sono adottati anche da L'Oréal, Estée Lauder e Nestlé nell'idea generation delle ricette, quando la progettazione è considerata dal punto di vista delle formulazioni chimiche o nutrizionali, piuttosto che nella fase di definizione concettuale del prodotto commerciale, per la quale è prevista una collocazione specifica nel Quadrante F.

In questi casi tuttavia, l'AI generativa, pur essendo addestrata su corpora testuali aziendali, mantiene una natura generalista e non è in grado di modellare relazioni tecniche formali in modo rigoroso. Ciò ne limita l'efficacia nel supporto alla generazione di soluzioni tecniche orientate a funzioni o prestazioni specifiche, rendendola meno

adatta a questo quadrante e più efficace per le applicazioni concettuali del quadrante F, dove prevale la dimensione creativa rispetto al rigore tecnico richiesto in questa area.

Al contrario, esistono casi in cui l'AI generativa è addestrata e progettata per rispondere a finalità specifiche, risultando idonea a supportare la fase divergente dello sviluppo di prodotti anche di natura prevalentemente tecnica, come quelli presenti in questo quadrante. In particolare, si tratta di modelli transformer-based che operano in modo analogo agli LLM nella modellazione di sequenze testuali, ma che sono addestrati su corpora strutturati di formulazioni, nei quali i componenti risultano tokenizzabili e le relazioni tecniche, chimiche o biologiche possono essere apprese dal dataset di training. In tali condizioni, il loro impiego risulta efficace nella generazione di un insieme di soluzioni tecniche progettualmente valide, dove l'AI supporta principalmente attività di idea generation e combination, mentre le fasi di ottimizzazione sono generalmente demandate a strumenti più rigorosi nelle fasi successive del processo.

Sebbene nel Quadrante C fosse riscontrabile un'applicazione formalmente analoga di questo tipo di modelli, come nel caso di Evozyne con NVIDIA per la progettazione di nuovi composti molecolari, il posizionamento in quel quadrante era determinato dalla natura prevalentemente scientifica ed esplorativa dell'attività, non guidata da un obiettivo applicativo definito. La ricerca risultava infatti orientata alla generazione di conoscenza inedita, con potenziali ambiti di applicazione eterogenei, dal medico all'ambientale. Nel quadrante qui considerato, al contrario, la progettazione è finalizzata a uno scopo applicativo esplicito e orientata al soddisfacimento di un bisogno funzionale dell'utente, determinando un diverso posizionamento all'interno della matrice, pur in presenza di analogie a livello di strumento adoperabile e di approccio computazionale più idoneo.

Rientrano in questa categoria i casi di P&G con Basecamp Research, che impiegano modelli assimilabili agli LLM applicati a sequenze amminoacidiche per individuare nuovi enzimi destinati a detergenti efficaci anche a basse temperature, con l'obiettivo di ridurre l'impatto ambientale dei lavaggi, e di IBM con Nestlé, che hanno sviluppato un Regression Transformer per identificare nuove strutture molecolari destinate a materiali di imballaggio sostenibili, capaci di garantire al contempo protezione e conservazione degli alimenti.

In questo quadrante, il ruolo operativo dello strumento si configura come AUG/SUP nelle attività di generazione, poiché amplia la capacità di esplorare combinazioni e correlazioni su volumi di dati non gestibili manualmente, favorendo l'emergere di soluzioni scientifiche e ingegneristiche plausibili, in quanto guidate dai vincoli di dominio appresi, ma limitatamente alle fasi iniziali della divergenza.

Nelle fasi decisionali convergenti invece, il ruolo rimane prevalentemente SUP, a causa dell'elevato livello di S&E-oD e della criticità associata alla natura decisiva di tale fase. Ne consegue che il giudizio dell'esperto resta centrale nella valutazione, validazione e adattamento delle soluzioni ai vincoli concreti, non pienamente modellabili dagli strumenti di AI, soprattutto nelle fasi più avanzate e definitive del processo progettuale.

Quadrante E

In prossimità del vertice della matrice, in cui entrambe le direzioni progettuali assumono valori elevati, si colloca il Quadrante E, che comprende prodotti per i quali, all'interno delle dinamiche progettuali, coesistono un'elevata complessità ingegneristica e un'attenzione altrettanto marcata verso gli aspetti legati all'interazione diretta con l'utente. Spesso coincidono con sistemi che integrano moduli funzionalmente eterogenei ma interdipendenti, caratterizzati dalla presenza di molteplici layer infrastrutturali hardware e software, progettati per cooperare nella generazione sia di prestazioni funzionali, sia di esperienze d'uso interattive, come nel caso di dispositivi per la smart home, robot domestici, wearable ed elettronica personale.

In contesti di questo tipo, la progettazione di dettaglio dei diversi moduli funzionali, quando internalizzata all'interno dell'organizzazione, richiede il coordinamento tra team tecnici appartenenti a discipline eterogenee. Di conseguenza, anche gli strumenti di supporto alla progettazione devono non solo rispondere alle esigenze specifiche dei singoli domini, ma anche garantire la coerenza sistemica complessiva degli output prodotti. Ciò avviene, ad esempio, attraverso l'integrazione in ambienti di sviluppo estesi, come piattaforme collaborative interne all'azienda, pensate specificatamente per agevolare il rispetto dei vincoli di compatibilità e di integrazione tra sottosistemi.

La presenza di un elevato livello di U-oD richiede che la progettazione integri, con una priorità comparabile al conseguimento degli obiettivi prestazionali legati al comportamento tecnico del sistema, anche requisiti di natura funzionale, strutturale ed esperienziale, i quali risultano spesso in tensione con le logiche ingegneristiche. Ne deriva una progettazione fortemente multidimensionale, che necessita da un lato di strumenti altamente specializzati e, dall'altro, di piattaforme interoperabili e compatibili con gli strumenti specifici, in grado di rendere compatibili gli output della progettazione ingegneristica e di quella design-oriented.

È infine rilevante osservare come, anche quando l'obiettivo progettuale riguarda una specifica caratteristica del prodotto, prevalentemente collocabile lungo uno dei due orientamenti, le scelte progettuali ad essa associate non possano essere considerate indipendenti dagli effetti che esse producono sulle caratteristiche riconducibili all'altro orientamento progettuale, poiché il prodotto si configura come un sistema complesso in cui le due dimensioni possono influenzarsi reciprocamente. Ciò implica, ad esempio, che l'ottimizzazione di un componente o di una configurazione di sistema non possa prescindere dalla valutazione degli effetti sull'esperienza e sulle aspettative dell'utente, e viceversa. Tale interdipendenza rende particolarmente complesso l'impiego di un singolo strumento di AI, generalmente addestrato o adattato per risultare compatibile con obiettivi riferiti a un singolo dominio alla volta. La difficoltà di bilanciare fattori eterogenei, talvolta in sinergia e talvolta in contrapposizione, contribuisce a spiegare perché i casi riconducibili a quest'area della matrice siano ancora limitati e configurino applicazioni di frontiera.

Un esempio significativo emerso dalla ricerca empirica è rappresentato da Dassault Systèmes, il quale propone un tentativo di gestione di tale complessità all'interno di un'unica piattaforma collaborativa mediante un approccio di Generative MBSE (Model-Based Systems Engineering).

Questo caso risulta emblematico in quanto evidenzia come l'AI possa supportare una progettazione sistemica coerente attraverso l'impiego di strumenti fondati su una base dati condivisa che riflette le correlazioni tra configurazioni tecniche, prestazioni e feedback degli utenti. La convergenza su un'unica piattaforma consente infatti di rendere compatibili i due orientamenti progettuali e di coordinare contributi disciplinari differenti.

Nella fase di strutturazione del problema, modelli di machine learning elaborano dati provenienti da prodotti pregressi, quali dati di utilizzo, log dei sensori e segnalazioni di guasto, a supporto della definizione dei requisiti dei nuovi sistemi. Nella fase convergente, il reasoning semantico permette di mettere in relazione le aspettative degli utenti, le prestazioni storiche dei prodotti e le configurazioni tecniche associate, consentendo la validazione delle soluzioni generate rispetto a entrambi gli orientamenti progettuali.

A supporto delle attività di valutazione e ottimizzazione, moduli di AI generativa grafica, addestrati su dati di progetto pregressi, forniscono visualizzazioni del funzionamento interno dei blocchi funzionali e delle loro interazioni. Ciò favorisce la comprensione del sistema sia a livello di singolo modulo sia di architettura complessiva, consentendo il passaggio da una rappresentazione di tipo *black box* a una trasparente di tipo *white box*. Tali visualizzazioni, integrate in simulazioni intelligenti, permettono di individuare incongruenze o criticità di alto livello, che vengono successivamente reinserite nel ciclo di apprendimento per il progressivo affinamento del modello.

L'elaborazione congiunta di dati, simulazioni e correlazioni semantiche consente infine di supportare anche la fase divergente, guidando la generazione di configurazioni e soluzioni attraverso modelli di AI generativa, sia grafici sia linguistici.

A causa dell'elevato livello di complessità e della criticità delle scelte progettuali coinvolte, e considerando che l'AI interviene prevalentemente in attività di sostegno alla valutazione decisionale, il suo ruolo si configura principalmente come SUP. Essa contribuisce infatti a semplificare ed efficientare il processo, rendere visualizzabili le configurazioni e i relativi effetti, anche in forma condivisa tra più soggetti, può formulare suggerimenti sulla base delle correlazioni apprese, ma i protagonisti del processo rimangono i progettisti. Inoltre, per risultare compatibile con orientamenti progettuali differenti lo strumento tende a perdere specificità, facendo sì che gli output prodotti richiedano comunque un adattamento successivo. Ciò rafforza i limiti del suo ruolo, per il momento riconducibile al solo supporto.

Quadrante F

Per quanto riguarda il quadrante F, esso è definito da un livello medio di S&E-oD e da un livello elevato di U-oD; ne deriva un posizionamento che, a parità di U-oD, lo rende spostato verso sinistra rispetto al quadrante E, indicando un livello inferiore di S&E-oD, mentre, rispetto al quadrante I, lo colloca su livelli di U-oD più elevati a parità di complessità tecnico-ingegneristica.

Tra i quadranti della matrice, quello per cui il confronto con F risulta più significativo è il quadrante D. I due quadranti possono infatti rappresentare, in molti casi, dimensioni complementari della progettazione degli stessi prodotti. Nel quadrante D, l'attività progettuale si concentra su componenti o caratteristiche funzionalmente core, caratterizzate da un'elevata complessità di progettazione tecnica, i cui effetti si riflettono anche sul livello di interazione con l'utente, sebbene in modo prevalentemente indiretto.

Nel quadrante F, al contrario, l'attenzione è rivolta alla progettazione concettuale e agli aspetti più periferici, relativi alle forme superficiali e ai tratti esperienziali del prodotto, ovvero quelli con cui l'utente interagisce in maniera immediata. Tuttavia, collocandosi in corrispondenza di una zona della matrice in cui risiedono prodotti il cui behaviour è influenzato da un certo grado di rigore tecnico, anche tali scelte concettuali devono necessariamente rimanere compatibili con i vincoli tecnici sottostanti e con le conseguenze che esse producono sul versante ingegneristico.

Se si considera invece la collocazione del quadrante F rispetto al quadrante E, il livello inferiore di S&E-oD comporta una riduzione parziale dell'interdipendenza tra gli effetti delle scelte progettuali riferite a caratteristiche riconducibili a orientamenti differenti. Ciò consente alla dimensione U-oD un maggiore margine di svincolamento dai tecnicismi ingegneristici, favorendo una più ampia libertà creativa nella definizione delle forme e una maggiore apertura esplorativa nella progettazione delle feature concettuali.

È inoltre rilevante osservare come la progettazione concettuale, che in questo quadrante assume un ruolo prevalente in virtù della volontà di rendere i bisogni di interazione dell'utente l'elemento centrale e caratterizzante dello sviluppo di prodotto, non si fonda esclusivamente su informazioni di natura market-side. Accanto alle preferenze dei consumatori, essa integra infatti variabili di tipo supply-side, quali il contesto competitivo, i trend tecnologici, i vincoli regolatori brevettuali, che assumono un peso altrettanto rilevante nella definizione dei concept. Tali fattori operano sia come requisiti nella fase di generazione delle idee, sia come criteri di valutazione delle soluzioni concettuali proposte.

Nell'idea generation assume un ruolo centrale la Generative AI, spesso basata su LLM e modelli GPT, con relative estensioni multimodali (text-to-text, text-to-image, image-to-image), impiegate per esplorare concept visivi e soluzioni coerenti con esigenze funzionali, esperienziali e sensoriali, oltre che con preferenze estetiche dei clienti.

Questo è ciò che emerge in casi di studio quali la definizione degli esterni automotive in Ferrari, l'esplorazione di funzionalità e forme per componenti esterni del trattore elettrico di Yamaha Motor con Final Aim, concept di prodotti cosmetici come in L'Oréal ed Estée Lauder e di largo consumo come in Nestlé e Colgate-Palmolive, fino alla customizzazione lato cliente tramite il car configurator di AWS con Ferrari.

Il caso Yamaha-Final Aim è esemplare della dinamica evolutiva dei prodotti all'interno dei quadranti della matrice. L'uso dell'AI generativa consente infatti di reinterpretare il trattore elettrico, tradizionalmente definito da caratteristiche prevalentemente funzionali e prestazionali, associandovi nuovi fini progettuali. Grazie alle capacità esplorative della gen AI, è stato possibile enfatizzare anche sotto-fattori esperienziali e delle forme, che, nel rispetto dei requisiti funzionali essenziali, hanno determinato uno spostamento della collocazione del prodotto, rispetto a quello che tipicamente sarebbe risultato idoneo nel caso di tecniche di progettazione tradizionale del veicolo.

Il medesimo esempio del trattore consente di mettere in luce un ulteriore elemento di interesse, già menzionato nella trattazione del quadrante D. Quando le idee generate riguardano prodotti che, sul piano tecnico, devono essere producibili e ingegneristicamente affidabili, il contributo dell'AI generativa tende a concentrarsi prevalentemente nelle fasi di early design. Nella transizione verso la concretizzazione delle soluzioni, in termini di prestazioni, fattibilità produttiva e vincoli reali, diventa infatti imprescindibile l'intervento del progettista, che opera attraverso

strumenti tradizionali e ambienti di modellazione dedicati (ad es. CAD/3D) per tradurre i concept in soluzioni implementabili.

Nel complesso, poiché questo quadrante si concentra sulla controparte concettuale della progettazione di prodotti la cui fase di sviluppo tecnico ricade nel quadrante D, risultano pertinenti considerazioni analoghe a quelle già discusse in quella sede.

In particolare, quando i prodotti sono dotati di un nucleo tecnico sottostante che garantisce il suo funzionamento (ad esempio automobili, macchine agricole o formulazioni cosmetiche), l'AI generativa viene impiegata soprattutto nelle fasi preliminari del processo, a supporto dell'ideazione del concept, offrendo spunti tramite brainstorming conversazionale e generazione visiva, anche attraverso cicli iterativi di affinamento basati su modifiche condizionate. L'efficacia di tale contributo tende ad aumentare al crescere della specificità del modello, ad esempio mediante training dedicato su dati aziendali, che consente di incorporare in modo implicito vincoli e prassi derivanti dai progetti pregressi.

Sebbene lo strumento sia più coerente con l'esplorazione concettuale del prodotto, così come intesa in questo quadrante, rispetto all'analisi più rigorosa dei tecnicismi propria del quadrante D, rimane invariata la conclusione secondo cui esso è inadatto alle fasi di finalizzazione della soluzione, in cui il concept viene reso compatibile con vincoli reali e di producibilità tramite strumenti specialistici tipici delle fasi avanzate dello sviluppo.

Un'ulteriore considerazione pertinente a questa tipologia di prodotti riguarda la necessità di integrare la progettazione di caratteristiche eterogenee in un unico artefatto. Come già evidenziato nel quadrante E, anche per i quadranti D ed F vale la considerazione secondo cui tale eterogeneità comporta il ricorso a strumenti di intelligenza artificiale specialistici e differenziati, impiegati da team funzionali distinti. Ne deriva un processo progettuale che tende a mantenersi frammentato e poco organico, nonostante l'esigenza che team e output convergano verso un allineamento complessivo coerente. Da ciò discende la necessità di piattaforme collaborative capaci di rendere compatibili gli output generati da strumenti eterogenei e di abilitarne l'interoperabilità, assicurando al contempo una visualizzazione contestuale e aggiornata delle modifiche lungo fasi e attività differenti, come suggerito dall'esempio dimostrativo di Dassault Systèmes.

Si osservi, inoltre, che in questo quadrante rientrano anche attività di produttività, ricerca ed elaborazione orientate alla raccolta e all'analisi dei bisogni e delle informazioni di contesto, tipiche della fase di planning, finalizzate alla traduzione in requisiti lato domanda e lato offerta, che precedono e guidano direttamente il design concettuale. In tale ambito, gli LLM (in modalità image-to-text e text-to-text) supportano la ricerca, la sintesi e la strutturazione delle informazioni, nonché la definizione documentabile e la giustificazione dei requisiti, come nei casi Yamaha, Estée Lauder, Nestlé e Colgate-Palmolive. In quest'ultimo, l'impiego di RAG, contribuisce a ridurre il rischio di allucinazioni ancorando la generazione a fonti esterne esplicite e verificabili.

Nel caso di Estée Lauder, l'adozione della GenAI evidenzia inoltre il valore strategico del patrimonio di dati distribuito tra mercati e dipartimenti aziendali sugli esiti della progettazione. Nello specifico emerge che i modelli LLM generalisti risultano particolarmente adatti a organizzazioni grandi e distribuite, poiché garantiscono uniformità all'interno delle routines organizzative, mentre la specificità applicativa dei team viene ottenuta tramite istanze dedicate di modelli (es. GPT) o agenti specializzati per task, spesso pensati dai dipendenti dei dipartimenti e addestrati sui dati aziendali condivisi. Le organizzazioni di dimensioni minori tendono invece a privilegiare strumenti più verticali, coerenti con esigenze di standardizzazione più contenute.

Inoltre, anche in questa zona della matrice è presente una dinamica convergente, non intesa come momento di decisione finale, bensì come parte integrante dei cicli iterativi di ottimizzazione concettuale. In questo contesto, Estée Lauder cita, a titolo esemplificativo, l'impiego di LLM per lo screening qualitativo di ingredienti e dosaggi, basato sull'analisi documentale delle formulazioni, nelle fasi che precedono direttamente il testing dei prodotti, in modo analogo a quanto osservato per Moderna nel quadrante D.

Accanto a ciò, modelli di ML predittivo operano come surrogate model a supporto di valutazioni multicriterio, come nei casi Mondelez e Nestlé, suggerendo sostituzioni o variazioni compatibili con vincoli concettuali quali coerenza di brand, costo, impatto ambientale, profilo nutrizionale e fattibilità produttiva. Sebbene la valutazione e la selezione definitive restino in capo a ricercatori, panel sensoriali e figure di brand steward, gli algoritmi svolgono una funzione di filtraggio delle molteplici alternative. In questo quadro, alcune aziende, tra cui Mondelez,

manifestano cautela verso strumenti che abilitano un'ideazione eccessivamente divergente, come alcune tecniche generative, poiché i consumatori abituali tendono a premiare la novità solo quando rimane prossima al familiare, coerentemente con le strategie di brand extension.

Per quanto riguarda il ruolo operativo degli strumenti, il machine learning, abilitando predizioni basate sull'elaborazione di grandi moli di dati, svolgerebbe una funzione di augmentazione, poiché consente analisi e predizioni non riproducibili dall'uomo con pari efficienza. Tuttavia, le caratteristiche dello strumento e il contesto della fase valutativa in cui viene impiegato ridefiniscono il suo ruolo come semplice supporto (SUP). Infatti, anche se l'algoritmo consente di stimare alcune variabili numeriche, spesso non è in grado di cogliere altre dimensioni più qualitative e meno formalizzabili, che per loro natura richiedono una valutazione più sfumata, che solo il progettista esperto è in grado di gestire. Inoltre, in alcuni casi accade che anche quando si riescono a identificare delle metriche numeriche per tradurre alcuni aspetti qualitativi, tali stime non ne esauriscono completamente il significato e necessitano comunque di un'interpretazione soggettiva. Pertanto, il progettista è chiamato sia a interpretare criticamente le predizioni fornite dallo strumento, inclusi i risultati sulle variabili quantitative, sia a svolgere considerazioni a parte per variabili non codificabili dallo strumento, così che gli output dell'algoritmo rappresentano solo uno degli input del processo valutativo complessivo, che continua a essere guidato in larga misura dall'esperto, dalla sua intuizione e dalla conoscenza dei comportamenti, talvolta non razionali, delle forze che compongono il contesto di riferimento.

Relativamente all'utilizzo dell'AI generativa nelle fasi divergenti, questa interviene principalmente come strumento di ampliamento dello spazio esplorativo, fornendo stimoli e alternative concettuali. Il controllo del processo rimane in capo al progettista, che ne orienta l'impiego attraverso il prompting e mediante modifiche condizionali alle proposte di concept progressivamente generate, selezionando e adattando quelle ritenute valide per le fasi successive della progettazione, dove lo sviluppo è affidato ad altri strumenti specialistici. L'autonomia ancora limitata della GenAI e il suo impiego circoscritto nelle fasi di early design fanno sì che la sua capacità augmentativa resti vincolata a un utilizzo principalmente di supporto, configurandone quindi il ruolo operativo in posizione AUG/SUP.

Un ruolo analogo è svolto dagli LLM quando impiegati per task di produttività, ricerca e strutturazione delle informazioni nel planning. Sebbene consentano di individuare ed elaborare dati a una velocità non accessibile all'uomo, la definizione di cosa cercare, cosa selezionare e come interpretare i risultati resta sotto il controllo del soggetto umano.

Quadrante G

Il quadrante G, collocato in alto a sinistra della matrice (Uo-D alto, S&Eo-D basso), rappresenta quelle applicazioni dell'AI che si concentrano su contesti creativi e user-centered, come design concettuale, comunicazione, interazione e co-creazione con l'utente. Sul piano dell'orientamento Uo-D, i sotto-fattori più considerati sono quello esperienziale, strutturale e delle forme, mentre quello funzionale assume un rilievo secondario. Quest'ultimo, infatti, risulta spesso associato a requisiti prestazionali più stringenti, che richiedono una traduzione in specifiche e parametri progettuali la cui modellazione è più tipica di livelli S&E-oD superiori.

Nel caso di questo quadrante più che in altri, l'AI generativa assume un ruolo particolarmente efficace come stimolo creativo all'ideazione. Infatti, in questa zona la progettazione è prevalentemente orientata a soddisfare esigenze legate all'interazione dell'utente con il prodotto, in una forma più creativa e meno vincolata dal rigore del rispetto dei vincoli tecnici. Ne consegue un contesto progettuale in cui la divergenza dell'esplorazione creativa è maggiormente tollerata, risultando più flessibile rispetto a quanto avviene nei quadranti D ed E, nei quali i vincoli ingegneristici limitano questa apertura, anche quando applicati alle fasi preliminari e concettuali del design.

In merito all'impiego di modelli generativi visivi e linguistici a supporto di attività divergenti, gli strumenti sono utilizzati per la strutturazione ed elaborazione delle informazioni raccolte, per il brainstorming conversazionale finalizzato alla definizione dei requisiti e alla generazione critica di idee (text-to-text), nonché per la traduzione delle idee emerse in spunti visuali a supporto dell'idea generation (text-to-image), con cui viene inibito il blocco creativo iniziale, problematica tipica dei primi stadi dell'ideazione. Essi consentono inoltre di integrare idee, schizzi e immagini preliminari di prodotto a supporto del concept visualization, e di abilitare processi di idea combination e concept refinement attraverso modifiche iterative delle generazioni virtuali create,

guidate da sequenze rapide di prompt. L'implementazione delle modifiche (in modalità text-to-image, image-to-image) viene abilitata mediante la combinazione di più immagini, la preservazione della coerenza stilistica tra generazioni successive e infine, tramite operazioni di editing espresse in linguaggio naturale, il tutto comunicato tramite interfaccia conversazionale e raffigurativa che rende la traduzione delle esplicitazioni immediata.

Ancora una volta il designer mantiene la guida del processo, mentre lo strumento consente di ridurre il ricorso a interventi manuali e conseguentemente diminuisce tempi di esecuzione tipici delle attività che gli vengono affidate (ad es. nella produzione condizionata di schizzi), accollandosi anche parte del carico cognitivo che sarebbe richiesto al progettista. Inoltre, la rapidità di visualizzazione facilita la comunicazione con il cliente e la collaborazione interdisciplinare, abilitando oltre al task di DEV (development), anche quello di COM (communication), grazie al quale gli accorgimenti e reindirizzamenti progettuali, sono resi possibili fin dalle prime fasi del processo di sviluppo.

Per conseguire questi scopi, vengono impiegati modelli generativi basati su architetture Transformer, come LLM, disponibili anche in versioni nativamente multimodali (ad esempio Gemini integrato in Figma), a cui si affiancano modelli generativi visivi condizionati, come quelli utilizzati da Nike e IKEA per la visualizzazione rapida a partire da prompt testuali, modelli di diffusione impiegati in ambito automotive da Kia Global Design per il design dei cerchi, e GAN condizionali, come quelle sviluppate da Autodesk e sperimentate da Kia Motors per la generazione di modelli 3D destinati al design degli esterni delle auto.

Tra questi casi, IKEA si distingue per un approccio particolarmente innovativo attraverso soluzioni come *IKEA Kreativ* e *IKEA AI Assistant*, che integrano computer vision, realtà aumentata e AI generativa per coinvolgere direttamente il cliente nella progettazione e configurazione del proprio spazio. Tale coinvolgimento rafforza il senso di appartenenza dell'utente al progetto, orientandolo direttamente all'acquisto. Infatti, l'interazione con lo strumento, resa immediata dal prompting conversazionale e dalla visualizzazione istantanea, introduce semplificazioni che rendono la progettazione accessibile anche a soggetti non esperti e che consentono di elevare l'efficacia dell'affordance di acquisto.

Inoltre, i modelli generativi linguistici sono impiegati anche nelle attività di planning, problem structuring e concept evaluation, quest'ultima intesa sia come valutazione sia come validazione di mercato. Nelle fasi di planning e strutturazione del problema, essi supportano la raccolta e l'elaborazione di informazioni di contesto e trend di mercato, nonché l'analisi di trascrizioni di focus group, interviste e dati di feedback dei clienti, consentendo la formulazione di requisiti di prodotto. In alcuni casi, tali modelli permettono anche la generazione di personas virtuali che, come nel caso di Creative Dock, simulano gruppi di consumatori e favoriscono un'analisi più approfondita dei bisogni di vari segmenti.

Le personas consentono inoltre di abilitare la validazione del concept, simulando risposte e feedback dei clienti sulla base di preferenze e comportamenti appresi dai dati su cui il modello è allenato. Gli output prodotti da queste simulazioni vengono successivamente rielaborati dagli LLM per esplorare in modo più approfondito ulteriori bisogni dei gruppi, espliciti e latenti.

Un ulteriore livello di utilizzo riguarda la valutazione qualitativa dei concept generati, finalizzata a guidare le iterazioni di ottimizzazione. Gli LLM svolgono qui una funzione di strutturazione dei contenuti (STR) che abilita a seguire il task di controllo e valutazione (CNTR), attraverso cui fornisce riflessioni qualitative e spunti di miglioramento che suggeriscono possibili proposte di evoluzioni progettuali.

Dal punto di vista del ruolo operativo, quando l'AI generativa è impiegata con finalità esplorative e divergenti, essa si configura generalmente come AUG/SUP. Da un lato, potenzia la creatività del progettista, generando idee e alternative visive difficilmente producibili manualmente, sia per varietà sia per tempi di esecuzione, svolgendo quindi una funzione di augmentazione. Dall'altro lato, il processo rimane interamente guidato dal progettista, che formula i prompt, seleziona gli output e prosegue lo sviluppo e l'adattamento dei concept attraverso strumenti di modellazione tradizionali.

Il ruolo specifico svolto dall'AI generativa nella fase divergente della progettazione emerge da alcuni casi di studio in cui le modalità di interazione tra progettista e strumento sono rese esplicite, mettendo in evidenza come tale interazione non risulti sempre continua, ma si configuri piuttosto come un rapporto intermittente, che si sviluppa lungo un processo talvolta frammentato.

In una fase iniziale, lo strumento fornisce stimoli descrittivi e visivi che favoriscono l'esplorazione delle prime idee e contribuiscono a superare il suddetto blocco creativo iniziale. Successivamente, il progettista prosegue l'elaborazione in modo autonomo, reinterpreta e raffinando gli spunti ricevuti in funzione dell'identità del marchio, delle preferenze del proprio target e della propria esperienza sul campo.

In una fase successiva, il designer può tornare allo strumento definendo prompt più specifici e fornendo anche schizzi preliminari, che l'AI interpreta per generare concept complessivi coerenti con gli input ricevuti, supportando attività di visualizzazione, editing e modifica condizionata. Infine, lo sviluppo viene nuovamente affidato a strumenti di modellazione tradizionali (ad es. CAD), attraverso i quali il progettista definisce in modo puntuale forme e soluzioni finali.

Sebbene lo strumento, per le sue attuali caratteristiche di funzionamento, risulti idoneo a supportare solo alcune fasi specifiche del workflow completo, contribuendo a una frammentazione del processo complessivo, tale modalità d'impiego consente al tempo stesso di ridurre il rischio di allucinazioni cui l'AI generativa è tuttora soggetta. In questa configurazione di utilizzo, infatti, i modelli non generano output finali, ma producono esclusivamente stimoli creativi o traduzioni visive di istruzioni progettuali, che vengono successivamente reinterpretate e validate dal progettista nella fase di definizione finale, consentendo l'individuazione e l'eliminazione di eventuali allucinazioni commesse.

In alcuni casi, per superare i limiti di frammentazione derivanti dal tentativo di integrare questi strumenti nei flussi di lavoro esistenti, i software di AI sono stati specificamente progettati per il contesto in cui dovevano essere impiegati, analizzando le procedure operative dei designer al fine di sviluppare soluzioni quanto più possibile allineate alle pratiche progettuali e capaci di favorire un adattamento reciproco, come nel caso della collaborazione tra Autodesk e Kia Design.

Infine, nella fase convergente, in cui lo strumento è utilizzato per attività di valutazione o validazione, il ruolo operativo dell'AI generativa non è univoco ma è funzione del suo grado di specializzazione rispetto al task, che dipende dall'obiettivo, dai dati di training, e della criticità dell'applicazione per cui è previsto. Quando viene impiegato per fornire giudizi qualitativi sulle proposte progettuali, come nel caso di Loft, il suo ruolo rimane di supporto (SUP), per le stesse ragioni discusse nel quadrante F. La fase di valutazione richiede infatti il giudizio e l'esperienza del progettista, soprattutto in presenza di obiettivi qualitativi e soggettivi e di conseguenza, i giudizi e i suggerimenti dell'AI vengono considerati come spunti, ovvero come uno degli input che contribuiscono alla valutazione complessiva. Nel caso di Creative Dock, invece, lo strumento viene utilizzato in una fase di validazione, che si distingue dalla valutazione per un livello di criticità inferiore, essendo che a questo punto le decisioni progettuali principali sono già state assunte e si procede solo con le verifiche e aggiustamenti finali. In quest'ultimo caso lo strumento è specificamente addestrato su dati relativi alle preferenze dei consumatori e simula gruppi di utenti che hanno effettivamente espresso tali feedback, rendendo le risposte generate più affidabili rispetto a quelle di un modello generalista. Per questi motivi, il ruolo operativo dello strumento si configura come AUG/SUP, nonostante la natura convergente della fase. Il ruolo di AUG è attribuito in ragione del fatto che consente di ottenere feedback su larga scala e in tempi significativamente ridotti rispetto a interviste tradizionali sul campo, mentre resta SUP poiché la definizione delle modalità di interrogazione delle personas virtuali e la decisione su quali modifiche implementare sulla base dei feedback ricevuti, rimangono prerogative del progettista.

Quadrante H

Infine, a sinistra del quadrante I e in posizione sottoposta a G, si colloca il quadrante H. Come in G, predomina l'impiego di intelligenza artificiale generativa, ma questa volta si differenzia per il fatto che non assume un ruolo creativo, piuttosto prevalentemente organizzativo e analitico.

L'attenzione si concentra su attività di identificazione e strutturazione, talvolta orientate alla pianificazione operativa e strategica dello sviluppo prodotto e alla definizione del problema progettuale, talvolta rivolte all'esecuzione di micro-task di produttività. Questi ultimi possono applicarsi sia a fasi di sviluppo più trasversali, come planning e problem structuring, anche quando inserite in contesti di project management Agile (ad es. StackSpot AI nello sviluppo software), sia a esigenze specifiche dei team appartenenti a differenti funzioni verticali aziendali.

I task di produttività possono includere l'analisi e la sintesi di grandi quantità di dati aziendali e di mercato, finalizzate a individuare azioni strategiche e a definire priorità, rischi e dipendenze tra le attività. Possono inoltre consistere nello svolgimento di alcune attività operative pianificate, quali l'estrazione e la strutturazione di requisiti e user story in formati standard, la revisione del backlog di progetto e la traduzione del linguaggio tecnico in documentazione operativa accessibile e condivisibile tra team. Coerentemente con il posizionamento del quadrante, si tratta di compiti preliminari o contestuali alla progettazione e alla sua programmazione, necessari per procedere con l'avanzamento del processo ma in larga misura ripetitivi e operativi, e quindi tipicamente percepiti come attività a minor valore che sottraggono tempo ai progettisti rispetto ai compiti a maggiore impatto, che risultano collocati in prossimità degli altri tre estremi della matrice.

Il fatto che il livello di U-oD rimanga moderato, deriva dal fatto che, pur essendo ripetitive, queste attività richiedono spesso di considerare alcuni aspetti legati all'utente quando il prodotto è destinato all'uso diretto, soprattutto perché planning e problem structuring precedono la progettazione concettuale e ne vincolano le idee attraverso le informazioni elaborate.

Nel planning, i casi di studio richiamati in questo quadrante includono Notion AI ed Estée Lauder, che impiegano LLM (modelli GPT) come assistenti e, in alcuni casi, agenti personalizzati per porzioni automatizzabili dei task. In tale contesto, questi sistemi supportano la raccolta e l'organizzazione delle informazioni, l'individuazione dei bisogni, la definizione di direzioni strategiche e la pianificazione delle attività necessarie a rendere esecutivi i piani. Ciò include, ad esempio, ricerche a partire da prompt, analisi e sintesi documentale e redazione di output basati sulle informazioni processate. L'efficacia è massima quando i compiti sono sufficientemente standardizzabili e ripetitivi e quando il perimetro operativo e gli obiettivi risultano definiti con chiarezza.

Nel problem structuring, in Notion AI gli LLM consentono di interfacciarsi con lo strumento per redigere requisiti in forma standardizzata nel Product Requirement Document (PRD). Con StackSpot AI, un LLM integrato con ML addestrato su dati, pratiche procedurali e formati aziendali interni, supporta la definizione e strutturazione delle user stories, rendendole più chiare e uniformi tramite comandi rapidi preimpostati. Inoltre, integra criteri di accettazione già definiti per garantire requisiti di qualità, prestazioni, sicurezza e usabilità, automatizzando anche la loro verifica di conformità, mentre un agente AI supervisiona il backlog occupandosi di organizzazione e prioritizzazione dei task. In questo modo riduce il carico operativo dei project managers, che possono dedicarsi a compiti più strategici.

Nella fase di evaluation, Notion AI propone un impiego dell'LLM analogo a quello dei quadranti precedenti, utilizzandolo per analizzare trascrizioni di feedback dei clienti e suggerire valutazioni qualitative dei concept o dei prodotti realizzati. Infine, per le diverse funzioni aziendali, Notion ed Estée Lauder offrono la possibilità ai dipendenti di creare GPT personalizzati e agenti specifici attraverso eventi aziendali dedicati, con l'obiettivo di promuovere la produttività e l'efficienza operativa complessiva dell'organizzazione.

Quanto al ruolo operativo, nei casi di planning e problem structuring in cui l'LLM agisce da assistente conversazionale, si configura come AUG/SUP. Il ruolo di AUG si deve all'ampliamento della capacità di esplorazione di contingenze, criticità e direzioni strategiche e al potenziamento dell'attività di raccolta ed elaborazione rapida di grandi volumi di dati su mercato e consumatori. Tuttavia, mantiene una componente SUP perché la selezione di ciò che è effettivamente rilevante e le modalità di impiego delle informazioni rimangono sotto il controllo dell'operatore, anche in un contesto di criticità relativamente contenuta, in ragione della modalità operativa con cui lo strumento è stato progettato per interagire con l'utilizzatore. Nei task di produttività, invece, laddove il perimetro risulti circoscritto e il contesto operativo sia definito e noto, l'agente può svolgere in misura più o meno indipendente attività ripetitive e standardizzate per le quali è stato addestrato, assumendo ruoli che variano da AUG/AUT fino ad AUT, in funzione del grado di autonomia che riesce a implementare, consentendo così di riallocare le risorse umane verso compiti a maggiore criticità, tipici di contesti più destrutturati.

4.4. Conclusioni del capitolo

Il capitolo in esame ha consentito di garantire il passaggio dalla mappatura teorica a un livello di analisi empirico, usando casi studio aziendali per capire se e come l'AI sostiene effettivamente le fasi della progettazione, e in che misura questo varia in funzione dell'orientamento progettuale e dei vincoli di dominio, con un focus particolare sulla fase divergente e sulle applicazioni dell'AI generativa.

Per adempire a questo scopo, i casi studio aziendali sono stati trattati come istanze specifiche del processo progettuale, dove ciascuna istanza è stata individuata in termini di caratteristica modellata e di finalità di progettazione impressa, per uno specifico prodotto in un determinato dominio industriale.

Per garantire una esplorazione empirica coerente con gli obiettivi di ricerca, è stata introdotta la Matrice degli Orientamenti Progettuali (U-oD; S&E-oD) che ha permesso di evidenziare visivamente i pattern emersi, fornendo una base di confronto comune anche tra domini applicativi eterogenei, focalizzandosi sulle similitudini in termini della natura e del grado di sforzo cognitivo impiegato.

La distribuzione dei casi nella matrice mette in evidenza diversi spunti di riflessione, alcuni dei quali erano già emersi in uno stadio preliminare dell'analisi e avevano orientato la sua costruzione al fine di essere resi espliciti.

In prima istanza, si nota che non esiste una corrispondenza rigida tra tecniche di AI, livelli, fasi e sottofasi progettuali, ma piuttosto tendenze prevalenti. La matrice non restituisce quindi una mappa deterministica, bensì una maggiore o minore coerenza tra strumenti e orientamenti, in cui la collocazione dei casi tiene conto non solo del livello e della sottofase di progettazione, ma anche di fattori locali legati alle caratteristiche e alle finalità specifiche considerate, riferite a un prodotto inserito in un determinato dominio.

La collocazione risulta quindi sensibile alla caratteristica locale analizzata, piuttosto che al prodotto nel suo complesso, evidenziando la natura stratificata degli sforzi progettuali che possono coesistere all'interno dello stesso prodotto. In altri termini, l'associazione dello strumento non avviene rispetto a una classe di prodotti, ma rispetto allo sforzo cognitivo richiesto per modellare una specifica caratteristica. Ne consegue che la medesima famiglia di prodotti può collocarsi in punti diversi della matrice al variare delle molteplici determinanti di posizionamento, che coincidono con fase o sottofase, livello di progettazione, caratteristica e finalità progettuale, vincoli del dominio di riferimento. Questo rende possibile riconoscere aree tipiche di concentrazione per combinazioni ricorrenti di tali fattori, che corrispondono con le tendenze e i pattern emersi dalla mappatura.

Si osserva inoltre che la rigidità dei vincoli e le limitazioni proprie di determinati domini, così come le caratteristiche specifiche dell'impresa che vi opera, influenzano non solo il posizionamento nella matrice, ma anche il ruolo operativo e il grado di autonomia con cui gli strumenti vengono impiegati, rafforzando o attenuando le associazioni risalenti alla mappatura teorica.

Inoltre, il ricorso a orientamenti, anziché a categorie rigide, è coerente con il fatto che i prodotti combinano livelli U-oD e S&E-oD in proporzioni variabili, così come i sotto-fattori che li compongono. La matrice consente quindi di evidenziare come, al variare delle combinazioni tra dimensioni progettuali, gli strumenti teoricamente compatibili per modellare un singolo aspetto, possano risultare meno efficaci quando il prodotto integra simultaneamente caratteristiche collocate su orientamenti diversi, poiché le scelte su una dimensione generano effetti sull'altra. In tali condizioni, uno strumento idoneo a modellare una specifica caratteristica può diventare parzialmente incompatibile con le implicazioni prodotte su altre dimensioni del prodotto, rendendo necessaria l'integrazione attraverso software o architetture di coordinamento capaci di armonizzare gli output progettuali riferiti allo stesso sistema.

La matrice recepisce inoltre il carattere dinamico dell'evoluzione settoriale: caratteristiche che storicamente si sarebbero collocate su un determinato orientamento possono spostarsi nel tempo in funzione di cambiamenti tecnologici, ambientali o organizzativi. Non cristallizza quindi le associazioni, ma ne consente una riconsiderazione evolutiva. Allo stesso tempo, permette di individuare cluster di prodotti che, pur appartenendo a domini differenti, condividono caratteristiche e finalità progettuali simili, mettendo in evidenza competenze e capacità strumentali comuni e configurandosi anche come una mappa delle capacità funzionali degli strumenti nei diversi settori.

In termini di associazioni tra attività progettuale e strumenti, e del ruolo operativo e livello di autonomia con cui questi vengono coinvolti, emergono alcune evidenze di rilievo.

Per quanto riguarda le tecniche di ML, queste risultano prevalentemente impiegate per valutazioni predittive di KPI proxy, sia concettuali sia prestazionali, a supporto dello screening intermedio delle soluzioni generate. Tali applicazioni interessano diversi livelli della dimensione U-oD, ma si concentrano tipicamente su valori medio-alti di S&E-oD. Il ML è inoltre utilizzato per individuare correlazioni semantiche nei dati e favorire il riconoscimento di associazioni soluzione-problema utili alla definizione e validazione dei requisiti. In combinazione con modelli generativi, introduce capacità di apprendimento automatico che consentono di vincolare la generazione ai dati aziendali, trasferendo relazioni tecniche derivate da simulazioni ingegneristiche oppure elementi identitari e preferenze dei consumatori nel caso di contesti più creativi e di largo consumo.

Pur essendo per natura uno strumento di tipo aumentativo, poiché si fa carico di capacità di calcolo elevate e non riproducibili dall'uomo per complessità e tempi richiesti, quando è impiegato in fasi di valutazione, intrinsecamente critiche, il suo ruolo operativo tende a ricondursi al supporto (SUP). Tale dinamica vale anche per altri strumenti valutativi, dai software di simulazione ingegneristica alle verifiche rule-based su vincoli di producibilità e ambientali abilitate dai moduli simbolici, fino ai modelli generativi utilizzati per fornire giudizi qualitativi preliminari. Solo quando lo strumento è stato progettato e addestrato in modo altamente specifico per un compito circoscritto, come nel caso della validazione di mercato tramite personas virtuali, il ruolo può avvicinarsi ad AUG/SUP grazie all'aumento di affidabilità acquisita.

Il generative design mostra invece un comportamento differenziato in funzione della natura del prodotto considerato. Nei prodotti ingegneristici complessi viene prevalentemente utilizzato come stimolo vincolato nelle fasi preliminari di ideazione; nei prodotti a ingegneria moderata si estende alla fase di ottimizzazione, dove risponde efficacemente a trade-off tecnici non eccessivamente complessi e rende possibile usufruire della complementarità con le tecniche di produzione additive; nei prodotti contemporaneamente tecnici e user-oriented, può contribuire alla modellazione degli aspetti ingegneristici, ma richiede successivi interventi di adattamento per rispondere a esigenze di usabilità e coerenza con l'identità del brand. Di conseguenza, il ruolo operativo varia, tende a essere AUG/SUP nei casi più critici o ibridi, e AUG quando l'idoneità tecnica è più elevata.

La terza evidenza centrale concerne l'AI generativa e l'ampiezza delle sue potenzialità applicative. Questo elemento risulta particolarmente significativo rispetto agli obiettivi dell'indagine, poiché ne conferma l'importanza rispetto alle altre tecniche esplorate all'interno del perimetro di analisi considerato.

Il suo impiego più frequente risiede nell'esplorazione divergente del design concettuale, soprattutto in prodotti caratterizzati da basso S&Eo-D e alto Uo-D, dove favorisce il superamento del blocco creativo, il brainstorming conversazionale e la visualizzazione immediata di alternative. Gli LLM risultano più impiegati per l'ideazione funzionale, mentre modelli multimodali, GAN e diffusion models supportano l'ispirazione visiva. Grazie a questi strumenti risulta abilitata, oltre all'idea generation, anche la sottofase di concept generation e refinement. Quest'ultima, in particolare, beneficia della possibilità di intervenire sui concept generati tramite prompt, modificandone in modo iterativo e conversazionale feature e geometrie. Le variazioni vengono così rese immediatamente visibili, non solo su immagini ma, potenzialmente, anche su modelli 3D.

Tuttavia, l'idoneità della GenAI, spesso circoscritta a momenti specifici delle sottofasi di idea generation e concept generation e refinement, tende a rendere il processo più frammentato, poiché richiede il ricorso a strumenti differenti per completare il ciclo di generazione della soluzione. Ne deriva un'interazione intermittente, in cui il modello generativo fornisce uno stimolo iniziale, segue una fase di elaborazione centrale a cura del progettista, quindi un ritorno allo strumento per rendere visualizzabile il concept tramite prompt più dettagliati, fino alla modellazione e definizione in CAD o in strumenti separati. Questo assetto introduce inefficienze, ma al contempo restituisce un controllo maggiore del rischio, riducendo l'impatto di possibili allucinazioni cui questi strumenti sono soggetti, grazie al fatto che gli output vengono trattati come stimoli da validare e non come risultati finali. La frammentazione tende invece a ridursi, e l'efficacia ad aumentare, quando i workflow dei designer vengono appositamente osservati per essere tradotti in soluzioni software che integrano le componenti generative in modo coerente con le pratiche operative esistenti.

La capacità divergente, utile soprattutto nell'idea generation, evidenzia anche un altro limite ricorrente. In alcuni casi, infatti, le alternative prodotte risultano tra loro molto simili e lo screening viene svolto prevalentemente in modo manuale. Ne deriva un potenziale sovraccarico per i progettisti, chiamati a gestire volumi elevati di output e a discriminare differenze talvolta marginali.

Un punto a favore di questi strumenti riguarda invece il fatto che permettono di supportare la conversazione e la costruzione di una comprensione condivisa tra attori con competenze eterogenee, inclusa l'interazione tra progettisti e clienti. Ne consegue un più rapido allineamento preliminare su requisiti e alternative ammissibili, con riduzione di incomprensioni, sprechi e rilavorazioni.

Questa capacità divergente risulta particolarmente efficace in contesti molto creativi e poco vincolati, nei quali la novità è accettata e valorizzata. Al contrario, tende a essere impiegata con maggiore cautela in imprese consolidate e orientate alla continuità di portafoglio, dove un'eccessiva divergenza può entrare in tensione con i requisiti di familiarità richiesti dal mercato e con logiche di riconoscibilità e fidelizzazione, come avviene tipicamente nel largo consumo alimentare.

In contesti maggiormente ingegneristici, caratterizzati da un livello di S&E-oD più elevato, alcuni di questi strumenti, se adeguatamente addestrati su simulazioni specifiche e integrati con feature fisiche o parametri ingegneristici espliciti, possono essere impiegati anche per la generazione di idee tecniche nella fase divergente preliminare. Tuttavia, in tali condizioni risultano complessivamente meno idonei allo scopo rispetto ai casi dei quadranti sopra menzionati.

Nel caso di task divergenti applicati a prodotti caratterizzati da elevato grado di S&E-oD, tipicamente con valori di Uo-D moderatamente bassi, i modelli generativi transformer-based intervengono apprendendo la grammatica delle relazioni di dominio tra oggetti elementari di sistemi tecnici, trattati come unità tokenizzabili, come elementi di codice, componenti elettronici di una scheda madre o amminoacidi in sequenze proteiche, generando combinazioni inedite funzionali a nuovi scopi. Analogamente anche i VAE si sono dimostrati adeguati a questo scopo, ma con un procedimento di apprendimento diverso e tramite interpolazioni dello spazio latente. Nei contesti di progettazione ingegneristica complessa, che richiedono software ad hoc, gli LLM assumono inoltre un ruolo di intermediazione e consulenza tecnica, semplificando l'uso e il processo di interazione con i software, la traduzione di requisiti tecnici in soluzioni implementabili e il recupero della conoscenza specifica.

Un ulteriore ambito di applicazione degli LLM riguarda il planning e il problem definition & structuring, dove essi abilitano la raccolta e l'elaborazione di dati provenienti da fonti frammentate, la sintesi informativa e la generazione di idee strategiche, nonché la traduzione di tali indicazioni in piani operativi e task concreti. In questo ambito, il contributo principale riguarda l'identificazione di opportunità e rischi e l'incremento di produttività nelle attività operative. Quando tali attività sono particolarmente circoscritte, standardizzate e ripetitive, esse vengono talvolta automatizzate tramite agenti, soprattutto in aziende con marcato orientamento user-oriented.

Negli ambiti descritti relativi alla GenAI, la tendenza prevalente è quella di interpretare il ruolo operativo come AUG/SUP. Sebbene possa potenziare la creatività, ampliare gli spunti di riflessione critica e integrare informazioni estratte da molteplici fonti e dati frammentati, la natura interattiva dell'uso e le criticità ancora presenti (ad es. allucinazioni) richiedono guida, interpretazione e selezione da parte del soggetto umano, che resta responsabile degli output da integrare nel risultato finale.

Gli strumenti generativi sono inoltre impiegati per lo screening delle alternative. In alcuni casi forniscono valutazioni qualitative di idee concettuali, in altri supportano anche lo screening di soluzioni tecniche, analizzando report e documentazione di progetto e producendo sintesi basate su evidenze tratte da fonti ufficiali. In ulteriori applicazioni, simulano il comportamento di sistemi evidenziando potenziali malfunzionamenti e supportando la riprogettazione. Anche in questi casi, la criticità della fase limita tipicamente il ruolo a SUP, i giudizi prodotti vengono infatti revisionati e confrontati con analisi indipendenti.

Un'ulteriore considerazione riguarda la variabilità tra un impiego più libero e uno più vincolato della GenAI, in funzione dell'idoneità del task divergente affrontato, che incide direttamente sul ruolo operativo e sul livello di autonomia attribuibile allo strumento.

Nella progettazione concettuale di prodotti con alto U-oD e basso S&E-oD, l'utilizzo può essere relativamente più aperto e si ammette un impiego operativo dello strumento in chiave AUG/SUP, pur entro i vincoli derivanti da: identità del marchio, linee strategiche aziendali e preferenze dei consumatori, tradotti in dati e requisiti di riferimento con cui guidare la generazione di soluzioni.

In contesti più vincolati, come quelli ingegneristici e con restrizioni regolatorie forti, al contrario, la necessità critica di presidiare la conformità e la correttezza degli output, che incide non solo sulle conseguenze economiche dell'impresa ma anche sulla sicurezza e sulle ritorsioni legali delle decisioni prese, riduce l'autonomia dello strumento, che tende a essere impiegato prevalentemente con un ruolo più prudente di supporto (SUP).

Nel complesso, il capitolo conferma l'ipotesi iniziale secondo cui la compatibilità effettiva tra AI e progettazione è meglio descritta come un insieme di tendenze condizionate da orientamenti progettuali e vincoli contestuali, più che come una corrispondenza univoca tra sottofasi e strumenti. Il carattere multi-dominio della matrice rende infatti il posizionamento dei casi e l'assegnazione dei ruoli operativi sensibili a molteplici determinanti e alle loro combinazioni, facendo emergere pattern di alto livello che mettono in relazione i medesimi strumenti con prodotti accomunati da caratteristiche, finalità progettuali e vincoli di contesto simili, pur appartenendo a domini differenti.

In questo senso, la matrice si conferma utile per predisporre un confronto critico con il framework teorico del capitolo precedente, che cercava di proporre una mappatura trasversale, focalizzata sulle associazioni tra strumenti e sottofasi, trascurando le precisazioni legate al dominio, ai livelli progettuali, e alla natura dello sforzo progettuale impiegato. A tale scopo gli esiti empirici verranno ripresi nelle conclusioni della tesi per discutere in che misura essi confermino, raffininno o si discostino dalle associazioni teoriche del secondo capitolo, chiudendo il ciclo di esplorazione tramite una validazione giustificata da evidenze aziendali concrete e risultati misurabili.

5. Conclusioni

Con l'obiettivo di rispondere alle domande di ricerca inizialmente formulate, la tesi è articolata in tre sezioni. La prima domanda di ricerca si proponeva di indagare i paradigmi e le tecniche di AI, al fine di individuare quelli rilevanti per analizzare le applicazioni nei processi di progettazione e di chiarire uno schema di classificazione che consentisse di ricomporre la frammentazione della letteratura in una tassonomia comprensibile e utilizzabile, capace di far emergere gli aspetti delle tecniche utili a evidenziare potenzialità e limiti applicativi.

Per rispondere a tale domanda è stato adottato un approccio deduttivo, che è partito dall'individuazione di un piano di classificazione guida finalizzato a costruire lo scheletro della tassonomia. A questo livello è stata scelta una categorizzazione per tecniche organizzate per paradigmi di AI, utile a distinguere gli approcci sulla base dei principi di funzionamento, con l'obiettivo di delineare la varietà dei task svolgibili. In questa ottica la tassonomia ha permesso di raggruppare le tecniche in cinque paradigmi: AI simbolica, AI evolutiva e bio-ispirata, machine learning tradizionale, deep learning e AI ibrida.

A seguire, internamente ai paradigmi, sono stati introdotti altri piani di classificazione, che hanno rappresentato diramazioni complementari rispetto al piano principale, utili a esplorare ulteriori prospettive e ad articolare maggiormente lo schema tassonomico, senza comprometterne la coerenza con il piano precedente. In particolare, per il machine learning è stata aggiunta una classificazione legata al tipo di apprendimento, che ha consentito di riorganizzare diversamente alcuni metodi già collocati nella classificazione per tecniche e altri rimasti inesplorati in ragione del diverso obiettivo di rappresentazione. Analogamente, per il deep learning è stato introdotto una categorizzazione basata sulla formulazione probabilistica del modello, distinguendo tra modelli discriminativi e generativi. Questa distinzione ha inoltre consentito di chiarire la separazione concettuale tra architettura e modello, facendo emergere le combinazioni più tipiche e ricorrenti tra i due.

A partire dalla costruzione della struttura tassonomica di riferimento, è stata portata avanti una ricerca mirata sulle varie tecniche citate, per ciascun piano di classificazione adottato. Nell'AI simbolica sono rientrati sistemi rule-based, ontologie e knowledge graph, orientati alla rappresentazione esplicita della conoscenza e al ragionamento basato su regole, funzionale alla verifica interpretabile di vincoli. Il machine learning, articolato in base alla modalità di apprendimento, ha incluso tecniche supervisionate di classificazione e regressione (es. Random Forest, SVM, boosting, KNN), metodi esplorativi per l'identificazione di pattern quali clustering (k-means, gerarchico) e riduzione dimensionale (PCA), oltre a tecniche di apprendimento per rinforzo. Il deep learning è stato ulteriormente organizzato distinguendo tra modelli discriminativi e generativi, includendo architetture neurali quali reti convoluzionali e ricorrenti, oltre a modelli generativi (autoencoder, GAN e varianti); è stato inoltre dedicato un approfondimento specifico ai Transformer, architettura alla base delle evoluzioni più avanzate dell'AI generativa. Infine, sono stati considerati approcci ibridi, in particolare neuro-simbolici, con l'obiettivo di combinare l'apprendimento statistico con una strutturazione esplicita e interpretabile della conoscenza. Inoltre, in coerenza con le tendenze attuali e le possibili traiettorie evolutive, è stato incluso un cenno agli agenti e alle architetture multi-agente.

L'analisi di struttura e funzionamento dei diversi paradigmi ha permesso di cogliere l'allineamento delle tecniche con task idonei, ma non è risultata sufficiente a valutarne la compatibilità di implementazione in ambito aziendale. Per questo, l'indagine si è estesa a un secondo livello di analisi, introducendo dimensioni caratterizzanti orientate a una lettura più applicativa. Tali dimensioni risultano utili a far emergere potenziali vincoli di implementazione e a superare la sola valutazione di coerenza sul piano funzionale. In particolare, sono state considerate tipologia di input processabili, dominio di applicabilità, interpretabilità, scalabilità, risorse computazionali e tempi di training, trattate in forma comparativa per rendere le tecniche confrontabili lungo una prospettiva multidimensionale.

A questo punto, l'analisi si è spostata sulla seconda sezione, finalizzata a rispondere alla seconda e alla terza domanda di ricerca. La seconda domanda richiedeva una rilettura delle fasi e sottofasi del processo di progettazione nel NPD che fosse, da un lato, compatibile con l'associazione agli strumenti di AI e, dall'altro, sufficientemente generalizzabile da risultare trasferibile tra livelli e domini progettuali differenti. La terza domanda riguardava

invece la definizione di categorie di collegamento più idonee a formalizzare tali associazioni e a identificare, sul piano teorico, le relazioni maggiormente coerenti tra sottofasi della progettazione e strumenti di AI.

Per rispondere alla seconda domanda di ricerca, è stato adottato un modello unificato del processo di progettazione noto in letteratura come Stage-Based Design Process, che scompone il design in fasi divergenti e convergenti e nelle relative sottofasi. In particolare, le fasi divergenti riportano problem definition and structuring, idea generation, idea/component combination e concept generation, cui seguono refinement e optimization, quest'ultima con natura in parte divergente e in parte convergente, per poi chiudere il processo con la fase convergente di evaluation & selection.

Sebbene questa struttura sia tipicamente adottata per la razionalizzazione del livello di design concettuale, è risultata la più generalizzabile per descrivere step e sottofasi della progettazione nelle sue diverse esplicazioni, dimostrandosi trasversale e trasferibile sia tra domini diversi, sia tra differenti livelli progettuali.

A seguire, sono state definite categorie di collegamento per rendere confrontabili e quindi associabili le due prospettive, quella dello strumento e quella delle sottofasi. Per gli strumenti sono stati considerati livello di autonomia e ruolo operativo, distinguendo tre modalità di intervento (SUP, AUG, AUT); per le fasi, supervisione umana richiesta e criticità, entrambe valutate su tre livelli (alta, media, bassa). Una terza categoria, comune a fasi e strumenti, è stata la tipologia di task secondo il Context of Action (ID, STR, DEV, CNTR, COM), interpretato come la natura dell'attività richiesta dalla sottofase e come classe di task implementabile dallo strumento. L'assegnazione di tali categorie ha consentito di costruire un framework teorico unificato di associazione sottofase-strumento basato sulla compatibilità dei profili, fornendo la base per rispondere in modo strutturato alla terza domanda di ricerca.

Nel paradigma di AI simbolica, l'associazione prevalente riguarda la strutturazione delle informazioni esplicitate (STR) e la verifica dei vincoli formalizzati (CNTR). Knowledge graph, sistemi a regole e ontologie consentono di formalizzare competenze, relazioni semantiche tra attori, competenze richieste, problemi e soluzioni emerse in progetti precedenti, nonché requisiti e vincoli sia del dominio complessivo sia del progetto corrente. Tali tecniche trovano applicazione soprattutto nelle fasi di planning e problem structuring, dove le informazioni vengono strutturate e rese interrogabili, così da poter guidare le fasi successive di idea generation e combination. Inoltre, abilitano attività di constraint checking e validazione nella fase di concept evaluation & selection, risultando particolarmente affidabili nei casi in cui le relazioni siano di natura tecnica e formalizzabile. All'interno di questo perimetro rientrano anche tecniche di pianificazione simbolica e PoP che, nel problem structuring trattano le relazioni tra funzioni di prodotto come se fossero azioni da sequenzializzare per realizzare l'obiettivo ultimo, ossia lo scope del sistema. A questi si affiancano anche formalizzazioni di framework divergenti, come TRIZ, di cui vengono resi automatizzabili alcuni passaggi, al fine di associare il problema in questione al principio solutivo più coerente tra quelli derivati dall'analisi dei brevetti posizionati nella matrice delle contraddizioni (STR), supportando così l'individuazione di alternative tecniche compatibili.

Quando la progettazione è caratterizzata dalla ricerca di compromessi tra obiettivi multipli e da un'elevata presenza di vincoli, in particolare di natura fisica, ingegneristica e produttiva, si ricorre tipicamente a tecniche di AI evolutiva e bio-ispirata, integrate in approcci più ampi di generative design, dove operano attraverso cicli iterativi che alternano attività di generazione (DEV) e valutazione (CNTR).

Algoritmi genetici, sia in forma semplice sia multi-obiettivo (GA, NSGA-II), insieme a tecniche di ottimizzazione topologica, abilitano processi iterativi di generazione-valutazione che consentono l'esplorazione di spazi solutivi fortemente vincolati. Tali tecniche possono fornire stimoli utili anche alla fase di idea generation e, nella fase di concept optimization, supportano la determinazione dei valori parametrici che migliorano i trade-off di soluzioni già parzialmente definite. L'efficacia di questi approcci è tuttavia subordinata al grado di strutturazione della funzione di fitness, che dipende dalla natura delle variabili e dei parametri modellati e condiziona direttamente l'affidabilità delle valutazioni prodotte.

A seguire, il machine learning tradizionale si configura come un paradigma le cui tecniche risultano in grado di coprire una gamma più ampia di task rispetto a quelle comprese nei paradigmi precedenti. Tuttavia, esso continua a essere riconosciuto come un insieme di strumenti specialistici, che richiedono una definizione esplicita del task, delle variabili e dei dataset di riferimento. Ne deriva una maggiore dipendenza dalla specifica

formulazione del problema e dal dominio di addestramento e, conseguentemente, una minore trasferibilità applicativa rispetto ai deep generative models che, pur essendo anch'essi fortemente condizionati dai dati su cui sono stati pre-addestrati, presentano un grado relativamente più elevato di riutilizzabilità trasversale tra task differenti, in virtù della loro architettura e del pretraining su larga scala.

Quando le tecniche di ML sono impiegate in forma non supervisionata, come clustering e riduzione dimensionale, sono impiegabili per supportare segmentazioni di clienti, tecnologie e competitor, per la sintesi di dataset complessi e per l'individuazione di correlazioni e associazioni latenti tra caratteristiche dei dati (ID, STR). Nelle forme supervisionate, invece, attraverso task di classificazione e regressione, abilitano attività di previsione e prioritizzazione di alternative, bisogni, requisiti e feature, includendo la stima del rischio e della probabilità di successo di opzioni strategiche o soluzioni di prodotto, oltre al forecasting della domanda e delle vendite. Nelle fasi più analitiche e di controllo, il ML è spesso impiegato come modello surrogato di simulazioni e test onerosi per lo screening e scoring intermedio delle soluzioni generate all'interno dei cicli di ottimizzazione, prima della valutazione finale (CNTR). In molti casi diventano rilevanti anche tecniche XAI (es. SHAP/PDP) e strategie di feature engineering physics-informed per aumentare plausibilità e interpretabilità delle previsioni, pur senza eliminare del tutto il carattere black-box dei modelli.

Nel complesso, tali impieghi si concentrano nelle fasi di planning, problem structuring e nelle valutazioni preliminari, in cui classificazione ed elaborazione dei dati sono finalizzate a far emergere trend, pattern, correlazioni, stime di regressione e forecasting, fornendo un supporto strutturato al processo decisionale. Un ulteriore ambito è la validazione di mercato, dove l'apprendimento di relazioni tra caratteristiche di prodotto e risposta dei consumatori consente di stimare la probabilità di successo di un'alternativa e di verificare l'adeguatezza delle feature implementate rispetto alle preferenze attese. Infine, la visualizzazione delle elaborazioni derivate da grandi moli di dati raccolti potenzia la discussione critica tra esperti (COM) in merito ai provvedimenti da intraprendere. Al contempo, contribuisce alla strutturazione semantica di informazioni utili sia al problem structuring sia alla idea generation.

Per quanto riguarda il deep learning invece, la distinzione tra compiti predittivi e generativi chiarisce l'associazione con sottofasi diverse. Sul versante predittivo, architetture predisposte per modellare sequenze temporali come LSTM, GRU, Temporal CNN, Transformer temporali, si associano al planning per forecasting di dati relativi a domanda, vendite, trend tecnologici e competitivi (CNTR), mentre BERT abilita task di NLP come sentiment analysis ed estrazione di concetti da testi (ID), come quelli associati a bisogni, attributi di prodotto, vincoli regolatori e stakeholders, supportando planning, problem structuring e idea generation; modelli come DTM consentono inoltre di tracciare l'evoluzione temporale delle feature estratte, abilitando riflessioni su trend dinamici (STR, CNTR). Le rappresentazioni vettoriali e l'analisi avanzata delle similarità, mediante architetture Bi-LSTM o CNN applicate ai concetti estratti con tecniche NLP basate su BERT, supportano l'individuazione di relazioni tra bisogni, requisiti e parametri di design, nonché la stima del grado di indipendenza tra funzioni di prodotto. Ciò consente di derivare indicazioni sulla modularità o integrazione del sistema (STR) e di orientare, nelle fasi divergenti, gli spuntiolutivi. In questo senso, le tecniche predittive di deep learning svolgono funzioni in parte analoghe a quelle del machine learning tradizionale, ma consentono anche di operare su input destrutturati e di apprendere relazioni di maggiore complessità. Inoltre, grazie alla capacità di modellare dipendenze di lungo raggio, risultano adatte all'elaborazione di sequenze anche molto estese.

Sul versante generativo, LLM e modelli multimodali abilitano brainstorming conversazionale, organizzazione e strutturazione delle informazioni (framework strategici come Porter e SWOT, decomposizioni funzionali, profili di personas e mappe concettuali delle idee emerse) nel planning, problem structuring e idea generation (DEV, STR). Nel caso di applicazioni ingegneristiche in cui i sistemi formati da componenti elementari sono trattabili come sequenze di token, il modello apprende la grammatica del dominio che lega gli elementi del sistema, e produce delle combinazioni alternative inedite che risultano valide rispetto alle relazioni apprese (DEV, CNTR, STR).

Inoltre, grazie a capacità di reasoning, lo strumento supporta valutazioni critiche prevalentemente qualitative, anche adottando prospettive multiple, ad esempio assumendo punti di vista contrapposti come quello del progettista e del cliente, oppure di progettisti con competenze differenti, dimostrandosi utile a supportare anche la comunicazione (COM) e la collaborazione tra stakeholders. In alcuni contesti, oltre ai giudizi qualitativi, l'analisi

delle alternative può essere resa più strutturata tramite schemi di valutazione multicriterio (CNTR), producendo valutazioni di tipo semi-quantitativo.

Questo contributo si colloca soprattutto nelle valutazioni preliminari del design concettuale, dove la comparazione tra alternative è meno dipendente da criteri pienamente formalizzati. Nei contesti più tecnici e verticali, invece, la valutazione richiede tipicamente analisi numeriche e simulazioni fisiche dedicate, motivo per cui, quando lo strumento generativo viene utilizzato per attività divergenti di questo tipo, l'affidabilità dimostrata tende a ridursi, con una conseguente limitazione dell'autonomia attribuibile e del ruolo operativo assegnato.

Parallelamente, GAN, diffusion models, VAE e modelli multimodali supportano la generazione e trasformazione di immagini, schizzi e geometrie, ampliando le capacità creative e contribuendo a superare il blocco iniziale nelle fasi di idea generation e combination (DEV, COM). Nelle fasi di concept generation e refinement, inoltre, rendono immediatamente visibili le modifiche apportate alle caratteristiche di prodotto e gli effetti dell'editing sulle forme (DEV). Pur avendo impostato l'analisi in modo trasversale ai diversi livelli progettuali, l'high-level system design mostra una corrispondenza più netta con l'impiego di modelli generativi basati su grafi nella fase divergente. In tale ambito, approcci come graph VAE, modelli autoregressivi e grammar-based risultano più adeguati rispetto alle altre tecniche generative considerate per la definizione di architetture di sistema e per l'esplorazione di combinazioni tra componenti (DEV, CNTR, STR).

L'AI agentiva, nelle declinazioni LLM-based agents, architetture multi-agente e deep multi-agent reinforcement learning, è teoricamente associabile a un ampio insieme di fasi e sottofasi della progettazione, pur rappresentando allo stato attuale una quota ancora limitata delle applicazioni rilevate. Tale trasversalità è riconducibile a più livelli di impiego.

Un primo livello riguarda agenti orientati a compiti standard di produttività, quindi replicabili lungo diverse fasi e trasferibili tra domini progettuali diversi (DEV), ma soprattutto associati agli stadi di planning e problem structuring. Un secondo livello concerne agenti appositamente addestrati per interiorizzare regole e dinamiche di domini specifici, in grado di svolgere attività a maggiore valore aggiunto e di operare su task verticali di una determinata area disciplinare (DEV), coprendo porzioni estese del relativo ciclo di progettazione. In tali configurazioni, essi possono costituire componenti di architetture multi-agente, nelle quali un meccanismo di orchestrazione coordina e controlla gli output (ID, STR, COM, CNTR), gestendo i flussi input-output, l'integrazione dei feedback umani, l'invocazione di strumenti esterni (ad es. software di simulazioni) e l'interpretazione dei risultati per indirizzare le iterazioni successive, ricomponendo le soluzioni generate in un sistema complessivo coerente e funzionante. L'attribuzione di maggiore autonomia resta condizionata dal grado di specializzazione dell'architettura e dei singoli agenti e dal livello di rischio tollerabile dall'azienda.

Infine, le tecniche ibride si dimostrano particolarmente efficaci quando l'obiettivo diventa quello di bilanciare punti di forza e di debolezza dei diversi approcci. In questa categoria rientrano componenti neuro-fuzzy (ad es. ANFIS) per gestire l'incertezza nelle attività di valutazione e predizione (CNTR) e metodi di relational learning su grafi per inferire relazioni mancanti e latenti, ad esempio tra problema e soluzione, a supporto dell'idea generation (STR). Si collocano inoltre pipeline ibride che automatizzano framework quali TRIZ e FBS, combinando LLM per la comprensione linguistica (DEV, STR, COM), metodi simbolici basati su regole esplicite per rendere interpretabili i passaggi che conducono all'identificazione della soluzione (STR) e tecniche di ML per integrare l'apprendimento da progetti pregressi. Nel generative design, configurazioni ibride possono integrare algoritmi genetici e reinforcement learning per la ricerca e il settaggio iterativo, ML/DL per apprendere relazioni di dominio dalle simulazioni passate e modelli generativi visivi (GAN, diffusion, VAE) per la visualizzazione della soluzione coerente ai vincoli appresi, a supporto di idea generation, combination e concept optimization (DEV, CNTR).

Quanto al ruolo operativo lungo le sottofasi, analogamente a quanto osservato per le associazioni tra strumenti e attività, emergono alcune tendenze prevalenti.

Nel planning predomina AUG, soprattutto in compiti di raccolta, integrazione e analisi di grandi volumi di dati, sia strutturati sia destrutturati, nonché nell'identificazione di pattern e nel forecasting. In tali attività, infatti, lo strumento automatizza catene di calcolo e procedure analitiche estese che il soggetto umano difficilmente potrebbe replicare con la stessa tempestività. Si osserva invece un passaggio verso AUG/SUP nelle attività creative e

strategiche (ad es. brainstorming conversazionale e scenario analysis), dove la direzione dell'esplorazione rimane principalmente in capo al progettista.

All'aumentare della criticità decisionale, ad esempio nella valutazione e selezione strategica, il ruolo tende a collocarsi su SUP, poiché l'output dello strumento viene assunto come supporto informativo e non come guida primaria della decisione. AUT, infine, resta circoscritto a task di produttività di routine (trascrizioni, summarization, retrieval), spesso abilitati da agenti.

Nel problem structuring, trattandosi di una fase ad alta criticità insieme all'evaluation, prevale SUP. La definizione dei requisiti, l'individuazione delle correlazioni chiave e la costruzione di criteri e pesi di valutazione, orientano sia l'esplorazione divergente sia le scelte convergenti e, di conseguenza, determinano in modo significativo l'impostazione e le conseguenze sulle attività successive.

La criticità deriva sia dall'irreversibilità di alcune decisioni, sia dall'effetto di propagazione delle scelte inappropriate e delle imprecisioni commesse sulle altre attività del processo. Infatti, errori introdotti nelle fasi preliminari di definizione non solo generano rilavorazioni costose, ma vincolano lo sviluppo successivo sulla base di assunzioni errate. Ne consegue che anche la valutazione finale può risultare distorta, in quanto applica criteri costruiti su ipotesi scorrette. In parallelo al problem definition & structuring, anche la fase di evaluation è intrinsecamente critica, poiché una valutazione inadeguata può condurre a una selezione finale con effetti sul mercato difficilmente recuperabili oppure orientare in modo improprio i cicli di miglioramento, concentrando risorse su interventi marginali e trascurando le leve effettivamente determinanti.

Tuttavia, in alcuni casi particolari, nonostante l'elevata criticità, anche all'interno del problem structuring si osserva l'utilizzo degli strumenti in modalità AUG/SUP. Accade per esempio quando le relazioni vengono formalizzate, poi rese verificabili e recuperabili tramite modelli simbolici che registrano informazioni su larga scala, oppure quando modelli generativi propongono un numero significativo di alternative di configurazioni architetture, aggiuntive rispetto a quelle pensate senza il ricorso allo strumento. Sebbene la criticità rimanga elevata, è evidente il potenziamento che lo strumento è in grado di apportare.

Come nel planning, anche nel problem structuring l'autonomia (AUT) resta per lo più confinata a compiti circoscritti e ripetitivi, come la verifica sintattica di requisiti standard. In prospettiva, come già anticipato, alcuni modelli indicano un'estensione di questa modalità operativa verso architetture multi-agente capaci di ristrutturare il problema in base ai feedback umani ricevuti, orchestrare gli output delle fasi generative di cui si occupano agenti specializzati, e integrare tool esterni per internalizzare, con buona affidabilità, anche le capacità di valutazione lungo l'intero ciclo progettuale.

Nell'idea generation invece, domina AUG/SUP. Gli strumenti forniscono stimoli divergenti e possibili direzioni creative, mentre il controllo su selezione, interpretazione e combinazione degli output rimane al progettista. AUG risulta invece più coerente quando la generazione è parametrica e algoritmicamente codificabile, ovvero quando il software è in grado di produrre soluzioni già vincolate da requisiti integrati e con basse probabilità di errore, grazie a una logica di funzionamento pienamente coerente con la natura del problema da modellare. Una logica analoga si estende alla fase di idea combination, dove, oltre alla codificabilità tipica della sottofase, il livello di criticità moderato e la natura esplorativa e reversibile del ciclo rendono compatibile AUG anche per attività valutative preliminari, come screening e scoring tramite KPI proxy.

Nella concept generation prevale AUG/SUP, in virtù della rapidità di visualizzazione e della facilità di modifica di feature e forme, anche se la necessità di un raffinamento iterativo continuo guidato dal progettista aumenta il peso relativo di SUP.

Nel concept optimization torna dominante AUG, grazie alla codificabilità e iteratività automatizzabile della sottofase. I cicli alternati di generazione e valutazione riducono progressivamente l'errore prodotto dalle scelte imprecise o sbagliate, e tendono a smorzarlo all'interno della sottofase stessa, diminuendo il rischio che si ripercuota sulle attività successive.

Nel caso specifico del detailed design, i modelli surrogati assumono più spesso un ruolo di SUP a supporto dello screening preliminare, senza estendersi all'AUG/SUP, tipico invece di scenari meno complessi e rigorosi. In contesti ad elevata complessità, infatti, la valutazione non è affidabile se basata esclusivamente su indicatori di

alto livello. Nonostante ciò, i modelli surrogati mantengono utilità nella scrematura iniziale delle alternative, poiché consentono di predire performance espresse in variabili quantitative con costi e tempi inferiori rispetto a simulazioni numeriche e multi-fisiche lunghe e onerose. Queste ultime restano tuttavia imprescindibili per la validazione finale, che viene così concentrata su un insieme più ristretto di soluzioni.

Infine, nell'evaluation, proprio in ragione della criticità elevata, il ruolo operativo si colloca prevalentemente su SUP. Gli output predittivi sono trattati come uno dei molteplici input che confluiscono in valutazioni più ampie, integrate con risultati derivanti da analisi sperimentali e indipendenti, al fine di aumentare l'affidabilità complessiva delle decisioni prese. Fanno eccezione alcuni casi di AUG, ad esempio verifiche codificabili di tipo rule-based per l'elevato grado di interpretabilità che abilitano, formalizzate preventivamente durante il problem structuring. Inoltre, strumenti di simulazione e analisi ingegneristica (FEM, CFD, MBD), pur richiedendo impostazione e interpretazione da parte del progettista, consentono calcoli complessi e la previsione di effetti con un livello di accuratezza tale da renderli spesso il principale mezzo di valutazione in presenza di fenomeni fisici e ingegneristici altamente critici, configurandosi come AUG/SUP.

Infine, la terza e ultima sezione ha adottato una prospettiva empirica per rispondere alla quarta domanda di ricerca, analizzando evidenze multi-dominio relative alle applicazioni attuali dell'AI nei processi di progettazione e valutando in che misura tali evidenze confermino, specifichino o ridimensionino le associazioni teoriche precedentemente formulate, alla luce dei vincoli operativi e del carico cognitivo richiesto ai progettisti nei diversi contesti applicativi.

Con lo scopo di confrontare gli effetti delle applicazioni nei diversi domini, è stata costruita una matrice fondata su due orientamenti (Uo-D e S&Eo-D). Per ciascun orientamento, la matrice descrive la natura dello sforzo cognitivo richiesto nella progettazione di una specifica caratteristica di prodotto, distinguendo al suo interno diversi livelli di intensità che riflettono il carico e la complessità che, nei singoli casi, il progettista è chiamato a gestire. La matrice ha così consentito di posizionare le istanze di progettazione in funzione dell'orientamento prevalente e dell'intensità dello sforzo associato alla caratteristica considerata. A partire da tale posizionamento, è stato possibile osservare quali tecniche di AI ricorrano con maggiore frequenza e risultino più coerenti nel supportare specifiche combinazioni dei due assi, considerando il perimetro applicativo della caratteristica modellata. In questo modo è stato possibile interpretare l'associazione tra casi e strumenti tenendo conto anche dei vincoli operativi e di contesto che ne condizionano l'adozione e l'implementazione a livello aziendale.

Da tale impostazione consegue che il posizionamento dei casi non è stato concepito per associare in modo diretto i domini a specifiche aree della matrice. Assumere come discriminante lo sforzo progettuale richiesto dalla caratteristica in esame ha invece evidenziato come le potenzialità di uno stesso strumento possano trasferirsi tra domini differenti, a condizione che rimangano comparabili la natura e l'intensità dello sforzo cognitivo coinvolto. Ne deriva che casi appartenenti a domini diversi tendono a convergere nelle medesime aree della matrice e quindi a utilizzare strumenti simili quando riguardano caratteristiche progettuali analoghe e richiedono livelli di sforzo cognitivo equivalenti, a meno di vincoli di dominio particolari che ne limitano l'applicazione o il ruolo operativo.

Per quanto riguarda il confronto con il framework teorico, la mappatura dei casi ha evidenziato sia punti di continuità sia di scostamento. Le differenze sono principalmente riconducibili a limiti empirici, condizioni abilitanti e vincoli reali che, in alcuni casi, ridimensionano quanto atteso sul piano teorico. Nel complesso, la maggior parte delle associazioni tra sottofasi e strumenti risulta confermata, alcune applicazioni previste nella mappatura teorica, tuttavia, si sono rivelate troppo ambiziose e non trovano riscontro nella pratica, oppure emergono in forme più specializzate e compatibili con le esigenze concrete dell'ambito applicativo.

Tra gli scostamenti più evidenti emerge una marcata riduzione delle applicazioni di AI simbolica, oggi spesso percepita come un approccio superato. Tuttavia, essa può risultare ancora funzionale in numerose attività, soprattutto in ambito aziendale, grazie agli elevati livelli di spiegabilità e interpretabilità che garantisce rispetto agli approcci neurali, che invece li assicurano solo in parte. Ne consegue che le imprese potrebbero trarre beneficio da una maggiore esplorazione di soluzioni neuro-simboliche, in grado di combinare apprendimento statistico e strutturazione esplicita della conoscenza, integrando maggiore controllabilità nelle potenzialità avanzate offerte dagli approcci neurali moderni.

Al contrario, l'attenzione attuale si concentra prevalentemente sull'AI generativa e sui sistemi agentivi, che occupano una posizione centrale nel dibattito e nelle strategie di investimento aziendali. Permane tuttavia l'esigenza di chiarire in quali contesti tali tecnologie siano effettivamente in grado di generare valore stabile, replicabile e misurabile, così da orientare le decisioni di adozione aziendali su basi analitiche e consapevoli piuttosto che su dinamiche di hype.

A questo proposito, un ulteriore elemento di disallineamento rispetto alla teoria riguarda proprio l'AI agentiva. Le architetture multi-agente si configurano ancora come applicazioni di frontiera e, nei casi osservati, le implementazioni si limitano prevalentemente a singoli agenti o a configurazioni multi-agente semplici, impiegate su task operativi circoscritti. Non si osservano infatti, se non in forma embrionale, sistemi in grado di gestire in modo coordinato il processo anche nei task più critici e ad alto valore, nonostante il potenziale evidenziato dal framework teorico. Tale limitata diffusione risulta coerente con le dinamiche tipiche dei cicli di innovazione, nei quali le prime applicazioni tendono a concentrarsi su ambiti più circoscritti, funzionali a testare la tecnologia e a dimostrarne la fattibilità. Solo in una fase successiva, a fronte di evidenze consolidate e di investimenti più consistenti, anche le configurazioni più avanzate trovano implementazione. In questo senso, il fatto che le imprese stiano attualmente sperimentando soprattutto agenti orientati a compiti di produttività appare coerente con una fase iniziale di adozione, mentre l'estensione a task più critici e complessi dipenderà dalla progressiva maturazione tecnologica e organizzativa.

Anche sul piano del ruolo operativo, le determinanti individuate teoricamente restano valide, in particolare la criticità della fase e il grado di interazione per cui lo strumento è progettato; tuttavia, l'assegnazione effettiva del ruolo risulta spesso più prudente rispetto alla stima teorica perché intervengono fattori contestuali che la teoria non incorpora, quali vincoli specifici di dominio e flussi di lavoro aziendali già consolidati, requisiti di coerenza con identità e stile di brand, vincoli regolatori e requisiti di sicurezza per ambiente e persone, propensione alla gestione del rischio, protezione dei dati a fini competitivi, attribuzione della responsabilità decisionale, oltre alla criticità del componente progettato e al suo valore nel sistema di destinazione. Nel complesso, tali fattori aumentano la necessità di supervisione umana e spostano il ruolo verso riduzioni di autonomia e di ruolo operativo assegnato, salvo nei casi in cui lo strumento sia progettato in modo specifico e dedicato per quello scopo, anche quando l'istanza riguarda un caso particolarmente critico.

In linea generale, permane il trend verso SUP nelle fasi convergenti ad alta criticità, mentre la GenAI si colloca prevalentemente in AUG/SUP nelle fasi divergenti, dove potenzia la creatività in modo guidato e accelera produzione e visualizzazione di alternative. Analogamente, in processi iterativi con numerosi calcoli, anche complessi, il contributo è spesso AUG/SUP, poiché l'impostazione delle iterazioni e l'interpretazione o rimodellazione degli output restano in carico al progettista, sia per adattare i risultati al contesto specifico sia per colmare aspetti non modellati dallo strumento. Il ruolo può avvicinarsi a AUG quando il task è altamente formalizzabile e i vincoli tecnici risultano gestibili, come in alcune applicazioni di generative design su prodotti a ingegneria moderata. Le modalità AUT/AUG e, più raramente, AUT emergono invece soprattutto in task pienamente circoscritti, ripetitivi e a basso valore, per i quali un eventuale errore non richiede un presidio stringente della responsabilità.

In questo senso, rispetto alla mappatura teorica, gli scostamenti osservati si traducono spesso in un ridimensionamento delle aspettative in termini di autonomia attribuita allo strumento e in una maggiore cautela nell'assegnazione del ruolo operativo. Accade così che applicazioni differenti, pur basate sul medesimo strumento, vengano associate in alcuni casi a modalità AUG e in altri, collocati in quadranti diversi della matrice, risultino più realisticamente configurate come AUG/SUP, come nel caso del generative design.

La mappatura empirica rivela inoltre diversi spunti di riflessione che permettono di raffinare gli esiti teorici previsti e di vincolarli alle esigenze concrete. In primo luogo, i prodotti risultano spesso composti da caratteristiche che richiedono la modellazione congiunta sia di aspetti orientati all'utente, sia degli aspetti ingegneristici sottostanti, con sforzi cognitivi di natura diversa ma interdipendenti, poiché le scelte progettuali su un aspetto tendono a influenzare l'altro. Ne deriva che anche gli strumenti, spesso specializzati su specifiche forme di sforzo progettuale, devono essere adeguatamente coordinati, facendo emergere il valore di piattaforme collaborative e unificanti in grado di integrare e rendere coerenti output prodotti da strumenti differenti.

In secondo luogo, l'adozione di tool ad hoc per compiti molto specifici tende ad aumentare la qualità del risultato sul singolo task, ma può frammentare il flusso di lavoro e introdurre costi di coordinamento e setup che crescono con l'aumentare del numero di passaggi e di task coinvolti.

Questo tema emerge con particolare chiarezza quando si riconosce la specializzazione di uno strumento rispetto a un determinato task e lo si adotta in modo mirato per quel compito. È il caso, ad esempio, di componenti di ML o DL impiegati per una predizione circoscritta, di moduli di AI simbolica e deterministica utilizzati per verificare il rispetto di vincoli produttivi formalizzati, o di addestramenti focalizzati su esigenze operative specifiche. Questa logica, apparentemente più tipica di strumenti meno generalisti e verticali su un particolare dominio o su un task, si riflette però anche nell'AI generativa. Nonostante la sua natura più generalista e trasferibile tra attività diverse, il suo valore emerge soprattutto quando viene impiegata su compiti ben definiti, per i quali risulta realmente efficace. Di conseguenza, le organizzazioni che ne comprendono il funzionamento e i punti di forza caratterizzanti, tendono a trattarla non come una soluzione universale, ma come uno strumento da integrare selettivamente nelle applicazioni in cui il contributo è veramente di valore.

A tal proposito, alcune imprese la utilizzano in modo localizzato nelle fasi preliminari come supporto al brainstorming e per ridurre il blocco creativo, impiegando gli output come ispirazione e spostandosi poi su CAD o strumenti specialistici per refinement e validazione.

In questi casi, la specializzazione degli utilizzi degli strumenti generativi, da un lato, aumenta la frammentazione del processo, dall'altro contribuisce a mitigare il rischio di hallucinations a cui tali strumenti sono soggetti. Ciò avviene perché ogni generazione si colloca a monte delle attività che compongono la fase divergente e, di conseguenza, ogni output viene sottoposto a successive revisioni e rielaborazioni per adattarlo alle necessità concrete. Tuttavia, il problema della frammentazione permane. Per ridurlo, alcune aziende hanno sviluppato soluzioni più integrate, progettate a partire dall'osservazione dei workflow dei progettisti, con l'obiettivo di incorporare le funzionalità di AI all'interno di software più ampi, capaci di offrire un'interfaccia digitale unitaria in cui pratiche e step di lavoro preesistenti possano essere integrati con le nuove funzionalità offerte dai modelli generativi. Questa tendenza è visibile sia nelle chatbots integrati in software di progettazione e simulazione ingegneristica complessi, sia nelle applicazioni sviluppate per i designer che, a partire da keywords e requisiti iniziali, generano concept di prodotto coerenti con i vincoli definiti.

In alcune istanze specifiche, come nei contesti delle grandi aziende dei beni di consumo in cui la strategia punta più sulla differenziazione di prodotto che sull'innovazione radicale, gli obiettivi strategici di alto livello si sono dimostrati un limite rilevante che ha portato a circoscrivere l'utilizzo degli strumenti generativi. In questi casi, l'elevata divergenza delle generazioni cui lo strumento tende può indurre a limitarne l'impiego anche nelle fasi iniziali, soprattutto quando la familiarità del prodotto e la coerenza con l'identità del brand e con le abitudini dei consumatori costituiscono leve critiche per la fidelizzazione del cliente.

Un ulteriore limite, legato alla natura stessa di questi strumenti, riguarda la produzione di numerose alternative tra loro molto simili, con un effetto di sovraccarico sull'attività di screening manuale, che riduce l'efficienza complessivamente associata alla valutazione e selezione delle alternative da portare avanti nel processo di sviluppo.

Un altro elemento, già in parte richiamato, riguarda la diffusione dei modelli generativi con impiego generalista e la loro effettiva compatibilità nei contesti aziendali. La loro adozione può generare benefici di standardizzazione e sinergia interna, creando talvolta maggior valore rispetto all'impiego di molteplici soluzioni specialistiche. Tuttavia, l'utilizzo del medesimo asset su task eterogenei può diminuirne l'idoneità su alcune attività e introdurre frammentazione, poiché rilavorazioni e raffinamenti richiedono il passaggio a tool differenti, con una conseguente riduzione dell'affidabilità e dell'autonomia operativa attribuibile allo strumento inizialmente percepito come sufficiente anche per quelle attività più specifiche. A ciò si aggiunge un costo opportunità, legato al mancato utilizzo di strumenti più specializzati che, sul singolo compito, potrebbero garantire risultati migliori, pur introducendo maggiori costi di integrazione, coordinamento e setup.

Ne consegue la necessità di bilanciare costi e benefici tra l'adozione di un modello generalista più orizzontale e una soluzione verticale basata su strumenti specializzati. L'approccio specialistico tende ad aumentare i costi di integrazione e coordinamento, legati ai numerosi passaggi tra workflow e task abilitati da tool differenti, alla

moltiplicazione dei setup e alla difficoltà di rendere coerenti output prodotti da componenti diversi. L'adozione di un modello generalista, al contrario, può ridurre tali costi grazie a standardizzazione, coerenza degli output e maggiore facilità di comunicazione e allineamento tra dipartimenti, ma introduce trade-off distinti. In particolare, una minore efficacia su task verticali può rendere necessaria l'integrazione di strumenti aggiuntivi più idonei, adoperati successivamente a quello generalista, con cui raffinare e rendere compatibile l'output creato in partenza, riducendo parte del vantaggio iniziale in termini di coordinamento e setup e incidendo anche sulla fiducia operativa riposta nello strumento.

Le evidenze riportate dai casi aziendali dimostrano che il bilancio complessivo tende a essere positivo quando il modello generalista è impiegato trasversalmente ma limitatamente ai task per cui risulta effettivamente idoneo, e soprattutto in imprese di grandi dimensioni, dove la quota di task di produttività è elevata e i benefici di standardizzazione si amplificano lungo numerosi passaggi e handoff. Al contrario, realtà più piccole o maggiormente focalizzate ricorrono più spesso a strumenti ad hoc, coerentemente con la natura più circoscritta dei progetti e con una minore esigenza di uniformità su larga scala.

Altre evidenze sono emerse in relazione agli strumenti di generative design. Nei prodotti di grandi dimensioni e ad elevata complessità, l'impiego tende a concentrarsi nelle fasi preliminari di ideazione, poiché il numero elevato di variabili e di obiettivi di ottimizzazione ne limita l'efficacia nelle fasi divergenti più avanzate. Inoltre, la scarsa compatibilità di tali prodotti con la manifattura additiva, che può generare strutture fortemente integrate, esposte a tensioni residue e difficoltà manutentive, riduce la convenienza economica di tecniche produttive alternative nel tradurre in soluzioni realizzabili le geometrie proposte dal generative design. Una concentrazione analoga dell'uso dello strumento solo in certi stadi della fase divergente si osserva anche nei prodotti in cui la modellazione tecnica del behavior convive con una forte componente user-oriented, quando requisiti di brand e usabilità impongono di interromperne l'utilizzo e ricorrere ad altri strumenti per rifinire aspetti più concettuali che il generative design non modella. Al contrario, in contesti prevalentemente tecnici, poco complessi e con una componente user-oriented marginale, il generative design risulta più idoneo anche in fasi avanzate e consente di sfruttare con maggiore continuità la sinergia con la produzione additiva.

A livello interno aziendale emergono alcune condizioni necessarie affinché le associazioni rilevate risultino effettivamente realizzabili. In primo luogo, la gestione dei dati rappresenta un vincolo centrale. Le imprese tendono a evitare la diffusione dei propri dati e privilegiano modelli interni oppure soluzioni open source specializzate, sottoposte a fine-tuning su dataset aziendali, così da integrare conoscenza specifica mantenendo la protezione delle informazioni. In questo contesto, conta non solo la quantità dei dati, ma soprattutto la loro qualità, pulizia ed etichettatura, da cui dipendono affidabilità predittiva e generativa, presenza di bias e rischio di hallucinations. Si osserva inoltre una tendenza alla specializzazione dei modelli in funzione delle finalità progettuali e delle relazioni di dominio da apprendere. I dati possono provenire da simulazioni, progetti tecnici passati, feedback dei clienti, vincoli regolatori e ambientali, oppure da specifiche condizioni di producibilità interne. La natura dei dati e l'obiettivo di addestramento determinano il grado di specializzazione del modello, rendendolo maggiormente idoneo al task assegnato. Anche i modelli generalisti, se opportunamente adattati, possono acquisire maggiore aderenza al dominio rispetto alla loro configurazione originaria.

L'integrazione dello strumento nei processi aziendali dipende inoltre da variabili organizzative e culturali. Vincoli normativi, livello di digitalizzazione e livello di avanzamento dei processi di raccolta dati, competenze interne e, soprattutto, fiducia nella tecnologia, influenzano fortemente la compatibilità di implementazione dei sistemi di AI. Una scarsa consapevolezza delle capacità e dei limiti di questa tecnologia può portare sia a sottoutilizzo sia a sovrastima dello strumento, con conseguenze anche potenzialmente gravi. Diventa quindi fondamentale sviluppare competenze complementari, come la comprensione dei profili regolatori (es. AI Act) e la capacità di prompting, soprattutto in un contesto in cui l'interazione conversazionale assume un ruolo centrale come quello degli approcci generativi. Se da un lato l'automazione crescente riduce la necessità di intervento continuo da parte dell'utente, dall'altro rende ancora più decisivo l'input iniziale fornito dal soggetto, che orienta l'intero processo di ragionamento.

Infine, la gestione delle responsabilità costituisce un ulteriore vincolo all'attribuzione dell'autonomia affidata allo strumento. In termini operativi e giuridici, la responsabilità dell'esito resta in capo al soggetto che valida e supervisiona l'output, anche quando parti del lavoro sono state delegate allo strumento. Di conseguenza,

l'incertezza sulla tracciabilità delle decisioni e il rischio di errori o di output difficilmente giustificabili a posteriori alimentano forme di cautela più rigide. In alcuni contesti, ciò induce a confinare l'uso dell'AI a compiti a basso impatto, oppure a rafforzare i livelli di verifica umana, riducendone di fatto l'autonomia e l'ampiezza di impiego.

Dal punto di vista delle prospettive future, le traiettorie evolutive suggeriscono uno sviluppo verso strumenti capaci di coniugare progressivamente specializzazione e generalizzazione, ossia di svolgere task differenti mantenendo al contempo un'elevata qualità esecutiva. Ciò che oggi viene perseguito attraverso piattaforme collaborative che integrano output prodotti da strumenti specialistici distinti tende a evolvere in architetture multi-agente sempre più complesse, in grado di coordinare, aggiornare dinamicamente e integrare in modo iterativo i contributi di agenti verticali dedicati a specifiche attività progettuali.

Già con l'AI generativa si intravede questa duplice tendenza alla generalizzazione e alla specializzazione simultanea, evidente nel passaggio dai modelli linguistici a quelli multimodali e nelle diverse declinazioni dei modelli transformer-based adattati tramite fine-tuning a finalità specifiche. Tuttavia, tali modelli mostrano ancora limiti quando vengono impiegati in contesti per cui non sono stati originariamente concepiti. Le architetture multi-agente, che combinano tecniche differenti per compiti sia trasversali di coordinamento e comunicazione sia verticali di progettazione, rappresentano un tentativo di superare tali limiti, così come stanno tentando di fare gli approcci neuro-simbolici, che mirano a integrare apprendimento statistico e strutturazione esplicita della conoscenza, aumentando affidabilità e controllabilità attraverso la complementarità dei paradigmi.

Parallelamente, si stanno sviluppando concetti teorici ancora in larga parte ipotetici, come l'Artificial General Intelligence e la cosiddetta superintelligenza, intesi come sistemi in grado di eguagliare o superare l'essere umano su un'ampia gamma di compiti cognitivi, coniugando al massimo grado specializzazione e generalità. Sebbene tali sviluppi si trovino ancora in una fase preliminare e manchi una definizione condivisa, la direzione della ricerca appare orientata verso trasformazioni potenzialmente profonde, non solo nei processi di progettazione e nella creazione di valore economico, ma più in generale nelle modalità di organizzazione del lavoro e della vita quotidiana.

Nel complesso, dal punto di vista del contributo apportato, la tesi propone una revisione della letteratura sull'intelligenza artificiale che consente di esplorare tecniche passate, attuali ed emergenti, offrendo una visione tassonomica coerente con i piani di classificazione adottati e utile a ricostruire un quadro complessivo delle potenzialità oggi disponibili. Su questa base, il framework teorico definisce un modello di riferimento trasversale a livelli e domini della progettazione, proponendo associazioni tra sottofasi e strumenti e qualificandone l'idoneità tramite ruolo operativo e autonomia, così da descrivere sia applicazioni correnti sia traiettorie potenziali. Il risultato può costituire un punto di partenza, in ambito accademico, per individuare aree ancora poco esplorate, colmare lacune di associazioni mancanti e approfondire relazioni preliminari che sono apparse promettenti ma che richiedono ulteriori indagini e sperimentazioni. Sul piano empirico, l'analisi dei casi di studio conferma in parte le associazioni del framework teorico, ma introduce anche evidenze pratiche e vincoli reali che il modello trasversale non cattura pienamente. Infine, la matrice degli orientamenti progettuali ha consentito un posizionamento comparativo dei casi aziendali e ha ricondotto l'adozione degli strumenti non al prodotto nel suo complesso, bensì alla natura dello sforzo cognitivo richiesto dalla progettazione di specifiche caratteristiche di prodotto. Assumendo tale criterio come guida per il collocamento dei casi, è stato possibile rendere esplicite le condizioni entro cui uno stesso strumento può essere applicato in domini differenti, offrendo alle imprese un riferimento per riconoscere analogie con il proprio contesto, analizzarne le implicazioni operative e basare le decisioni di adozione su effetti empiricamente osservabili, come documentato dai KPI dei casi analizzati.

Indice delle tabelle

Tabella 2.1:	Tassonomia per tecniche di Intelligenza artificiale completa, rielaborazione sintetica tratta dalle tabelle di Taxonomy of Artificial Intelligence [3].	41
Tabella 2.2:	Confronto tra tecniche selezionate di AI simbolica (Rule-based expert system, Knowledge Graph e Ontology reasoning), parte 1.	45
Tabella 2.3:	Confronto tra tecniche selezionate di AI simbolica (Rule-based expert system, Knowledge Graph e Ontology reasoning), parte 2.	46
Tabella 2.4:	Confronto tra tecniche selezionate di AI evolutiva (GA e GP), parte 1.	46
Tabella 2.5:	Confronto tra tecniche selezionate di AI evolutiva (GA e GP), parte 2.	47
Tabella 2.6:	Confronto tra tecniche selezionate di ML (Random Forest, SVM, K-Means), parte 1.	47
Tabella 2.7:	Confronto tra tecniche selezionate di ML (Random Forest, SVM, K-Means), parte 2.	48
Tabella 2.8:	Confronto tra tecniche selezionate di DL (architetture: CNN, RNN/LSTM, Transformer), parte 1.	49
Tabella 2.9:	Confronto tra tecniche selezionate di DL (architetture: CNN, RNN/LSTM, Transformer), parte 2.	50
Tabella 2.10:	Confronto tra tecniche selezionate di DL (modelli generativi: LLM, GAN, Diffusion Models, VAE), parte 1.	51
Tabella 2.11:	Confronto tra tecniche selezionate di DL (modelli generativi: LLM, GAN, Diffusion Models, VAE), parte 2.	52
Tabella 3.1:	Associazione delle categorie di collegamento alle attività e sottofasi del Planning: output attesi, tipologia di task da eseguire, criticità e livello di supervisione necessaria. Alcune delle attività presenti, con relativa associazione alla tipologia di task, sono tratte da Montagna.F (2011) [129].	68
Tabella 3.2:	Associazione delle categorie di collegamento alle attività e sottofasi del Problem Definition&Structuring: output attesi, tipologia di task da eseguire, criticità e livello di supervisione necessaria. Alcune delle attività presenti, con relativa associazione alla tipologia di task, sono tratte da Montagna.F (2011) [129].	69
Tabella 3.3:	Associazione delle categorie di collegamento alle attività e sottofasi dell'Idea Generation: output attesi, tipologia di task da eseguire, criticità e livello di supervisione necessaria. Alcune delle attività presenti, con relativa associazione alla tipologia di task, sono tratte da Montagna.F (2011) [129].	70
Tabella 3.4:	Associazione delle categorie di collegamento alle attività e sottofasi dell'Idea/Component Combination: output attesi, tipologia di task da eseguire, criticità e livello di supervisione necessaria. Alcune delle attività presenti, con relativa associazione alla tipologia di task, sono tratte da Montagna.F (2011) [129].	71
Tabella 3.5:	Associazione delle categorie di collegamento alle attività e sottofasi del Concept Generation&Optimization: output attesi, tipologia di task da eseguire, criticità e livello di supervisione necessaria. Alcune delle attività presenti, con relativa associazione alla tipologia di task, sono tratte da Montagna.F (2011) [129].	72
Tabella 3.6:	Associazione delle categorie di collegamento alle attività e sottofasi del Concept Evaluation&Selection: output attesi, tipologia di task da eseguire, criticità e livello di supervisione necessaria. Alcune delle attività presenti, con relativa associazione alla tipologia di task, sono tratte da Montagna.F (2011) [129].	73

Tabella 3.7:	Associazione delle categorie di collegamento ai paradigmi di AI: tipologie di output producibili, tipologia di task eseguibili, ruolo operativo e livello di autonomia.	76
Tabella 3.8:	Mappatura tra attività/sottofasì e strumenti di Intelligenza artificiale nel planning strategico, interpretato in relazione ai processi di innovazione e alle fasi di supporto decisionale che precedono la progettazione nel processo sviluppo prodotto.	82
Tabella 3.9:	Mappatura tra attività/sottofasì e strumenti di Intelligenza artificiale nel Problem Definition&Structuring.	87
Tabella 3.10:	Mappatura tra attività/sottofasì e strumenti di Intelligenza artificiale nell'Idea Generation.	92
Tabella 3.11:	Mappatura tra attività/sottofasì e strumenti di Intelligenza Artificiale nell' Idea/Component Combination.	96
Tabella 3.12:	Mappatura tra attività/sottofasì e strumenti di Intelligenza Artificiale nel Concept Generation.	98
Tabella 3.13:	Mappatura tra attività/sottofasì e strumenti di Intelligenza Artificiale nel Concept Optimization.	102
Tabella 3.14:	Mappatura tra attività/sottofasì e strumenti di Intelligenza artificiale nel Concept Evaluation&Selection.	105

Indice delle figure

Figura 2.1:	Schematizzazione del processo di ricerca: metodo PRISMA, Snowballing e ricerca mirata dei temi specifici.	14
Figura 2.2:	A sinistra è mostrata l'evoluzione nel tempo, a destra la distribuzione geografica dei documenti sulla letteratura dell'intelligenza artificiale indicizzati in Scopus.	15
Figura 2.3:	Distribuzione dei documenti sulla letteratura dell'intelligenza artificiale presenti nel database Scopus suddivisi per aree disciplinari.	16
Figura 2.4:	Relazione gerarchica tra Intelligenza Artificiale, Machine Learning, Deep Learning e Generative AI, con esempi rappresentativi e principi distintivi, posizionati nel tempo (rielaborazione da IBM, 2024 [4] e Abou Ali et al., 2025 [5]).	18
Figura 2.5:	Classificazione per tecniche.	21
Figura 2.6:	Tassonomia dell'AI simbolica con metodi e algoritmi più noti, schema rielaborato da tabella di Taxonomy of Artificial Intelligence [3].	21
Figura 2.7:	Tassonomia dell'AI evolutiva e bio-ispirata con metodi e algoritmi più noti, schema rielaborato da tabella di Taxonomy of Artificial Intelligence [3].	23
Figura 2.8:	Tecniche di apprendimento nel ML, figura tratta da "Machine Learning and Deep Learning Paradigms: From Techniques to Practical Applications and Research Frontiers" [28].	24
Figura 2.9:	Tassonomia del ML con metodi e algoritmi più noti, schema rielaborato da tabella di Taxonomy of Artificial Intelligence [3].	25
Figura 2.10:	Tassonomia del DL con metodi e algoritmi più noti, schema rielaborato da tabella di Taxonomy of Artificial Intelligence [3].	28
Figura 2.11:	Classificazione delle tecniche DL in base alla modalità di apprendimento <i>e alla formulazione probabilistica</i> [36].	29
Figura 2.12:	Domini e Applicazioni dei Transformer, tratta da [28].	36
Figura 2.13:	Tassonomia del Hybrid AI con metodi e algoritmi più famosi, schema rielaborato da tabella di Taxonomy of Artificial Intelligence [3].	38
Figura 3.1:	Domini, livelli e fasi della progettazione nel processo sviluppo prodotto.	61
Figura 3.2:	Categorie di collegamento tra le fasi del processo di progettazione e gli strumenti di Intelligenza Artificiale e relativi fattori influenzanti.	66
Figura 4.1:	Rappresentazione della Matrice degli Orientamenti Progettuali, articolata in livelli ordinali lungo gli assi U-oD e S&E-oD, con quadranti etichettati da lettere per identificare aree di posizionamento.	114
Figura 4.2:	Sotto-fattori che determinano l'orientamento U-oD: Funzionale (F), Esperienziale(E) e Strutturale (S).	116
Figura 4.3:	Schematizzazione di elementi funzionali distinti che interagiscono all'interno di un sistema per realizzare una funzionalità pratica di livello superiore. Fonte: slide del corso <i>Gestione dell'innovazione e sviluppo prodotto</i> , Prof.ssa Francesca Montagna, 2025.	117
Figura 4.4:	Sotto-fattori che determinano l'orientamento S&E-oD dalla prospettiva ingegneristica: Behaviour del sistema (Bs) e Behavior del componente (Bc).	118
Figura 4.5:	Sotto-fattori che determinano l'orientamento S&E-oD dalla prospettiva scientifica: numero fasi e criticità delle soglie.	119

Figura 4.6:	Collocazione dei casi di studio aziendali emersi dalla ricerca empirica all'interno della Matrice degli Orientamenti Progettuali.....	156
Figura 4.7:	Mappatura degli strumenti e delle tecniche di intelligenza artificiale nei quadranti della Matrice degli Orientamenti Progettuali in relazione ai casi applicativi aziendali analizzati.....	157
Figura 4.8:	Mappatura dei ruoli operativi e dei livelli di autonomia degli strumenti e delle tecniche di intelligenza artificiale nei quadranti della Matrice degli Orientamenti Progettuali, in relazione ai casi applicativi aziendali analizzati.....	158

Bibliografia

- [1] A. Krizhevsky, I. Sutskever and G. E. Hinton, "ImageNet Classification with Deep Convolutional Neural Networks," *Advances in Neural Information Processing Systems*, vol. 25, pp. 1097-1105, 2012.
- [2] B. Liang, Y. Wang and C. Tong, "AI Reasoning in Deep Learning Era: From Symbolic AI to Neural-Symbolic AI," *Mathematics*, vol. 13, no. 11, p. 1707, 2025.
- [3] A. Dutta, "Taxonomy of Artificial Intelligence," July 2025.
- [4] IBM, What is Artificial Intelligence (AI)?, IBM Think Topics, <https://www.ibm.com/think/topics/artificial-intelligence>, 2024.
- [5] M. Abou Ali and F. Dornaika, Agentic AI: A Comprehensive Survey of Architectures, Applications, and Future Directions, 2025.
- [6] M. Chen, Y. Bai, J. D. Lee, T. Zhao, H. Wang, C. Xiong and R. Socher, *Towards Understanding Hierarchical Learning: Benefits of Neural Representations*, 2020.
- [7] Gartner, Inc., "Gartner Hype Cycle Identifies Top AI Innovations in 2025," 5 August 2025. [Online]. Available: <https://www.gartner.com/en/newsroom/press-releases/2025-08-05-gartner-hype-cycle-identifies-top-ai-innovations-in-2025>.
- [8] J. Wu, H. You and J. Du, AI Generations: From AI 1.0 to AI 4.0, 2025.
- [9] J. Kaplan, S. McCandlish, T. Henighan, T. B. Brown, B. Chess, R. Child, S. Gray, A. Radford, J. Wu and D. Amodei, "Scaling laws for neural language models.," 2020.
- [10] S. J. Russell and P. Norvig, *Artificial Intelligence: A Modern Approach*, 1995.
- [11] D. Mourtzis, J. Angelopoulos and N. Panopoulos, "A Comparative Analysis of Symbolic and Subsymbolic Approaches in Artificial Intelligence," in *Handbook of AI in Engineering Applications: Tools, Techniques, and Algorithms.*, CRC Press / Routledge, 2024, pp. 25-49.
- [12] P. Gärdenfors, "Knowledge in Flux: Modeling the Dynamics of Epistemic States," MIT Press, 1988.
- [13] H. G. Beyer and H. P. Schwefel, "Evolution strategies. A comprehensive introduction," *Natural Computing*, vol. 1, no. 1, pp. 3-52, 2002.
- [14] T. Bäck, «Evolutionary Algorithms for Parameter Optimization — Thirty Years (1993-2023),» in *Evolutionary Computation*, 31(2), 2023.
- [15] Z.-H. Zhan, L. Shi, K. Chen Tan and J. Zhang, "A Survey on Evolutionary Computation for Complex Continuous Optimisation Problems," *Artificial Intelligence Review*, 2021.
- [16] L. Sekanina, *Evolutionary Algorithms in Approximate Computing: A Survey*, 2021.
- [17] Y. Qawqzeh, M. T. Alharbi, A. Jaradat and K. N. A. Sattar, A review of swarm intelligence algorithms deployment for scheduling and optimization in cloud computing environments, 2021.
- [18] A. A. Shaban and I. M. Ibrahim, "Swarm Intelligence Algorithms: A Survey of Modifications and Applications," *International Journal of Scientific World*, vol. 11, no. 1, 2025.
- [19] A. Mugwagwa, C. Chibaya and E. Bhero, "A Survey of Inspiring Swarm Intelligence Models for the Design of a Swarm-Based Ontology for Addressing the Cyber Security Problem," *Int. J. Research in Business and Social Science*, vol. 12, no. 4, pp. 483-494, 2023.
- [20] N. Hansen, D. Arnold and A. Auger, "Evolution Strategies," in *Springer Handbook of Computational Intelligence.*, Berlin, Springer Handbooks, 2015.

- [21] L. Rios and N. Sahinidis, "Derivative-free optimization: a review of algorithms and comparison of software implementations," *Journal of Global Optimization*, vol. 56, pp. 1247-1293, 2013.
- [22] R. Storn and K. Price, "Differential Evolution – A Simple and Efficient Heuristic for Global Optimization over Continuous Spaces," *Journal of Global Optimization*, vol. 11, pp. 341-359, 1997.
- [23] O. Adekanmbi and P. Green, "Conceptual Comparison of Population-Based Metaheuristics for Engineering Problems," *The Scientific World Journal*, 2015.
- [24] R. Poli, J. Kennedy and T. Blackwell, "Particle Swarm Optimization – An overview," *Swarm Intelligence*, vol. 1, no. 1, pp. 33-57, 2007.
- [25] M. Dorigo and K. Socha, *An Introduction to Ant Colony Optimization*, MIT Press, 2019.
- [26] D. Karaboga and B. Basturk, "A powerful and efficient algorithm for numerical function optimization: artificial bee colony (ABC) algorithm," *J Glob Optim*, no. 39, p. 459–471, 2007.
- [27] H. Alaskar and T. Saba, *Machine Learning and Deep Learning: A Comparative Review*, 2021.
- [28] K. Razzaq and M. Shah, "Machine Learning and Deep Learning Paradigms: From Techniques to Practical Applications and Research Frontiers," *Computers*, vol. 14, no. 3, p. 93, 2025.
- [29] R. J. S. Ruíz, O. A. M. López, G. H. Ramírez and J. C. Hiriart, "Generalized Linear Models Springer," *Generalized Linear Mixed Models with Applications in Agriculture and Biology*, pp. 43-84, 2023.
- [30] J. A. Nelder and R. W. M. Wedderburn, "Generalized Linear Models," *Journal of the Royal Statistical Society. Series A (General)*, vol. 135, no. 3, pp. 370-384, 1972.
- [31] J. Ameet V., *Machine Learning and Artificial Intelligence*, 2nd Edition, Springer, 2023.
- [32] J. Quinlan, "Induction of decision trees," *Mach Learn I*, p. 81–106, 1986.
- [33] N. Chauhan and K. Singh, "A Review on Conventional Machine Learning vs Deep Learning," in *International Conference on Computing, Power and Communication Technologies (GUCON)*, 2018.
- [34] Z. He, D. Lin, T. Lau and M. Wu, "Gradient Boosting Machine: A Survey," 2019.
- [35] M. Puttegowda and S. B. Nagaraju, "Artificial intelligence and machine learning in mechanical engineering: Current trends and future prospects,," *Engineering Applications of Artificial Intelligence*, vol. 142, 2025.
- [36] I. H. Sarker, "Deep Learning: A Comprehensive Overview on Techniques, Taxonomy, Applications and Research Directions," *SN Comput Sci.*, vol. 2, no. 6, p. 420, 2021.
- [37] S.F. Ahmed, M.S.B. Alam, M. Hassan et al., "Deep learning modelling techniques: current progress, applications, advantages, and challenges," *Artif Intell Rev* 56, p. 13521–13617, 2023.
- [38] E. Argouarc'h, F. Desbouvries, E. Barat and E. Kawasaki, "Generative vs. Discriminative Modeling under the Lens of Uncertainty Quantification," 2024.
- [39] D. Patil, N. L. Rane, P. Desai and J. Rane., "Machine learning and deep learning: Methods, techniques, applications, challenges, and future research opportunities," 2024.
- [40] I. Goodfellow, Y. Bengio and A. Courville, *Deep Learning*, MIT Press, 2016.
- [41] R. Mishra, G. Reddy and H. Pathak, *The Understanding of Deep Learning: A Comprehensive Review. Mathematical Problems in Engineering*, 2021.
- [42] C. Janiesch, P. Zschech and K. Heinrich, "Machine learning and deep learning," *Electronic Markets*, vol. 31, no. 3, p. 685–695, 2021.

- [43] S. Pouyanfar, S. Sadiq, Y. Yan, H. Tian, Y. Tao, M. Presa Reyes, M. L. Shyu, S. C. Chen and S. Iyengar, “A Survey on Deep Learning: Algorithms, Techniques, and Applications,” *ACM Computing Surveys*, no. 51, pp. 1–36, 2018.
- [44] Q. Liu, M. Allamanis, M. Brockschmidt and A. L. Gaunt, “Constrained Graph Variational Autoencoders for Molecule Design,” *Advances in Neural Information Processing Systems*, 2018.
- [45] P. S. Q. Yeoh, K. Hasikin, X. Wu, S. L. Goh and K. W. Lai, “Trends and applications of variational autoencoders in medical imaging analysis,” *Computers in Biology and Medicine*, vol. 178, p. 108352, 2025.
- [46] L. Yang, Z. Zhang, Y. Song, S. Hong, R. Xu, Y. Zhao, W. Zhang, B. Cui and M.-H. Yang, Diffusion models: A comprehensive survey of methods and applications, 2025.
- [47] L. Deng and N. Jaitly, “Deep Discriminative and Generative Models for Pattern Recognition,” *Deep Learning: Methods and Applications, Microsoft Research*, ch. 1.2, 2014.
- [48] S. Bond-Taylor, A. Leach, Y. Long and C. G. Willcocks, Deep Generative Modelling: A Comparative Review of VAEs, GANs, Normalizing Flows, Energy-Based and Autoregressive Models, 2022.
- [49] A. Vaswani, N. Shazeer, N. Parmar, J. Uszkoreit, L. Jones, A. Gomez, L. Kaiser and I. Polosukhin, “Attention Is All You Need,” in *31st Conference on Neural Information Processing Systems (NIPS)*, 2017.
- [50] C. Zhou et al., A Comprehensive Survey on Pretrained Foundation Models: A History from BERT to ChatGPT, 2023.
- [51] S. Minaee, T. Mikolov, N. Nikzad, M. Chenaghlu, R. Socher, X. Amatriain and J. Gao, Large Language Models: A Survey, 2024.
- [52] Gemini Team, Google, Gemini: A Family of Highly Capable Multimodal Models, 2025.
- [53] K. Yi, J. Wu, C. Gan, A. Torralba, P. Kohli and J. Tenenbaum, “Neural-Symbolic VQA: Disentangling Reasoning from Vision and Language Understanding,” *Advances in Neural Information Processing Systems (NeurIPS)*, 2019.
- [54] T. A. Henzinger, “The Theory of Hybrid Automata,” *Proceedings of the 11th Annual IEEE Symposium on Logic in Computer Science (LICS)*, p. 278–292, 1996.
- [55] D. S. Nau, T. C. Au, O. Ilghami, U. Kuter, H. Muñoz-Avila, J. W. Murdock, D. Wu and F. Yaman, “SHOP2: An HTN Planning System,” *Journal of Artificial Intelligence Research*, vol. 20, p. 379–404, 2003.
- [56] L. P. Kaelbling and T. Lozano-Pérez, “Integrated Task and Motion Planning,” *International Journal of Robotics Research*, vol. 32, no. 9–10, p. 1194–1227, 2013.
- [57] R. Manhaeve, S. Dumančić, A. Kimmig, T. Demeester and L. D. Raedt, “DeepProbLog: Neural Probabilistic Logic Programming,” *Advances in Neural Information Processing Systems (NeurIPS)*, 2018.
- [58] R. Riegel et al., “Logical Neural Networks,” *Proc. AAAI Conf. Artif. Intell.*, vol. 34, p. 2954–2961, 2020.
- [59] L. A. Zadeh, “Fuzzy Sets,” *Information and Control*, vol. 8, no. 3, p. 338–353, 1965.
- [60] J.-S. R. Jang, “ANFIS: Adaptive-Network-Based Fuzzy Inference System,” *IEEE Transactions on Systems, Man, and Cybernetics*, vol. 23, no. 3, p. 665–685, 1993.
- [61] T. Rocktäschel and S. Riedel, “End-to-End Differentiable Proving,” *Advances in Neural Information Processing Systems (NeurIPS)*, 2017.
- [62] R. Evans and E. Grefenstette, “Learning Explanatory Rules from Noisy Data,” *Journal of Artificial Intelligence Research*, vol. 61, p. 1–64, 2018.

- [63] J. H. Holland, "Adaptation in Natural and Artificial Systems," Ann Arbor, MI, USA, Univ. Michigan Press, 1975.
- [64] J. R. Koza, "Genetic Programming: On the Programming of Computers by Means of Natural Selection," Cambridge, MA, USA, MIT Press, 1992.
- [65] Y. Ren, Y. Liu, T. Ji and X. Xu, "AI Agents and Agentic AI – Navigating a plethora of concepts for future manufacturing," *Journal of Manufacturing Systems*, vol. 83, p. 126–133, 2025.
- [66] G. de Aquino et al., "From RAG to Multi-Agent Systems: A Survey of Modern Approaches in LLM Development," *Preprints*, 6 Feb. 2025.
- [67] N. Indurkha, S. M. Weiss and P. Politakis, Complexity-based evaluation of rule-based expert systems, 1987.
- [68] P. Lucas and L. C. van der Gaag, Principles of Expert Systems, Addison-Wesley, 1991.
- [69] C. L. Forgy, "Rete: A Fast Algorithm for the Many Pattern/Many Object Pattern Match Problem," *Artificial Intelligence*, vol. 19, no. 1, p. 17–37, 1982.
- [70] D. Calvanese, G. De Giacomo, D. Lembo, M. Lenzerini and R. Rosati, "Tractable reasoning and efficient query answering in Description Logics: The DL-Lite family," *Journal of Automated Reasoning*, vol. 39, no. 3, p. 385–429, 2007.
- [71] A. Poggi, D. Lembo, D. Calvanese, G. De Giacomo, M. Lenzerini and R. Rosati, "Linking data to ontologies," *Journal on Data Semantics*, vol. 10, p. 133–173, 2008.
- [72] F. Baader, D. L. McGuinness, D. Nardi and P. F. Patel-Schneider, The Description Logic Handbook: Theory, Implementation, and Applications, 2003.
- [73] I. Moser and E. Polakova, "On the scalability of genetic algorithms to very large-scale feature selection.," in *Advances in Evolutionary Computing: Theory and Applications*, Springer, 2000.
- [74] E. Alba and M. Tomassini, "Parallelism and evolutionary algorithms," *IEEE Transactions on Evolutionary Computation*, vol. 6, no. 5, p. 443–462, 2002.
- [75] A. Eiben and J. Smith, Introduction to Evolutionary Computing, Springer, 2003.
- [76] M. Mitchell, An Introduction to Genetic Algorithms, MIT Press, 1996.
- [77] D. E. Goldberg, Genetic Algorithms in Search, Optimization and Machine Learning, Addison-Wesley Longman Publishing Co., 1989.
- [78] S. Luke, "Modification point depth and genome growth in genetic programming," Fairfax, VA., Department of Computer Science, George Mason University, 2000.
- [79] R. Poli, W. B. Langdon and N. F. McPhee, A Field Guide to Genetic Programming, Lulu Enterprises, 2008.
- [80] S. Silva and E. Costa, "Dynamic limits for bloat control in genetic programming and a review of past and current bloat theories," *Genetic Programming and Evolvable Machines*, vol. 10, pp. 141-179, 2009.
- [81] A. Broder, L. Pueyo, V. Josifovski, S. Vassilvitskii and S. Venkatesan, "Scalable K-Means by ranked retrieval," in *Proceedings of the 7th ACM International Conference on Web Search and Data Mining*, 2014, pp. 233-242.
- [82] R. Genuer, J.-M. Poggi, C. Tuleau-Malot and N. Villa-Vialaneix, "Random forests for big data," *Big Data Research*, vol. 6, pp. 28-46, 2015.
- [83] B. Li, X. Chen, M. J. Li, J. Z. Huang and S. Feng, "Scalable random forests for massive data," in *Advanced Data Mining and Applications*, Springer, 2012, p. 158.

- [84] L. Breiman, “Random Forests,” *Machine Learning*, vol. 45, pp. 5-32, 2001.
- [85] GeeksforGeeks, “When to use Random Forest over SVM and vice versa?,” 23 July 2025. [Online]. Available: <https://www.geeksforgeeks.org/machine-learning/when-to-use-random-forest-over-svm-and-vice-versa>.
- [86] T. Joachims, “Making large-scale SVM learning practical,” in *Advances in Kernel Methods: Support Vector Learning*, MIT Press, 1998.
- [87] J. C. Platt, “Fast training of support vector machines using sequential minimal optimization,” in *Advances in Kernel Methods: Support Vector Learning*, MIT Press, 1998, pp. 185-208.
- [88] L. Bottou and C.-J. Lin, “Support vector machine solvers,” in *Large-Scale Kernel Machines*, MIT Press., 2007, pp. 301-320.
- [89] B. Bahmani, B. Moseley, A. Vattani, R. Kumar and S. Vassilvitskii, “Scalable k-means++,” *Proceedings of the VLDB Endowment*, vol. 5, no. 7, p. 622–633, 2012.
- [90] T. Kanungo, D. M. Mount, N. S. Netanyahu, C. D. Piatko, R. Silverman and A. Y. Wu, “An efficient k-means clustering algorithm: Analysis and implementation,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 24, no. 7, pp. 881-892, 2002.
- [91] K. He, X. Zhang, S. Ren and J. Sun, “Deep residual learning for image recognition,” *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, p. 770–778, 2016.
- [92] K. Simonyan and A. Zisserman, “Very Deep Convolutional Networks for Large-Scale Image Recognition,” in *3rd International Conference on Learning Representations (ICLR 2015)*, Computational and Biological Learning Society, 2015, pp. 1-14.
- [93] A. Shah, C.-Y. Wu, J. Mohan, V. Chidambaram and P. Krähenbühl, “Memory Optimization for Deep Networks,” in *International Conference on Learning Representations*, University of Texas at Austin, 2021.
- [94] S. Hochreiter and J. Schmidhuber, “Long short-term memory. Neural Computation,” vol. 9, no. 8, p. 1735–1780, 1997.
- [95] R. Jozefowicz, W. Zaremba and I. Sutskever, “An empirical exploration of recurrent network architectures,” *Proceedings of the 32nd International Conference on Machine Learning (ICML)*, p. 2342–2350, 2015.
- [96] N. P. Jouppi et al., *In-datacenter performance analysis of a Tensor Processing Unit*, 2017.
- [97] A. Brock, J. Donahue and K. Simonyan, “Large scale GAN training for high fidelity natural image synthesis,” in *International Conference on Learning Representations (ICLR)*, 2019.
- [98] K. Kurach, M. Lucic, X. Zhai, M. Michalski and S. Gelly, “A large-scale study on regularization and normalization in GANs,” *Proceedings of the 36th International Conference on Machine Learning (ICML)*, p. 3581–3590, 2019.
- [99] M. Lucic, K. Kurach, M. Michalski, O. Bousquet and S. Gelly, “Are GANs created equal? A large-scale study,” *Advances in Neural Information Processing Systems*, vol. 31, 2018.
- [100] Z. Wang, Q. She and T. E. Ward, “Generative Adversarial Networks in computer vision: A survey and taxonomy,” *ACM Computing Surveys*, vol. 54, no. 6, pp. 1-38, 2021.
- [101] J. Ho, A. Jain and P. Abbeel, “Denoising diffusion probabilistic models,” *Advances in Neural Information Processing Systems*, vol. 33, p. 6840–6851, 2020.
- [102] P. Dhariwal and A. Nichol, “Diffusion models beat GANs on image synthesis,” 2021.

- [103] F. Bieder, J. Wolleb, A. Durrer, R. Sandkühler and P. C. Cattin, “Memory-efficient 3D denoising diffusion models for medical image processing,” *Proceedings of Machine Learning Research*, vol. 227, pp. 552-567, 2023.
- [104] A. Buzovkin and E. Shilov, “Toward lightweight and fast decoders for diffusion models in image and video generation,” 2025.
- [105] L. Lo, C. Y. Yeo, H.-H. Shuai and W.-H. Cheng, “Distraction is all you need: Memory-efficient image immunization against diffusion-based image editing,” in *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, Seattle, WA, USA, 2024, pp. 24462-24471.
- [106] D. P. Kingma and M. Welling, “Auto-encoding variational Bayes,” 2022.
- [107] A. Asperti, S. Evangelista and A. Piccolomini, “A Survey on Variational Autoencoders from a Green AI Perspective,” *SN Computer Science*, vol. 2, no. 4, pp. 1-19, 2021.
- [108] M. Mintrom, “Herbert A. Simon, Administrative Behavior: A Study of Decision-Making Processes in Administrative Organization,” in *The Oxford Handbook of Classics in Public Policy and Administration*, Oxford University Press, 2015.
- [109] H. A. Simon, “A Behavioral Model of Rational Choice,” *Quarterly Journal of Economics*, vol. 69, pp. 99-118, 1955.
- [110] H. A. Simon, “The Structure of Ill-Structured Problems,” *Artificial Intelligence*, vol. 4, no. 3-4, pp. 181-201, 1973.
- [111] S. K. Reed, “The Structure of Ill-Structured (and Well-Structured) Problems Revisited,” *Educational Psychology Review*, vol. 28, no. 4, p. 691–716, 2016.
- [112] G. A. Gorry and M. S. S. Morton, “A Framework for Management Information Systems,” *Sloan Management Review*, vol. 13, no. 1, pp. 55-70, 1971.
- [113] H. A. Simon, Administrative behavior: A study of decision-making processes in administrative organizations, Macmillan, 1947.
- [114] H. A. Simon, The New Science of Management Decision, Harper & Brothers, 1960.
- [115] F. Montagna and M. F. Norese, “A hybrid-approach to model design and development processes and the evaluation of innovation opportunities,” *International Journal of Production Research*, vol. 46, no. 21, p. 5969–5988, 2008.
- [116] G. Pahl, W. Beitz, J. Feldhusen and K.-H. Grote, Engineering design: A systematic approach, 3rd edition, London: Springer, 2007.
- [117] N. Cross, Design Thinking: Understanding How Designers Think and Work, Oxford: Berg, 2001.
- [118] G. F. Smith and G. J. Browne, “Conceptual Foundations of Design Problem Solving,” *Systems, Man and Cybernetics, IEEE Transactions on*, vol. 23, pp. 1209-1219, 1993.
- [119] J. Stempfle and P. Badke-Schaub, “Thinking in design teams - an analysis of team communication,” *Design Studies*, vol. 23, no. 5, pp. 473-496, 2002.
- [120] D. A. Schön, The reflective practitioner: How professionals think in action, New York: Basic Books, 1983.
- [121] A. Hatchuel and B. Weil, “C-K design theory: an advanced formulation,” *Research in Engineering Design*, vol. 19, pp. 181-192, 2009.
- [122] J. S. Gero, “Design prototypes: A knowledge representation schema for design,” *AI Magazine*, vol. 11, no. 4, pp. 7-95, 1990.
- [123] T. Brown, “Design Thinking,” *Harvard Business Review*, vol. 86, no. 6, pp. 84-92, 2008.

- [124] D. A. Norman, *The Design of Everyday Things: Revised and Expanded Edition*, Cambridge, MA: MIT Press, 2013.
- [125] M. F. Norese and A. Ostanello, *Decision aid process typologies and operational tools*, 1988.
- [126] A. Loi, "Artificial intelligence tools in support of product development," *Master's Thesis. Politecnico di Torino. Master's Thesis. Politecnico di Torino, Master Degree in Management Engineering. Supervisors: Prof. Francesca Montagna, Prof. Gaetano Cascini. July 2023 Session*, 2023.
- [127] G. S. Altshuller, *Creativity as an exact science: The theory of the solution of inventive problems*, New York: Gordon and Breach Science Publishers, 1984.
- [128] G. S. Altshuller, *The innovation algorithm: TRIZ, systematic innovation and technical creativity*, Worcester, MA: Technical Innovation Center, 1999.
- [129] F. Montagna, "Decision-aiding tools in innovative product development contexts," *AI & Society*, vol. 22, no. 1, pp. 63-86, 2011.
- [130] L. Zheng, L. Sun, Z. He and S. He, "Dynamic product competitive analysis based on online reviews," *Decision Support Systems*, vol. 183, p. 114268, 2024.
- [131] L. Aristodemou and F. Tietze, "The state-of-the-art on Intellectual Property Analytics (IPA): A literature review on artificial intelligence, machine learning and deep learning methods for analysing intellectual property (IP) data," *World Patent Information*, vol. 55, pp. 37-51, 2018.
- [132] J. Qayyum, H. A. Siddiqui, A. A. Prince, S. Ahmad and M. Raza, "Revolutionizing market insights through AI and data analytics: The next era of competitive intelligence," *The Critical Review of Social Sciences Studies*, vol. 3, no. 1, pp. 3285-3302, 2025.
- [133] O. H. Olayinka, "Data-driven customer segmentation and personalization strategies in modern business intelligence frameworks," *World Journal of Advanced Research and Reviews*, vol. 12, no. 3, pp. 711-726, 2021.
- [134] A. Sleimi, M. Ceci, N. Sannier, M. Sabetzadeh, L. Briand and J. Dann, "A Query System for Extracting Requirements-related Information from Legal Texts," in *Proceedings of the 27th IEEE International Requirements Engineering Conference*, Paris, France, 27–31 August 2019.
- [135] A. Kallunki, *Transforming early-stage innovation with generative AI: Case study of leveraging LLM agents for ideation and screening (Master's thesis)*, Aalto University, Industrial Engineering and Management, 2025.
- [136] Z. Wang, J. Zhang, R. Li and X. Guo, "Research on disruptive technology prediction methods based on BERT model and graph theory analysis," *Proceedings of the World Conference of AI-Powered Innovation and Inventive Design (IFIP Advances in Information and Communication Technology)*, vol. 735, pp. 106-130, 2025.
- [137] T. Gokhan, K. Wang, I. Gurevych and T. Briscoe, *RIRAG: Regulatory information retrieval and answer generation*, <https://arxiv.org/abs/2409.05677>, 2024.
- [138] T. H. Davenport, J. Parra-Moyano, K. Schmedders and S. Schulte, "Use GenAI to uncover new insights into your competitors," *Harvard Business Review*, 17 November 2023.
- [139] D. Kudryavtsev, *Bridging knowledge gaps: AI-enhanced techniques for identifying skills and competencies*, <https://urn.fi/URN:NBN:fi-fe2024081965484>.
- [140] J. Joung and H. Kim, "Interpretable machine learning-based approach for customer segmentation for new product development from online product reviews," *Expert Systems with Applications*, vol. 223, 2023.
- [141] H. Malik, A. Afthanorhan, N. A. Amirah and N. Fatema, "Machine learning approach for targeting and recommending a product for project management," *Mathematics*, vol. 9, no. 16, p. 1958, 2021.

- [142] Y. Lee, "Identifying Competitive Attributes Based on an Ensemble of Explainable Artificial Intelligence," *Business & Information Systems Engineering*, vol. 64, p. 407–419, 2022.
- [143] C. Sahin, I. Ar and B. Baki, *An integrated approach on new product development process with data mining: a case study on smartphone design*, 2025.
- [144] J. Choi, J. Yoon and C. Lee, "Early screening of potential breakthrough technologies with enhanced interpretability: A patent-specific hierarchical attention network model," *Computers & Industrial Engineering*, vol. 195, 2025.
- [145] F. Fotrousi and T. Tavantzis, "ReqGenie: GPT-Powered Conversational-AI for Requirements Elicitation," *Product-Focused Software Process Improvement. PROFES 2024. Lecture Notes in Computer Science*, vol. 15452, 2025.
- [146] C. Arora, J. Grundy and M. Abdelrazek, "Advancing Requirements Engineering through Generative AI: Assessing the Role of LLMs," 1 Nov. 2023. [Online]. Available: <https://arxiv.org/abs/2310.13976>.
- [147] J. Chick, "AI-driven competency gap analysis model for continuous professional development in STEM industries," *International Advanced Research Journal in Science, Engineering and Technology*, vol. 12, no. 8, 2025.
- [148] F. A. Csaszar, H. Ketkar and H. Kim, "Artificial intelligence and strategic decision-making: Evidence from entrepreneurs and investors," *Strategy Science*, vol. 9, no. 4, pp. 322–345, 2024.
- [149] Y. Qian, Y. Jiang, J. Shang, Y. Chai and Y. Liu, "Why some products compete and others don't: A competitive attribution model from customer perspective," *Decision Support Systems*, vol. 169, p. 113956, 2023.
- [150] Z. Wang, H.-R. Pan, J.-S. Li and S.-F. Niu, *Exploring product rendering generation design catering to multi-emotional needs through the Superiority Chart–Entropy Weight method and Stable Diffusion model*, 2024.
- [151] X. Kang and Z. Zhao, *Optimal design of ceramic form combining Stable Diffusion model and GRU-Attention*, 2025.
- [152] D. R. Bell and C. Pescher, "Can AI help in crowdsourcing? A theory-based model for idea screening in crowdsourcing contests," *Journal of Marketing Research*, vol. 60, no. 5, pp. 993–1022, 2023.
- [153] J. A. Gracy, S. Parthasarathy and T. Chandrakumar, "A Cross-Validated Comparative Analysis of Machine Learning Models for Strategic Decision- Making in Software Startups," in *2025 International Conference on Advances in Modern Age Technologies for Health and Engineering Science (AMATHE)*, Shivamogga, India, 2025.
- [154] A. Franz, *Using machine learning to predict the success of product development projects*, Master's thesis, FH JOANNEUM, Studiengang "Digital Entrepreneurship", 2023.
- [155] G. Soltani-Fesaghandis and A. Pooya, "Design of an artificial intelligence system for predicting success of new product development and selecting proper market-product strategy in the food industry," *International Food and Agribusiness Management Review*, vol. 21, no. 7, pp. 847–862, 2018.
- [156] C. Reyes, O. Knight and P. Stewart, "Agent-based simulation of competitive market dynamics for strategic business planning," *Journal of Innovation in Governance and Business Practices*, vol. 1, no. 1, 2025.
- [157] A. Smirnov, N. Shilov, A. Kashevnik, M. Petrov, S. Brugger and T. Ismaili, "Early-identification of human resource trends and innovations through web-scraping technology," *Proceedings of the 23rd International Conference on Enterprise Information Systems (ICEIS 2021)*, vol. 1, pp. 642–651, 2021.
- [158] L. Greif, S. Hauck, A. Kimmig and J. Ovtcharova, "A Knowledge Graph Framework to Support Life Cycle Assessment for Sustainable Decision-Making," *Applied Sciences*, vol. 15, no. 1, p. 175, 2025.

- [159] H. Akay and S.-G. Kim, “Extracting functional requirements from design documentation using machine learning,” *Procedia CIRP*, vol. 100, 2021.
- [160] T. Da Silva, “Extracting knowledge graphs from user stories using LangChain,” *Master’s thesis, Brandenburg University of Technology Cottbus–Senftenberg, Master in Artificial Intelligence*, 2025.
- [161] M. Habib, D. Graziotin and S. Wagner, “ReqBrain: Task-specific instruction tuning of large language models for AI-assisted requirements generation,” 23 May 2025. [Online]. Available: <https://arxiv.org/abs/2505.17632>.
- [162] D. Ganiuly and A. Smayl, “Intelligent NLP system for translating business requirements into formalized technical project specifications,” *International Journal of Science and Research Archive*, vol. 13, no. 2, p. 1388–1395, 2024.
- [163] F. Dalpiaz and M. Parente, “RE-SWOT: From User Feedback to Requirements via Competitor Analysis,” in *Proceedings of the 25th International Working Conference on Requirements Engineering: Foundation for Software Quality (REFSQ’19)*, 2019.
- [164] V. Sahadevan, R. Joshi, K. Borg, V. Singh, A. R. Singh, B. Muhammed, S. B. Beemaraj and A. Joshi, “Knowledge augmented generalizer specializer: A framework for early stage design exploration,” *Advanced Engineering Informatics*, vol. 65, 2025.
- [165] Y. Wang, D. Mo and M. Tseng, “Mapping customer needs to design parameters in the front end of product design by applying deep learning,” *Advanced Engineering Informatics*, vol. 38, pp. 184–195, 2018.
- [166] Y. Cheng, Y. Li, N. Zhang, L. Chen and J. Cao, “A knowledge graph-enabled multi-domain mapping approach supporting product rapid design: A case study of new energy vehicles,” *Advanced Engineering Informatics*, vol. 62, 2024.
- [167] Z. Zhai, B. Liu, H. Xu and P. Jia, “Clustering product features for opinion mining,” in *Proceedings of the Fourth ACM International Conference on Web Search and Data Mining (WSDM’11)*, Hong Kong, China, 9–12 February 2011.
- [168] N. Restrepo Torres, “Automatic Transformation of Natural Language Requirements to PLCopen XML Using Large Language Models (LLM),” *Master’s Thesis, School of Innovation Design and Engineering, Mälardalen University, Västerås, Sweden.*, 2025.
- [169] M. Molla, J. Ahmad and W. Kadir, “A Comparison of Transforming the User Stories and Functional Requirements into UML Use Case Diagram,” *International Journal of Innovative Computing*, vol. 14, no. 1, p. 29–36, 2024.
- [170] J. Han, S. Sarica, F. Shi and J. Luo, “Semantic networks for engineering design: State of the art and future directions,” *Journal of Mechanical Design*, vol. 142, no. 11, 2021.
- [171] Z. Zhao, L. Zhang, X. Gao, X. Lian, H. Lv and L. Shi, “Automated Generating Natural Language Requirements based on Domain Ontology,” 30 Nov. 2022. [Online]. Available: <https://arxiv.org/abs/2211.16716>.
- [172] S. Massoudi and M. Fuge, “Agentic Large Language Models for Conceptual Systems Engineering and Design,” in *Volume 3B: 51st Design Automation Conference (DAC)*, American Society of Mechanical Engineers, 2025.
- [173] Z. Wang, F.-W. Lo, Q. Chen, Y. Zhang, C. Lin, X. Chen, Z. Yu, A. Thompson, E. Yeatman and B. Lo, *An LLM-enabled Multi-Agent Autonomous Mechatronics Design Framework*, 2025.
- [174] R. Izhar, S. Bhatti and S. Alharthi, “An NLP-Enabled Approach to Semantic Grouping for Improved Requirements Modularity and Traceability,” *International Journal of Advanced Computer Science and Applications (IJACSA)*, vol. 16, no. 2, p. 504, 2025.

- [175] P. Livotov and Mas'udah, "Challenges in Inventive Design Problem Solving with Generative AI: Interactive Problem Definition, Multi-directional Prompting, and Concept Development," in *Proceedings of the TRIZ Future Conference 2024 (TFC 2024)*, IFIP Advances in Information and Communication Technology, vol. 735, D. Cavallucci, P. Livotov, & S. Brad, 2025, p. 205–226.
- [176] A. Koyamparambath, N. Adibi, C. Szablewski, S. Adibi and G. Sonnemann, "Implementing Artificial Intelligence Techniques to Predict Environmental Impacts: Case of Construction Products," *Sustainability*, vol. 14, no. 6, p. 3699, 2022.
- [177] M.-S. Haddad and A. Seibel, "Functional decomposition of technical products based on large language models and Monte Carlo tree search," in *Proceedings of the Design Society, Volume 5: ICED25*, Cambridge University Press, 2025.
- [178] L. Chen, H. Zuo, Z. Cai, Y. Yin, Y. Zhang, L. Sun and P. Childs, "Toward controllable generative design: A conceptual design generation approach leveraging the Function–Behavior–Structure ontology and large language models," *Journal of Mechanical Design*, vol. 146, no. 12, p. 121401, 2024.
- [179] P. Rosenthal, N. Demke, F. Mantwill and O. Niggemann, "Plan-Based Derivation of General Functional Structures in Product Design," 9 Feb. 2022. [Online]. Available: <https://arxiv.org/abs/2302.04600>.
- [180] H. Akay and S.-G. Kim, "Measuring functional independence in design with deep-learning language representation models," *Procedia CIRP*, vol. 91, p. 528–533, 2020.
- [181] M. Esposito, X. Li, S. Moreschini, N. Ahmad, T. Cerny, K. Vaidhyanathan, V. Lenarduzzi and D. Taibi, "Generative AI for software architecture: Applications, challenges, and future directions," *Journal of Systems and Software*, vol. 231, 2026.
- [182] J. Göpfert, J. Weinand, P. Kuckertz and D. Stolten, "Opportunities for large language models and discourse in engineering design," *Advanced Engineering Informatics*, vol. 60, p. 101970, 2024.
- [183] S. Jiang, W. Li, Y. Qian, Y. Zhang and J. Luo, *AutoTRIZ: Automating engineering innovation with TRIZ and large language models*, 2025.
- [184] L. Chen, Y. Song, S. Ding, L. Sun, P. Childs and H. Zuo, "TRIZ-GPT: An LLM-augmented method for problem-solving," in *Proceedings of the ASME 2024 International Design Engineering Technical Conference and Computers and Information in Engineering Conference*, Washington, D.C., 25-28 August 2024.
- [185] Z. Mo, L. Gong, F. Ye, T. Fu, D. Zhu, H. Cui and J. Xie, "Knowledge and engineering parameter mapping technology supporting product conceptual design," *Procedia CIRP*, vol. 109, p. 368–374, 2022.
- [186] G. Paliwal, A. Donvir, P. Gujar and S. Panyam, "Accelerating Time-to-Market: The Role of Generative AI in Product Development," in *Proceedings of the 2024 IEEE Colombian Conference on Communications and Computing (COLCOM)*, 2024.
- [187] L. Chen, Q. Jing, Y. Tsang, Q. Wang, L. Sun and J. Luo, "DesignFusion: Integrating generative models for conceptual design enrichment," *Journal of Mechanical Design*, vol. 146, no. 11, p. 111703, 2024.
- [188] L. Chen, Z. Cai, W. Cheang, Q. Long, L. Sun, P. Childs and H. Zuo, "AskNatureGPT: an LLM-driven concept generation method based on bio-inspired design knowledge," *Journal of Engineering Design*, vol. 37, no. 1, p. 238–272, 2025.
- [189] C. Picard, K. Edwards, A. Doris, B. Man, G. Giannone, M. Alam and F. Ahmed, "From concept to manufacturing: evaluating vision-language models for engineering design," *Artificial Intelligence Review*, vol. 58, 2025.
- [190] Mas'udah, P. Livotov and B. Kokoschko, "Harnessing Generative AI for Sustainable Innovation: A Comparative Study of Prompting Techniques and Integration with Nature-Inspired Principles," in *World*

Conference of AI-Powered Innovation and Inventive Design. TFC 2024. IFIP Advances in Information and Communication Technology, vol 735, D. Cavallucci, S. Brad and P. Livotov, 2025.

- [191] S. Brad, V.-D. Bartoş, E. Brad and C.-V. Trifan, “Neuro-Symbolic AI-Driven Inventive Design of a Benzoic Acid Extraction Installation from Styra Resin,” *World Conference of AI-Powered Innovation and Inventive Design (TFC 2024)*, pp. 66-87, 2024.
- [192] Z. Huang, X. Guo, Y. Liu, W. Zhao and K. Zhang, “A smart conflict resolution model using multi-layer knowledge graph for conceptual design,” *Advanced Engineering Informatics*, vol. 55, 2023.
- [193] V. Silva-Rodríguez, S. Nava-Muñoz, L. Castro, F. Martínez-Pérez, H. Pérez-González and F. Torres-Reyes, “Classifying design-level requirements using machine learning for a recommender of interaction design patterns,” *IET Software*, vol. 14, no. 6, pp. 755-764, 2020.
- [194] J. Jia, Y. Zhang and M. Saad, “An approach to capturing and reusing tacit design knowledge using relational learning for knowledge graphs,” *Advanced Engineering Informatics*, vol. 52, p. 101550, 2022.
- [195] A. Nüßgen, R. Degen, M. Irmer, F. Richter, C. Boström and M. Ruschitzka, “Leveraging robust artificial intelligence for mechatronic product development — A literature review,” *International Journal of Intelligence Science*, vol. 14, 2024.
- [196] X. Zhang, C. Chai, S. Ding, Y. Yin, R. Cai, P. Hansen, G. Cascini and H. Fan, “A systematic review of generative artificial intelligence in product conceptual design: linking external design activities and internal cognitive needs,” *Journal of Engineering Design*, 2024.
- [197] S. G. Zafiris, *Generative system design in car powertrain architecture optimization (Master’s thesis)*, Aalto University, School of Engineering, 2025.
- [198] C. Subash, K. Santhi, Y. Abid, S. Sunil, C. S. Buvanashankar and T. Chellatamilan, “The artistry unleashed: Exploring quadrisociation for boundless creativity with the power of generative AI,” *Discover Applied Sciences*, vol. 7, p. 759, 2025.
- [199] M. Ataci, H. Cheong, J. Jun, J. Matejka, A. Tessier and G. Fitzmaurice, “Transformer-based interfaces for mechanical assembly design: A gear train case study,” 11 April 2025. [Online]. Available: <https://arxiv.org/abs/2504.08633>.
- [200] A. Pradas Gomez, P. Krus, M. Panarotto and O. Isaksson, “Large language models in complex system design,” *Proceedings of the Design Society*, vol. 4, pp. 2197-2206, 2024.
- [201] H. R. Fazeli and Q. Peng, “Product concept development and evaluation using multiagent reinforcement learning,” *IEEE Transactions on Engineering Management*, vol. 71, pp. 8701-8716, 2024.
- [202] X. Kang, Y. Luo, Q. Zhu and C. Wu, “Research on Kansei design of electric scooter integrating CNN-GRU-Attention and biologically inspired design,” *Expert Systems with Applications*, vol. 266, p. 126121, 2025.
- [203] <https://lovable.dev/enterprise-landing>.
- [204] V. Balmer, S. V. Kuhn, R. Bischof, L. Salamanca, W. Kaufmann, F. Perez-Cruz and M. A. Kraus, “Design Space Exploration and Explanation via Conditional Variational Autoencoders in Meta-Model-Based Conceptual Design of Pedestrian Bridges,” *Automation in Construction*, vol. 163, 2024.
- [205] A. Nichol, H. Jun, P. Dhariwal, P. Mishkin and M. Chen, *Point-E: A system for generating 3D point clouds from complex prompts*, <https://arxiv.org/abs/2212.08751>, 2022.
- [206] S. Yoo, S. Lee, S. Kim, K. H. Hwang, J. H. Park and N. Kang, “Integrating deep learning into CAD/CAE system: generative design and evaluation of 3D conceptual wheel,” *Structural and Multidisciplinary Optimization*, vol. 64, no. 4, 2021.

- [207] E. Dostatni, D. Mikołajewski, J. Dorożyński and I. Rojek, “Ecological Design with the Use of Selected Inventive Methods including AI-Based,” *Applied Sciences*, vol. 12, no. 19, p. 9577, 2022.
- [208] H. Jiang and F. Sabetzadeh, “Defining the Settings of Product Attributes for Product Design Using an Innovative NSGA-II,” in *Proceedings of the 2022 International Conference on Frontiers of Artificial Intelligence and Machine Learning (FAIML)*, Hangzhou, China, 2022.
- [209] Y. Ao, J. Lv, Q. Xie and Z. Zhang, “Multi-objective image optimization of product appearance based on improved NSGA-II,” *CMC - Computers, Materials & Continua*, vol. 75, no. 1, pp. 1-15, 2023.
- [210] H. Karali, G. Inalhan and A. Tsourdos, “Advanced UAV Design Optimization Through Deep Learning-Based Surrogate Models,” *Aerospace*, vol. 11, no. 8, p. 669, 2024.
- [211] X. Jin, S. Yan, Q. Wang, S. Deng, Y. Jiang and S. Zhao, *A closed-loop multi-agent framework for aerodynamics-aware automotive styling design*, <https://arxiv.org/abs/2508.03370>, 2025.
- [212] B. Song, S. Miller and F. Ahmed, “Attention-enhanced multimodal learning for conceptual design evaluations,” *Journal of Mechanical Design*, vol. 145, no. 4, 2023.
- [213] J. Salla, T. de Almeida and D. Silva, “Integrating machine learning with life cycle assessment: a comprehensive review and guide for predicting environmental impacts. (2025).,” *The International Journal of Life Cycle Assessment*, 2025.
- [214] L. Jing, C. Tian, S. He, D. Feng, S. Jiang and C. Lu, “Data-driven implicit design preference prediction model for product concept evaluation via BP neural network and EEG,” *Advanced Engineering Informatics*, vol. 58, 2023.
- [215] B. Xing, H. Cao, L. Shi, H. Si and L. Zhao, “AI-driven user aesthetics preference prediction for UI layouts via deep convolutional neural networks,” *Cognitive Computation and Systems*, vol. 4, no. 2, pp. 83-92, 2022.
- [216] L. W. van Dalen, *Predicting success of new product launches in the Dutch dairy market using machine learning methods*, Vrije Universiteit Amsterdam, Master Thesis in Business Analytics, 2024.
- [217] Z. Jiang, Q. Tang, Z. Wang, Y. Liu and H.-Z. Huang, “Generative reliability-based design optimization using in-context learning capabilities of large language models,” *Journal of Mechanical Design*, vol. 148, no. 3, 2025.
- [218] B. Romera-Paredes, M. Barekatin, A. Novikov et al., “Mathematical discoveries from program search with large language models,” *Nature*, vol. 625, p. 468–475, 2024.
- [219] M. Anuar, M. Sahid and N. Zainal, “Comparative Analysis of Test Case Prioritization Using Ant Colony Optimization Algorithm and Genetic Algorithm,” *Journal of Software and Computational Design Methods*, vol. 4, no. 2, 2023.
- [220] U. Casado, F. Altuna and L. Miccio, “Towards Sustainable Material Design: A Comparative Analysis of Latent Space Representations in AI Models,” *Sustainability*, vol. 16, no. 23, 2024.
- [221] A. Roy, R. Devanathan, M. Nartu and V. V. Joshi, “Autonomous alloy composition optimization using molecular dynamics guided by a large language model,” *Scripta Materialia*, vol. 272, 2026.
- [222] R. Mercado, E. Bjerrum and O. Engkvist, “Exploring Graph Traversal Algorithms in Graph-Based Molecular Generation,” *Journal of Chemical Information and Modeling*, vol. 62, no. 9, 2022.
- [223] J. Zhang, R. Mercado, O. Engkvist and H. Chen, “Comparative Study of Deep Generative Models on Chemical Space Coverage,” *Journal of Chemical Information and Modeling*, vol. 61, no. 6, 2021.
- [224] <https://www.autodesk.com/design-make/articles/automotive-design%C2%A0>.
- [225] <https://adsknews.autodesk.com/en/news/gm-autodesk-using-generative-design-vehicles-future/>.

- [226] <https://www.ibm.com/it-it/case-studies/ibm-consulting-watsonx-code-assistant%20>.
- [227] https://www.redhat.com/track/_pdfcdn/assets/10330/contents/645398/76219dc3-78d5-477b-91f2-06f28823064e.pdf.
- [228] <https://blog.jetbrains.com/idea/2023/06/ai-assistant-in-jetbrains-ides/%C2%A0>.
- [229] <https://iot-analytics.com/top-enterprise-generative-ai-applications/>.
- [230] <https://www.research.autodesk.com/blog/general-electric-collaboration-targets-jet-engine-efficiency-with-generative-design>.
- [231] <https://upcommons.upc.edu/server/api/core/bitstreams/ebd4c0d0-d276-48be-af26-e2ae81240418/content>.
- [232] <https://odr.chalmers.se/server/api/core/bitstreams/6e4ff5aa-8912-4ea9-89b8-20db441f72cd/content>.
- [233] <https://adsknews.autodesk.com/en>.
- [234] <https://www.getleo.ai/blog/leo-ai-raises-9-7m-to-build-the-world-s-first-ai-for-mechanical-engineering>.
- [235] <https://www.getleo.ai/about>.
- [236] <https://par.nsf.gov/servlets/purl/10592280>.
- [237] <https://blogs.nvidia.com/blog/generative-ai-proteins-evozyne/%20>.
- [238] <https://iot-analytics.com/top-enterprise-generative-ai-application>.
- [239] <https://flechetech.pages.dev>.
- [240] https://www.apriori.com/wp-content/uploads/2024/08/Eaton_and_aPriori-Case-Study-V3.pdf.
- [241] <https://openai.com/index/moderna/%C2%A0%20>.
- [242] <https://www.biopharmadive.com/news/moderna-openai-gpt-generative-ai-biotech-dose-id/714140>.
- [243] <https://www.pg.co.uk/blogs/basecamp-research-and-pg-to-design-high-performance-enzymes-with-ai/>.
- [244] https://www.nestle.com/about/research-development/news/ibm-ai-powered-sustainable-packaging?&__cf_chl_tk=UErIFhjraZ7HIh8pj5gVegr8PuHjgPafUKPAOA6Fmagg-1758554344-1.0.1.1-ILW.zkdQnk3CuCO0ShGqS3PN5n9TknI3w4LrDzR.UWU.
- [245] <https://www.nestleusa.com/stories/unlocking-new-opportunities-gen-ai>.
- [246] <https://research.ibm.com/publications/regression-transformer-concurrent-property-prediction-and-conditional-molecular-generation>.
- [247] <https://www.moodify.ai/reformulation/>.
- [248] <https://www.prnewswire.com/news-releases/procter--gambles-fragrance-development-group-partners-with-moodify-ai--based-software-solution-for-enhanced-fragrance-design-301945492.html>.
- [249] <https://www.3ds.com/assets/invest/2025-04/ht-generative-mbse-strategy-for-next-gen-electronics-whitepaper-en.pdf>.
- [250] <https://aws.amazon.com/it/solutions/case-studies/ferrari-generative-ai-case-study>.
- [251] <https://www.autodesk.com/autodesk-university/class/How-Generative-AI-Helped-Final-Aim-to-Design-a-Unique-Yamaha-EV-for-Farming-Terrain-2024#handout>.
- [252] <https://it.newsroom.ibm.com/ibm-e-loreal-cosmetici-sostenibili>.
- [253] <https://www.linkedin.com/pulse/new-oreos-now-designed-ai-nagesh-nama-juoue/>.

- [254] <https://www.wsj.com/articles/oreo-owner-mondelez-taps-ai-to-tweak-its-classic-snacks-6fa4c4cd>.
- [255] <https://smartdev.com/ai-use-cases-in-food-industry>.
- [256] <https://sloanreview.mit.edu/article/the-genai-focus-shifts-to-innovation-at-colgate-palmolive>.
- [257] <https://news.microsoft.com/source/2024/04/26/the-estee-lauder-companies-and-microsoft-increase-collaboration-to-power-prestige-beauty-with-generative-ai/%C2%A0>.
- [258] <https://www.microsoft.com/en/customers/story/23488-the-estee-lauder-companies-microsoft-copilot-studio>.
- [259] <https://cloud.google.com/blog/products/ai-machine-learning/gemini-2-5-flash-image-on-vertex-ai>.
- [260] <https://www.figma.com/blog/introducing-figma-ai>.
- [261] <https://www.figma.com/blog/introducing-figma-make>.
- [262] <https://www.autodesk.com/design-make/articles/kia-generative-ai-for-automotive-design%20%20>.
- [263] <https://blogs.autodesk.com/design-studio/2023/11/02/welcome-to-blankai>.
- [264] <https://www.research.autodesk.com/projects/project-bernini>.
- [265] <https://www.creativedock.com/blog/we-have-boosted-product-development-with-genai%20>.
- [266] https://uploadssl.webflow.com/65c21f52888f67ebdf669202/6628fbe8e781633f156746e6_Creative%20Dock%20AI%20Transformation%20Case%20Study.pdf.
- [267] <https://about.nike.com/en/magazine/nike-design-athlete-imagined-revolution>.
- [268] <https://www.ikea.com/global/en/stories/design/to-nyttillverkad-and-beyond-ikea-space10-and-designers-of-tomorrow-explore-future-with-ai-230420>.
- [269] <https://www.ikea.com/us/en/newsroom/corporate-news/ikea-launches-new-ai-powered-digital-experience-empowering-customers-to-create-lifelike-room-designs-pub58c94890>.
- [270] <https://www.ingka.com/newsroom/ikea-launches-new-ai-powered-assistant-in-openai-gpt-store>.
- [271] <https://www.notion.com/product/ai/use-cases?page=0>.
- [272] <https://www.notion.com/help/guides/how-product-teams-boost-productivity-and-spark-new-ideas-with-notion-ai>.
- [273] <https://www.notion.com/blog/notion-ai-for-work-unlocking-ai-driven-product-development>.
- [274] <https://stackspot.com/en/blog/backlog-refinement-case>.
- [275] <https://adsknews.autodesk.com/en/news/autodesk-volkswagen-generative-design-electric-showcase-vehicle>.
- [276] <https://www.autodesk.com/design-make/articles/decaathlon-diving-fin%20>.
- [277] <https://www.autodesk.com/products/fusion-360/blog/machine-learning-in-design-manufacturing/>.
- [278] <https://www.autodesk.com/products/fusion-360/blog/philippe-starck-designed-production-chair-generative-design-ai/#:~:text=Fuel%20Innovation%2C%20Cut%20Costs&text=A%20look%20back%20at%20how,AI%20in%20collaboration%20with%20humans>.
- [279] <https://www.autodesk.com/autodesk-university/class/Generative-Design-More-Than-a-Buzzword-2023#handout>.

Appendici

Appendice A




Figura A.1: Applicazione del metodo Snowballing sul database di Google Scholar.




Figura A.2: Applicazione del metodo PRISMA sul database di Scopus.

Appendice B

La seguente query seleziona articoli dal 1980 al 2025 su paradigmi, tecniche e modelli di intelligenza artificiale, con lo scopo di esplorare il panorama globale dell'AI.

TITLE-ABS-KEY (("artificial intelligence" OR "symbolic AI" OR "subsymbolic AI" OR "probabilistic AI" OR "evolutionary computation" OR "evolutionary algorithm" OR "genetic algorithm*" OR "machine learning" OR "deep learning" OR "reinforcement learning" OR "generative AI" OR "foundation model*" OR "large language model*" OR "transformer model*" OR "expert system*" OR "knowledge-based system*" OR "rule-based system*" OR "fuzzy logic" OR "neural network*" OR "connectionist" OR "cognitive architecture" OR "intelligent agent*" OR "multi-agent system*" OR "reasoning system*" OR "inference engine*" OR "representation learning" OR "knowledge representation" OR "computational intelligence" OR "cognitive computing" OR "learning paradigm" OR "AI paradigm")) AND PUBYEAR > 1979 AND PUBYEAR < 2026*

Appendice C

Apprendimento	Algoritmi principali
Supervisionato (classificazione e regressione)	Linear Classifier, Linear Regression, Logistic Regression (e altri GLM), Discriminant Analysis, Support Vector Machines (SVM), Support Vector Regression (SVR), Gaussian Process Regression (GPR), Naive Bayes, Decision Tree, Random Forest, Ensemble Methods, K-Nearest Neighbor (KNN), Artificial Neural Network (ANN), Multilayer Perceptron
Non supervisionato (clustering e associazione)	PCA, K-Means, Fuzzy K-Means, Hierarchical Clustering, Artificial Neural Networks (ANN), Hidden Markov Models, Gaussian Mixture Models
Semi-supervisionato (classificazione e clustering)	uClassify, GATE
Apprendimento per rinforzo (controllo)	Monte Carlo, Temporal Difference Methods, SARSA (State–Action–Reward–State–Action), Q-Learning, Direct Policy Search, Simulated Annealing, Estimated Value Functions

Tabella C.1: Classificazione modelli e algoritmi di ML in base alla modalità di apprendimento, rielaborazione delle rappresentazioni schematiche presenti nelle fonti: [27], [33], [35].

Appendice D

Paradigma di AI	Tecniche applicate ai task	Attività specifiche supportate
ML trad. (non supervisionato)	K-means, gerarchico (Clustering), PCA (riduzione dimensionale)	Segmentazione esplorativa di mercati, utenti, tecnologie e competitor; individuazione di pattern e strutture latenti; definizione preliminare delle dimensioni rilevanti
ML trad. (supervisionato)	Random Forest, SVM, Boosting, KNN, MLP (Classificazione e regressione)	Classificazione e prioritizzazione dei bisogni; scoring e screening preliminare di idee e alternative strategiche; stima di probabilità di successo, rischio e fattibilità
DL	LSTM, GRU, Temporal CNN, Transformer temporali, Autoencoder	Forecasting di trend di mercato, domanda e performance; change detection; individuazione di evoluzioni tecnologiche e competitive
	CNN	Estrazione automatica di feature di prodotto e competitor; embedding e classificazione; analisi della differenziazione competitiva e supporto al posizionamento strategico
ML/DL	NLP, Information retrieval, Natural Language Inference, classificazione supervisionata di testi	Topic modeling, sentiment analysis, feature extraction da testi, word embedding; analisi dei bisogni di mercato e della soddisfazione del cliente; estrazione di attributi di prodotto e segnali competitivi da recensioni e testi di mercato; identificazione e sintesi di vincoli regolatori; estrazione di obblighi normativi; supporto alla compliance e alla definizione dei vincoli progettuali
DL gen.	LLM	Conduzione di interviste esplorative; definizione di bisogni, personas e segmenti; generazione di idee, strategie e scenari; valutazione qualitativa delle alternative
	LLM + RAG: integrazione di fonti contestuali nei contenuti generati	Organizzazione e strutturazione delle informazioni strategiche; analisi di competitor e stakeholder; supporto a framework strategici (SWOT, 5 forze di Porter)
AI agentiva	LLM agent-based	Coordinamento di attività analitiche eterogenee; sviluppo, filtraggio e raffinamento iterativo di idee strategiche; memoria contestuale; controllo iterativo
AI simbolica / neuro-simbolica	Knowledge graph, ontologie leggere, rule-based systems, ANFIS	Formalizzazione delle relazioni tra competenze, attori e bisogni; supporto decisionale interpretabile; valutazione strategica basata su regole e indicatori
Speech processing	Transformer e Conformer	Trascrizione automatica di interviste, focus group e brainstorming; supporto alla raccolta di informazioni
Simulazione e modelli ibridi	Agent-Based Modeling con Q-learning, Monte Carlo	Simulazione di scenari competitivi; analisi “what-if”; valutazione di rischi, equilibri di mercato e impatti strategici
Visual analytics + ML trad.	Visualizzazione avanzata integrata con ML	Esplorazione interattiva dei dati; comprensione e comunicazione dei pattern; supporto alla validazione delle evidenze analitiche

Tabella D.1: Sintesi della mappatura tra tecniche di intelligenza artificiale e delle attività di planning strategico supportate, organizzata per paradigmi di AI.

Paradig. di AI	Tecniche applicate ai task	Attività specifiche supportate
AI Simb.	Ontologie leggere, knowledge graph, Semantic Web (RDF, SPARQL)	Rappresentazione esplicita della conoscenza di dominio in un'ontologia definita; formalizzazione delle entità, relazioni e vincoli del dominio in forma di grafo; strutturazione esplicita dei requisiti in una forma di conoscenza interrogabile (es. query su vincoli legali), utile per la validazione delle soluzioni progettuali.
	Partial Order Planning (POP), Planning Algorith.	Formalizzazione delle funzioni come azioni in un algoritmo di pianificazione; generazione della sequenza di funzioni per raggiungere un obiettivo di progettazione.
DL	Bi-LSTM, CNN, BERT, NLP	Estrazione semantica di informazioni relative ai requisiti da testi destrutturati: stakeholders, azioni, entità coinvolte, benefici attesi da user stories (relazioni formalizzate poi in knowledge graph e/o diagrammi dei casi d'uso), keywords (es. customer needs), contesto prima e dopo ogni parola (Bi-LSTM), attributi chiave del prodotto da recensioni; conversione requisiti e parametri di progettazione in vettori per calcolare indipendenza funzionale e il coupling tra i parametri
	GRU, meccanismo di Attention	Associazione tra preferenze emotive dei consumatori e le forme della superficie dei prodotti
DL gen.	LLM, LLM fine-tuned tramite instruction tuning	Conduzione di interviste contestualizzate; strutturazione delle informazioni raccolte dalle interviste in definizione del problema; profilazione stakeholders; suggerimento requisiti a partire dalle informazioni ricavate con le interviste; generazione requisiti conformi alla norma e ai vincoli del dominio ingegneristico a partire da prompt indicativi (LLM fine-tuned); stima dei dati ambientali mancanti nel ciclo di vita di un prodotto inferendo valori plausibili da pattern appresi da corpora di conoscenza nel settore; decomposizione funzionale; rappresentazione gerarchica delle funzioni, suggerimento alternative FBS.
DL/ML	NLP, DTM (Dynamic Topic Model)	Identificazione delle caratteristiche di prodotto dalle recensioni per tracciarne l'evoluzione nel tempo; sentiment analysis (valutazione positiva/negativa) sulle caratteristiche dei prodotti, topic modeling
	Tecniche di XAI	Esplicitazione e spiegabilità dei task svolti dai modelli black box
AI neuro-simb.	NLP, gen. NLP, vincoli determinist.	Generazione di requisiti software in linguaggio naturale sottoposti a controllo di vincoli sintattici per garantire formato standard
ML trad. (non superv)	K-means (clustering)	Clustering dei prodotti competitor (in base a qualità, prezzo funzionalità) per analisi preliminare del posizionamento
ML trad. (superv.)	Random Forest, Naïve Bayes, Gradient Boosting (classificazione)	Associazione delle opinioni alle caratteristiche di prodotto creando una mappatura, raggruppamento le caratteristiche, associazione dei customer needs a classi di design parameters, attribuzione livello di competitività ai prodotti
	Regressione logistica	Calcolo dei punteggi di importanza degli attributi di prodotto presenti nelle recensioni considerati come punti di differenziazione competitiva
AI Agentiv.	Sistemi multi-agente	1. Extractor (estrae e struttura requisiti), il Supervisor (coordina il flusso di lavoro), il Generator (propone design e trade-off), il Coder (sviluppa modelli numerici in Python) e il Reflector (fornisce critiche e miglioramenti). Gli LLM sono usati per decomporre funzioni, estrarre requisiti e generare modelli numerici. 2. L'agente di pianificazione traduce i requisiti in obiettivi di progettazione realizzabili, guida gli agenti specializzati (meccanica, elettronica, software) gestendo i feedback umani attraverso ristrutturazione iterativa del problema di progettazione.
Visual Analytics + ML trad.	Tableau, PCA, Clustering	Visualizzazione dei dati risultanti dalla sentiment analysis riguardanti le opinioni sulle caratteristiche di prodotto, analisi statistica per rendere i dati interpretabili, supporto nella creazione di mappe di posizionamento competitivo

Tabella D.2: Sintesi della mappatura tra tecniche di intelligenza artificiale e delle attività di Problem Definition&Structuring supportate, organizzata per paradigmi di AI.

Paradigmi di AI	Tecniche applicate ai task	Attività specifiche supportate
DL gen.	LLM, LLM+RAG, MLLM, Diffusion Models, GAN, VAE, modelli text-to-text (task NLP) / text-to-image / image-to-image	Esplicitazione e riformulazione di sottoproblemi e contraddizioni; costruzione iterativa del Network of Problems (NOP); generazione di mappe concettuali da brainstorming; generazione di descrizioni concettuali, immagini, schizzi e geometrie preliminari guidate dai requisiti; supporto al brainstorming creativo; sintesi e reporting; question answering su conoscenza interna/esterna; facilitazione del confronto interdisciplinare e riduzione delle ambiguità comunicative
DL	BERT, NLP, s-BERT, BiLSTM, Self-Attention, Word2Vec	Estrazione di requisiti, funzioni, parametri e concetti da testi non strutturati (feedback clienti, brevetti, documenti tecnici); associazione semantica tra requisiti funzionali e parametri di progetto; individuazione di similarità semantica tra problemi e soluzioni esistenti
AI simb.	Knowledge Graph, ontologie di dominio, regole di mapping, sistemi rule-based	Formalizzazione esplicita di concetti e relazioni (CR–FR–DP); strutturazione della conoscenza progettuale; supporto all’interpretazione, validazione e spiegabilità delle soluzioni generate; applicazione formale di TRIZ e gestione delle contraddizioni
AI Neuro-simb.	Pipeline ibride LLM + moduli simbolici, KG + ML	Integrazione tra comprensione linguistica e ragionamento strutturato per applicazione di framework TRIZ e FBS; mappatura dei problemi su principi solutivi (es. TRIZ); contestualizzazione dei principi rispetto al problema specifico mantenendo vincoli espliciti
ML trad. (supervisionato)	SVM, sistemi di classificazione e ranking	Classificazione di requisiti, brevetti o problemi in design pattern o principi solutivi noti; supporto allo screening e alla prioritarizzazione di soluzioni e alternative concettuali
ML su grafi/ Relational learning	Tensor factorization (es. RESCAL), semantic learning	Inferenza di relazioni mancanti nel grafo: relazioni problema–soluzione, connessioni latenti e conoscenza tacita; assegna score di probabilità a ciascuna possibile relazione problema–soluzione
AI agentiva (LLM-based)	Sistemi multi-agente	Identificazione dei trade-off tra requisiti e suggerimenti di soluzioni; generazione di soluzioni specifiche per sottoproblemi disciplinari (detailed design); gestione iterativa e contestuale del processo progettuale; integrazione del feedback umano
AI evolutiva, DL gen	Algoritmi genetici, NSGA-II, topology optimization, gradient based optimization, reinforcement learning, VAE, GAN/Diffusion models	Esplorazione di idee di concetti guidati da vincoli tecnici; supporto all’idea generation in contesti ingegneristici, training su progetti passati per apprendere relazioni implicite forma–funzione–performance; generazione iterativa di alternative progettuali progressivamente migliorate.

Tabella D.3: Sintesi della mappatura tra tecniche di intelligenza artificiale e delle attività di Idea Generation supportate, organizzata per paradigmi di AI.

Paradigma AI	Tecniche applicate ai task	Attività specifiche supportate
DL gen.	LLM, MLLM, VAE, GAN, Diffusion Models (condizionali), Graph VAE	Combinazione guidata di idee, concetti e feature; generazione di configurazioni coerenti con requisiti esplicitati tramite prompt; fusione visiva e morfologica di soluzioni; esplorazione controllata di varianti concettuali e architetture
	LLM con fine-tuning su relazioni strutturali, reasoning testuale	Combinazione sequenziale di moduli semplici; confronto argomentato e valutazione qualitativa delle alternative
Graph-based generative models	Autoregressive graph models, grammar-based graph models, Graph VAE	Combinazione di moduli e sottosistemi in architetture coerenti; generazione di configurazioni compatibili a livello strutturale e funzionale; esplorazione di alternative architetture rispettando vincoli di interfaccia
AI agentiva	Sistemi multi-agente, Deep Multi-Agent Reinforcement Learning	Decomposizione problema complesso in piccoli problemi di progettazione aggredibili da agenti specializzati; decision making sequenziale guidato da conoscenza ingegneristica per esplorare combinazioni; coordinamento tra discipline (meccanica, elettronica, software) nelle configurazioni complessive e idea/component combination integrata nella progettazione specifica di ciascun agente; integrazione del feedback umano
AI evolutiva, DL gen	Algoritmi genetici, NSGA-II, topology optimization, gradient based optimization, reinforcement learning, VAE, GAN/Diffusion models	Combinazione vincolata di forme, parametri e soluzioni elementari; generazione iterativa di configurazioni migliorative; esplorazione dello spazio delle soluzioni nel rispetto di obiettivi e vincoli ingegneristici
ML (superv.) /shallow DL	Random Forest, Gradient Boosting, SVR, MLP	Scoring, ranking e prioritizzazione delle soluzioni generate; stima di KPI proxy (costo, rischio, complessità, impatto ambientale); supporto alla selezione preliminare nel conceptual design
DL/ML	ML supervisionato, MLP profonde, CNN, GNN, RL come surrogate models	Valutazione intermedia delle combinazioni tramite surrogate models di simulazioni (es. FEM) per configurazioni ingegneristiche
AI simbolica	Rule-based systems, compliance checking	Verifica di conformità a regole, vincoli e requisiti esplicitati; validazione strutturale e normativa delle soluzioni combinate

Tabella D.4: Sintesi della mappatura tra tecniche di intelligenza artificiale e delle attività di Idea/Component Combination supportate, organizzata per paradigmi di AI.

Paradigma AI	Tecniche applicate ai task	Attività specifiche supportate
DL gen.	MLLM, GAN, Diffusion Models, VAE, modelli generativi condizionali (text-to-image, image-to-image, editing di immagini, image-to-3D)	Traduzione di caratteristiche funzionali e strutturali in assetto visivo, modellazione delle forme e delle ultime modifiche per consentire al concept di risultare conforme ai requisiti;
	LLM fine-tuned, altri modelli DL generativo	Prototipazione virtuale, generazione di mock-up: traduzione comandi testuali in prototipi virtuali (es. interfaccia interattiva applicazioni web)
DL	CNN-GRU-Attention	Mappatura non lineare tra emozioni e forme; valutazione dei concept con obiettivo di massimizzazione del valore Kansei
ML trad (supervisionato)	RF, GB, Shallow MLP	Feature recommendation, Constraint suggestion nella modellazione CAD
AI simb	Sistemi rule-based	Constraint checking
Prototipazione rapida fisica	3D printing, additive manufacturing	Modellazione fisica dei concept risultati da generative design

Tabella D.5: Sintesi della mappatura tra tecniche di intelligenza artificiale e delle attività di Concept Generation supportate, organizzata per paradigmi di AI.

Paradigma AI	Tecniche applicate ai task	Attività specifiche supportate
DL gen.	LLM	Analisi qualitativa dei risultati, suggerimenti per modifiche
ML trad./ DL	ML superv., MLP, DNN (quando relazioni non lineari), logica fuzzy per gestire variabili incerte AI data-driven guidata dalla fisica (Physics-informed feature engineering)	Valutazione delle soluzioni con metriche e KPI tramite modelli surrogati che sostituiscono analisi complete lunghe e costose; integrazione vincoli fisici negli input delle reti per rendere le valutazioni dei modelli black box maggiormente spiegabili
Topology Optimizat., AI evol., ottimizz. Num. (+DL gen, ML trad)	NSGA-II, Gradient-based optimization, reinforcement learning VAE, GAN, Diffusion Models	Generative Design: valutazione multi-obiettivo delle soluzioni generate, selezione delle alternative sulla base della dominanza di Pareto per il ciclo di ottimizz. successivo, esplorazione vincolata delle forme, generazione basata su apprendimento di relazioni implicite tra forma, funzione e performance, vincoli fisici da progetti passati
AI agentiva	Sistema multi-agente basato su LLM, Deep Multi-Agent Reinforcement Learning	1.Traduzione dei requisiti in obiettivi per gli agenti specializzati che si occupano della ottimizzazione specifica (meccanica, elettronica, software); coordinamento agenti; gestione feedback umani; 2. Agenti progettano in modo collaborativo aspetti distinti del prodotto e ottimizzano un reward comune legato alla qualità del concetto di prodotto, integrando conoscenza ingegneristica (QFD e Axiomatic Design) nella funzione di reward 3. Agenti orchestrati analizzano il mercato, estraggono attributi formali, generano concept visivi e geometrie 3D, in seguito validate tecnicamente tramite surrogate models neurali con physics-attention 4. Agenti basati su LLM invocano tool di simulazione e analisi ingegneristiche e poi interpretano i risultati

Tabella D.6: Sintesi della mappatura tra tecniche di intelligenza artificiale e delle attività di Concept Optimization supportate, organizzata per paradigmi di AI.

Paradigma AI	Tecniche applicate ai task	Attività specifiche supportate
DL gen.	LLM (anche fine-tuned su progetti passati) e modelli multimodali (Vision–Language Models (VLM); architetture multimodali con cross-attention)	Valutazione qualitativa dei concept nel design concettuale: stima di novità, qualità estetica e funzionale, producibilità del concept; interpretazione congiunta di descrizioni testuali e rappresentazioni visive; simulazione di giudizi esperti con prospettiva multipla (designer, cliente, product manager);
		Interpretazione qualitativa di output grafici e numerici prodotti durante il design di dettaglio (analisi di risultati di simulazione, ottimizzazione topologica, generative design, disegni tecnici e immagini di difetti); sintesi comparative e diagnosi di alto livello
DL	CNN per estrazione di feature visive; BERT e modelli NLP; modelli multimodali supervisionati	Valutazione semi-quantitativa dei concept: estrazione di feature da sketch e immagini, analisi semantica delle descrizioni testuali e predizione di metriche di design (es. qualità del disegno, eleganza, unicità, creatività, utilità) tramite regressione supervisionata.
	ANN, MLP, DCNN	Valutazione quantitativa e validazione di mercato: predizione di KPI continui (es. impatti ambientali, preferenza estetica), stima della preferenza implicita dell'utente a partire da segnali fisiologici (ECG) o dati di interazione online (like/view).
ML (supervision.)	RF, SVM, XGBoost, LightGBM, regressione logistica	Valutazione quantitativa rapida dei concept: stima di KPI (sostenibilità, costi e performance); classificazione di successo/insuccesso commerciale; analisi dell'importanza delle variabili di progetto
ML (non supervisionato)	K-means clustering	Supporto alla validazione di mercato: strutturazione e riduzione della complessità dei dati prima della predizione delle preferenze degli utenti
Neuro-simb.	ANFIS (Adaptive Neuro-Fuzzy Inference System)	Valutazione quantitativa in condizioni di incertezza: modellazione di relazioni vaghe o imprecise tra variabili di progetto e KPI; supporto a decisioni preliminari quando i dati sono incompleti o rumorosi
AI simb.	Rule-based systems	Compliance checking basato su regole esplicite requisiti e vincoli (controllo automatico di conformità a norme, regole di progetto e relazioni formalizzate, soprattutto nel design di dettaglio dove i tecnicismi sono più facilmente formalizzabili)
Simulazioni numeriche e analisi fisiche (AI-assisted)	CFD, FEM, Multibody Dynamics, simulazioni multi-fisiche	Verifica e validazione finale delle prestazioni ingegneristiche (analisi strutturali, fluidodinamiche, termiche e cinematiche quando geometria e materiali sono definiti); validazione rigorosa dei requisiti fisici.
AI agentiva	Agenti LLM orchestratori di tool; framework multi-agente	Impostazione autonoma di simulazioni, interrogazione di tool, analisi dei risultati e supporto al confronto tra alternative progettuali; valutazione collaborativa e iterativa

Tabella D.7: Sintesi della mappatura tra tecniche di intelligenza artificiale e delle attività di Concept Evaluation&Selection supportate, organizzata per paradigmi di AI.

Ringraziamenti

Sono sempre stata brava ad esprimere le mie emozioni, per quanto a volte forti e in alcuni casi smisurate. Sono sempre stata brava a scrivere dediche, messaggi di auguri, lettere per giorni speciali. Eppure, oggi, mi sento un po' sopraffatta, come se fosse impossibile esprimere pienamente quanto questo traguardo significhi per me e quanto tutto questo sia stato reso possibile perché ciascuno di voi, a modo suo, mi è stato vicino e ha permesso che riuscissi ad arrivare fino in fondo.

Devo ammettere che non è andata esattamente come avevo previsto all'inizio e che tollerare le deviazioni non è mai stato il mio forte. Il mio bisogno di pianificare percorsi lineari per tenere in mano il controllo della situazione a volte mi è un po' sfuggito di mano, e qualcuno qua dentro si è subito insieme a me le conseguenze degli imprevisti fuori programma. Basta pensare che durante le vacanze estive del liceo studiavo l'Alpha Test per entrare a Medicina, per poi iniziare Ingegneria Aerospaziale nei primi due anni di università, fino ad arrivare a questo giorno con il diploma in mano da ingegnere gestionale.

Direi che forse di lineare non c'è mai stato proprio niente, se non i piani che avevo in testa, le aspettative di perfezionismo continuo verso me stessa e la mancanza di accettazione verso alcuna forma di fallimento esistente, dallo studio all'amore, allo sport, all'essere una buona sorella o una brava amica.

Eppure, oggi, se mi guardo, capisco quanto a volte sono stata cattiva con me stessa nel non perdonarmi mai. Nel non accettare che si può sbagliare, che non è facile convivere con il peso di questa emotività addosso, che pensare tanto a volte porta a vivere la vita come se si facesse continuamente lo slalom, dove bisogna calibrare attentamente ogni scelta per paura di schiantarsi subito dopo. E di fronte a tutta questa rigidità con cui mi identifico, fatta di svisceramento analitico, previsione continua delle conseguenze future, programmazione anticipata, non mi sono resa conto che la cosa più importante l'ho imparata sul campo.

Ogni volta che ho cambiato i piani per tornare in carreggiata davanti agli ostacoli, creato nuovi progetti mentre quelli presenti si sgretolavano e imparato che deviare non significa fallire, ma saper gestire le difficoltà, tutto questo mi ha permesso di arrivare a oggi con il tipo di laurea che mi rappresenta, circondata dalle persone che volevo fossero presenti a festeggiare con me.

Ma questa tesi non è solo il coronamento del mio percorso, è l'insieme di tutti i contributi che ho ricevuto da ciascuno di voi, e la felicità e l'emozione che oggi sto provando le voglio dedicare a chi non ha mai smesso di credere in me e nella sincerità con cui questi rapporti sono arrivati fino ad oggi.

Un primo grazie va sicuramente alla mia famiglia. Ai miei fratelli Gianmarco, Riccardo e Letizia. Grazie perché mi ricordate continuamente che, anche se presi singolarmente a volte inciampiamo nelle nostre diverse forme di fragilità, insieme riusciamo a creare qualcosa di forte e che saremo per sempre l'uno per l'altro la spalla su cui piangere, l'abbraccio in cui confortarci, il calore da sentire nei giorni di festa e la risata sempre pronta per prendere un po' in giro papà.

A papà, che per quanto abbia avuto qualche difficoltà con me, ha sempre visto il mio potenziale di arrivare dove volevo e, di fronte alla mia rabbia e alle mie sfuriate, mi ha sempre guardata con tanta tenerezza, con la voglia di creare un contatto sincero e di stringere un legame profondo. Lo so che a volte non è facile per te, papà, ma sappi che ti voglio bene per come sei e per quello che riesci a darmi.

Ai miei nonni, che sono stati la mia prima famiglia a tutti gli effetti, che da quando sono nata mi trattano come se fossi la loro figlia. Alla nonna che mi ha sempre protetto e si è sempre presa cura di me, grazie di avermi fatta sentire così al sicuro. Al nonno che è stato ed è tutt'oggi tutto per me: il mio migliore amico, il mio confidente, la mia metà. Senza di te, nonno, non avrei mai imparato ad andare in bicicletta, a capire che per arrivare puntuali a un appuntamento bisogna partire almeno cinque ore prima e a mettere le ciabatte, sempre e comunque, anche quando ci sono 40 gradi d'estate. Senza di te non avrei mai capito che cosa significa davvero essere amata ed essere profondamente legata a una persona. Tu che mi hai insegnato la dedizione e a volte il sacrificio, verso chi

si vuole bene. I nostri sorrisi insieme e i tuoi gesti rimarranno per sempre in un cassetto dentro di me, indelebili come il tatuaggio della stregghetta che mi porto sulla pelle.

A Marco, che rimane sempre presente, che oltre ad aver scelto la mia mamma ha accettato e si è preso cura anche di noi e che è parte della mia famiglia a tutti gli effetti. Grazie perché a volte ci provi ancora e non ti arrendi, proprio come si fa con chi conta davvero.

A Enrico e alla sua famiglia, che fin da quando sono piccola mi accompagnano nelle giornate speciali della mia vita. La vostra presenza anche oggi, nonostante il tempo e la distanza, significa molto per me.

Un ringraziamento speciale va poi a tutti gli amici che, anche se hanno fatto parte della mia vita in periodi diversi, hanno comunque lasciato un segno e contribuito in qualche modo a questo traguardo.

A Gaia, Francesca e Miriam, che dalle medie al liceo e fino all'ultimo giorno dell'università non si sono mai perse una singola celebrazione e momento di difficoltà della mia vita. Grazie perché siete la casa da cui torno quando le cose vanno storte e il punto di ripartenza ogni volta che mi sento persa. Mi avete fatto sentire accettata anche quando tiravo fuori le parti più oscure di me e mi avete insegnato che non serve dare continuamente dimostrazioni per farsi voler bene. Grazie perché nel corso degli anni mi avete confermato sempre di più che finché ci sarete voi non sarò mai sola.

A Giudi, Lele, Sanni, Bordo, Nicolò e Matte B., per tutte le serate e le risate, per tutti i momenti di leggerezza, per la vostra costante presenza. Avete regalato calore e spensieratezza ai miei momenti più difficili.

A Marika e Denise, che condividono con me una parte molto sensibile e che ogni volta mi ricordano la potenza di questo strumento. A voi che create solo legami puri e rapporti sinceri e che, nel farlo, mi avete inclusa nella vostra cerchia ristretta. Quando sono con voi ho la possibilità di esplorare dimensioni più creative, emotive e profonde che, per quanto mi appartengano, a volte nascondo per paura di sentirmi sbagliata. Grazie perché con voi questa parte invece brilla. Siete in grado di farmi sentire valorizzata per quello che a volte sento una debolezza, e non c'è cosa più bella di questo.

Ad Alice ed Eugenia, il broccolo e la mela. A voi che non importa quanto tempo possa passare senza vederci o le distanze che ci separano, perché c'è sempre un filo che ci unisce, resistente ma elastico, che quando lo distendiamo troppo ci fa sentire la mancanza l'una dell'altra e, come effetto di ritorno, ci riporta a noi, ad aggiornarci sulle ultime novità e a confrontarci prima di prendere decisioni importanti. Grazie perché con voi non servono molte parole o rassicurazioni, voi lo sapete, e io lo so.

A Fru, che mi ha accompagnata in questi ultimi due anni di Politecnico, dal primo giorno in cui sono entrata in aula. Grazie perché senza di te il risultato finale dell'esperienza qui sarebbe stato positivo solo al 50%. Hai dato un senso alle ore di lezione con le risate, le prese in giro, i discorsi e le schiscette sotto al sole. Ci siamo scelte tra tante persone nonostante siamo così diverse, e spero che potremo dire lo stesso anche tra tanti anni, ovunque le nostre strade ci porteranno.

A Brucio, alla casa della Frugoni a Pisa, ai festini clandestini in zona rossa, ai discorsoni sulle spallette. Grazie perché sei stato il mio compagno di festa e di sfogo. Grazie perché trovi sempre tempo per me e per la nostra amicizia, e i tuoi abbracci quando ci salutiamo sanno puntualmente di "ci ribecchiamo alla prossima". E già sappiamo che la prossima ci sarà sempre.

A Funghetto, Streby, Boppy e Danto. Quando ripenso alla versione di me più solare e spontanea, la mia mente va a voi. I momenti che abbiamo condiviso mi hanno segnata così tanto, da aver determinato l'immagine che ho di me stessa in quel periodo. Grazie, perché avete reso quei ricordi una parte di me.

A Giada, Matteo, Christian e Mauri, a voi che avete reso Torino la mia seconda casa, quella dove vale la pena restare o tornare sempre. Voi che siete l'unica ragione per cui prendo il volo per Madrid il sabato anziché il venerdì, perché almeno un giorno della settimana ve lo devo dedicare. Siete stati in grado, in un anno, di rivelarmi quelli che considererò gli amici di tutta la vita. La sinergia che si è creata nel nostro gruppo, in cui posso contemporaneamente scherzare, confidarmi sinceramente, essere accettata mentre sono brutalmente me stessa, mi fa sentire come se non avessi bisogno di altro. Siete la quotidianità a cui non vorrei mai rinunciare.

A Daniel. Grazie per tutto quello che mi hai insegnato. Tu che vedi sempre il bicchiere mezzo pieno, sei ottimista e trasmetti la tua positività agli altri. Tu che spesso sacrifichi la maggior parte di te stesso solo per rendere felici le altre persone, devo ammettere che per questo mi ricordi un po' il nonno. Mi hai insegnato ad avere pazienza, che aspettare qualcuno è un gesto d'amore più forte dell'istinto del momento. Mi hai insegnato che accettare un no non significa tradire sé stessi, ma imparare a vivere di compromessi. Grazie perché mi supporti, mi dai sempre il conforto, l'incoraggiamento, la motivazione e l'amore di cui ho bisogno, ma senza mai trasmettermi l'idea di non bastare a me stessa. La tua capacità equilibrata di farmi sentire indipendente mentre mi stai dando tutto è semplicemente la realizzazione di una stabilità relazionale che desidero da tanto.

E infine, alla mamma. Se c'è una persona che merita una dedica, per tutto quello che sono riuscita a raggiungere fino ad adesso sei tu. Tu che, volente o nolente, mi hai trasferito tutte le sfumature che ti appartengono, dalla determinazione nell'inseguire i propri obiettivi alla faccia tosta con cui cerco sempre di farmi rispettare, fino ai lacrimoni da cocodrillo con cui ogni tanto, stremate, ci lasciamo andare per poi ripartire ancora più forti. Volevo dirti che io sono felice di quello in cui mi hai trasformata, del modo in cui le dinamiche del nostro rapporto evolvono, della possibilità di essere diventata per te un'amica, che poi è quello che hai sempre desiderato da quando la nonna non c'è più. Volevo dirti che sei la persona che stimo di più al mondo e che non avresti potuto fare la mamma meglio di come hai fatto, e che questo mio risultato di oggi è in larga parte anche tuo. Grazie mamma perché sei stata e sempre sarai il trampolino di lancio per tutti i traguardi della mia vita.

