

# POLITECNICO DI TORINO

Collegio di Ingegneria Gestionale e della Produzione

Corso di Laurea Magistrale  
in Ingegneria Gestionale e progettazione dei Servizi

Tesi di Laurea Magistrale

## **L'uso dell'intelligenza artificiale generativa nel settore manifatturiero: opportunità e sfide**



**Politecnico  
di Torino**

Relatore

prof. Federico Barravecchia

Candidato

Matteo Leopizzi

Aprile 2025



## Indice

<b>1.</b>	<b>Introduzione</b>	<b>1</b>
1.1	<i>Introduzione al tema e al contesto di studio</i>	1
1.2	<i>Definizione di intelligenza artificiale generativa</i>	2
1.3	<i>Rilevanza dell'IA generativa nel settore manifatturiero</i>	3
1.4	<i>Obiettivi della ricerca e metodologia</i>	5
1.5	<i>Struttura della tesi</i>	6
<b>2.</b>	<b>L'intelligenza artificiale generativa</b>	<b>9</b>
2.1	<i>Definizione e concetti fondamentali</i>	9
2.2	<i>Storia e sviluppo dell'IA generativa</i>	10
2.3	<i>Modelli unimodali e multimodali: struttura e funzionamento</i>	13
2.4	<i>Processo di generazione: il ciclo di vita di una IA generativa</i>	15
2.4.1	Raccolta e preprocessing dei dati	15
2.4.2	Architettura del modello	15
2.4.3	Addestramento del modello	16
2.4.4	Generazione dell'output	17
2.4.5	Postprocessing e affinamento dell'output	17
2.4.6	Confronto tra i modelli e implicazioni	18
2.5	<i>Obiettivi e ambiti di applicazione</i>	19
2.6	<i>Vantaggi e benefici dell'uso dell'IA generativa</i>	22
2.7	<i>Limiti e sfide dell'IA generativa</i>	23
<b>3.</b>	<b>Approccio metodologico alla revisione della letteratura</b>	<b>25</b>
3.1	<i>Obiettivi della revisione della letteratura</i>	25
3.1.1	Applicazioni principali dell'IA generativa nel settore manifatturiero	25
3.1.2	Benefici e sfide derivanti dall'utilizzo dell'IA generativa	26
3.1.3	Tecnologie e modelli di IA generativa più utilizzati	26
3.1.4	Obiettivi metodologici	26
3.1.5	Struttura del processo di revisione	27
3.2	<i>Criteri di selezione degli articoli scientifici</i>	27
3.2.1	Fonti di ricerca	28
3.2.2	Parole chiave utilizzate	28
3.2.3	Criteri di inclusione	29

3.2.4	Processo di selezione e valutazione qualitativa	30
3.3	<i>Strumenti e tecniche di analisi dei dati</i>	31
3.3.1	Gestione e organizzazione dei riferimenti	31
3.3.2	Analisi preliminare e creazione di categorie tematiche	31
3.3.3	Sintesi e interpretazione qualitativa	32
3.3.4	Esclusione di tecniche bibliometriche avanzate	32
3.4	<i>Limiti metodologici e considerazioni</i>	33
3.4.1	Selezione di un'unica banca dati	33
3.4.2	Restrizioni di lingua e periodo	33
3.4.3	Approccio manuale e assenza di strumenti bibliometrici avanzati	34
3.4.4	Possibile incompletezza dei risultati	34
3.4.5	Bias di selezione ed eterogeneità della letteratura	35
3.4.6	Considerazioni conclusive sui limiti metodologici	36
4.	<b>Analisi bibliometrica</b>	37
4.1	<i>Numero di pubblicazioni per anno</i>	37
4.2	<i>Riviste e conferenze principali</i>	39
4.3	<i>Autori e contributori principali</i>	40
4.4	<i>Distribuzione delle pubblicazioni per paese</i>	41
4.5	<i>Tecnologie generative utilizzate</i>	42
4.6	<i>Sintesi dell'analisi bibliometrica</i>	43
5.	<b>Analisi della letteratura: sintesi e tendenze emergenti</b>	47
5.1	<i>Progettazione di nuovi prodotti</i>	48
5.1.1	Casi studio rappresentativi	50
5.2	<i>Generazione di dati sintetici per l'addestramento dei modelli</i>	52
5.2.1	Casi studio rappresentativi	58
5.3	<i>Miglioramento dei processi produttivi</i>	59
5.3.1	Casi studio rappresentativi	64
5.4	<i>Simulazione avanzata di processi industriali</i>	65
5.4.1	Casi studio rappresentativi	67
5.5	<i>Controllo qualità</i>	67
5.5.1	Casi studio rappresentativi	70
5.6	<i>Produzione additiva</i>	71
5.6.1	Casi studio rappresentativi	73

5.7	<i>Analisi teorica e framework sull'GenAI</i>	74
6.	<b>Discussione delle opportunità, sfide e applicazioni nella GenAI per il manifatturiero</b>	77
6.1	<i>Analisi delle opportunità offerte dall'IA generativa nel manufacturing</i>	77
6.2	<i>Discussione delle principali sfide tecniche e organizzative</i>	81
6.3	<i>Implicazioni della GenAI per l'industria: applicazioni e casi studio</i>	83
6.3.1	Il caso Amazon, Microsoft e Airbus: IA generativa per la gestione della supply chain e l'automazione dei processi aziendali	84
6.3.2	Il caso Bosch e Siemens: IA generativa per generazione di dati sintetici e la manutenzione industriale.	86
6.3.3	Il caso Siemens per l'automazione intelligente della programmazione industriale	87
6.3.4	Il caso Toyota: IA generativa per l'ottimizzazione del design e lo sviluppo accelerato dei veicoli	88
7.	<b>Conclusione</b>	89
7.1	<i>Proposte per future linee di ricerca</i>	89
7.2	<i>Considerazioni finali e implicazioni della ricerca</i>	91
8.	<b>Bibliografia</b>	95



# 1. Introduzione

## 1.1 *Introduzione al tema e al contesto di studio*

L'intelligenza artificiale generativa (in inglese *generative artificial intelligence*, abbreviata come GenAI, o anche come IA generativa) rappresenta un ambito di ricerca e sviluppo che sta rivoluzionando diversi settori, tra cui quello manifatturiero, introducendo nuove modalità di progettazione, ottimizzazione dei processi e simulazione di scenari complessi. La capacità dei modelli generativi di creare dati, immagini, testi e altre forme di contenuti sintetici ha aperto prospettive inedite per l'industria, consentendo di migliorare la qualità dei prodotti, accelerare i cicli di sviluppo e ridurre i costi operativi. Grazie alla possibilità di apprendere le distribuzioni sottostanti dei dati e generare nuove istanze realistiche, l'IA generativa è oggi impiegata per supportare l'innovazione industriale in contesti altamente competitivi e caratterizzati da una crescente domanda di automazione e personalizzazione. Questa tesi si colloca all'interno di questo scenario in continua evoluzione, con l'obiettivo di analizzare in modo sistematico il ruolo dell'IA generativa nel settore manifatturiero, evidenziandone le applicazioni, i benefici e le sfide emergenti.

L'evoluzione di questa tecnologia è strettamente legata ai progressi compiuti nell'ambito del *deep learning* e delle architetture neurali avanzate. Le prime tecniche di generazione automatica dei dati si basavano su modelli probabilistici come le catene di Markov e i modelli nascosti di Markov (HMM), limitati nella loro capacità di rappresentare strutture complesse nei dati. L'avvento delle reti neurali profonde, e in particolare delle Generative Adversarial Networks (GAN) e dei Variational Autoencoders (VAE), ha introdotto nuovi paradigmi per la creazione di dati sintetici, portando a un miglioramento significativo nella qualità e nella diversità dei contenuti generati. Più recentemente, i modelli di diffusione e le architetture Transformer hanno ulteriormente ampliato le possibilità dell'IA generativa, migliorando la capacità di generare dati coerenti e contestualizzati in molteplici domini applicativi. Queste tecnologie trovano oggi applicazione in numerose aree del manufacturing, tra cui la progettazione assistita, la simulazione di processi produttivi, la generazione di dati sintetici per l'addestramento di modelli predittivi e il miglioramento del controllo qualità. Inoltre, la convergenza tra IA generativa e tecnologie multimodali ha ampliato le possibilità di integrazione tra linguaggio naturale, immagini e dati numerici, rendendo i sistemi di produzione sempre più adattabili e intelligenti.

Parallelamente ai benefici tangibili offerti dalla GenAI, emergono anche una serie di sfide e considerazioni critiche legate alla sua implementazione nel contesto industriale. Uno degli aspetti più rilevanti riguarda la necessità di garantire l'affidabilità e la robustezza dei modelli generativi, evitando problemi legati alla generazione di dati non accurati o privi di validità operativa. Le cosiddette "allucinazioni" dei modelli generativi, ovvero la produzione di output apparentemente plausibili ma errati, rappresentano un rischio significativo soprattutto in settori ad alta criticità, dove la qualità e la sicurezza dei prodotti sono fondamentali. Inoltre, l'integrazione dell'IA generativa nei sistemi produttivi solleva questioni relative alla trasparenza e all'interoperabilità con le infrastrutture esistenti, rendendo necessaria la definizione di standard e protocolli per garantire un utilizzo efficace e sicuro di queste tecnologie.

Un ulteriore aspetto critico riguarda l'impatto ambientale di questa, in particolare il consumo energetico associato all'addestramento e all'esecuzione di modelli di grande scala. La crescente adozione di queste tecnologie impone una riflessione sulla sostenibilità dei processi industriali e sulla necessità di sviluppare modelli più efficienti dal punto di vista computazionale.

In questo contesto, la ricerca sulla GenAI applicata al manufacturing si sta orientando verso metodologie che ottimizzano l'uso delle risorse e migliorano la trasparenza dei processi generativi, favorendo un'integrazione sicura ed efficace di queste tecnologie nei sistemi industriali. Le strategie di validazione incrociata tra modelli generativi e dati reali, l'uso di tecniche di compressione delle reti neurali e l'applicazione di approcci ibridi con simulazioni fisiche rappresentano alcuni esempi di come l'industria e la comunità scientifica stiano affrontando queste sfide.

Al di là dell'aspetto tecnologico, l'adozione dell'IA generativa nel settore manifatturiero si inserisce anche in un quadro più ampio, in cui le aziende si trovano a dover rimodellare la propria cultura e i propri processi operativi. L'implementazione di tecniche generative richiede competenze trasversali, che spaziano dalla data science alla gestione degli impianti, e implica una collaborazione stretta fra reparti di ricerca e sviluppo, produzione e IT. La disponibilità di infrastrutture adeguate, la sicurezza informatica e la definizione di pratiche di governance per la qualità dei dati sono elementi centrali per massimizzare i vantaggi di questa trasformazione digitale. Nei contesti più avanzati, la sinergia con la robotica collaborativa, i *digital twin* e le piattaforme di monitoraggio industriale sta aprendo nuove prospettive, in cui la generazione automatica di scenari e soluzioni ingegneristiche contribuisce a una produzione più flessibile e resiliente.

La presente tesi si propone di contribuire a questo dibattito attraverso una revisione sistematica della letteratura esistente, con l'obiettivo di delineare un quadro chiaro e aggiornato dell'IA generativa nel contesto manifatturiero. L'analisi si concentrerà sugli ambiti di applicazione, sui benefici tangibili ottenibili dall'adozione di queste tecnologie e sulle principali sfide da affrontare per un utilizzo responsabile ed efficiente dell'intelligenza artificiale generativa nell'industria. L'intento è quello di offrire una visione integrata delle potenzialità e dei limiti attuali, indicando possibili percorsi di ricerca futuri e individuando le leve strategiche che le imprese potranno adottare per cogliere appieno le opportunità da essa offerte.

## 1.2 *Definizione di intelligenza artificiale generativa*

L'intelligenza artificiale generativa può essere definita come un insieme di modelli e algoritmi capaci di apprendere la distribuzione statistica dei dati di addestramento e di generare in modo autonomo nuovi contenuti che risultano coerenti con quelli reali. Questi contenuti possono includere testi, immagini, sequenze numeriche, suoni e modelli tridimensionali, rendendo l'IA generativa una tecnologia estremamente versatile e applicabile a una vasta gamma di contesti (Goodfellow et al., 2014; Kingma e Welling, 2013)

La GenAI si distingue dai modelli discriminativi, i quali si limitano a classificare o prevedere la probabilità di appartenenza di un dato a una determinata categoria. I modelli generativi, invece, si focalizzano sulla comprensione e riproduzione delle relazioni e strutture sottostanti ai dati stessi. In questo modo, anziché limitarsi a individuare la frontiera di separazione tra classi, un modello generativo apprende la funzione di probabilità congiunta dei dati, consentendo la creazione di nuove istanze che presentano caratteristiche statisticamente simili a quelle reali (García-Peñalvo e Vázquez-Ingelmo, 2023).

L'evoluzione dell'IA generativa è stata guidata da innovazioni architetturali e metodologiche fondamentali. In particolare, i Variational Autoencoders (VAE), introdotti da Kingma e Welling (2013), hanno dimostrato come sia possibile apprendere una rappresentazione compatta e continua dei dati, consentendo di generare nuove istanze attraverso il campionamento nello spazio latente. Successivamente, le Generative Adversarial Networks (GAN), sviluppate da

Goodfellow et al. (2014), hanno introdotto un paradigma basato sulla competizione tra un generatore e un discriminatore, migliorando significativamente la qualità e la varietà dei dati sintetici prodotti. Più recentemente, i modelli di diffusione hanno rappresentato un ulteriore progresso nel campo, offrendo un approccio probabilistico alla generazione che migliora la qualità e la stabilità dell'output (Ho et al., 2020)

Questo approccio di “comprensione” profonda della distribuzione statistica rappresenta uno dei punti di forza dell'IA generativa poiché consente la produzione di contenuti sinora inediti ma coerenti con le proprietà di partenza e l'ha reso uno strumento strategico per numerosi settori, tra cui quello manifatturiero. In questo ambito, infatti, l'applicazione di tali tecniche si traduce in vantaggi significativi come la possibilità di generare dati sintetici per integrare dataset reali, simulare scenari produttivi che riflettano con accuratezza le condizioni operative o ideare soluzioni progettuali innovative. Tali potenzialità si accompagnano all'esigenza di assicurare affidabilità e precisione nella fase di generazione, affinché l'output risulti pertinente agli obiettivi industriali e non presenti distorsioni o incongruenze. L'interesse verso l'IA generativa nasce quindi dalla sua capacità di combinare la potenza dell'apprendimento automatico con la creatività computazionale, fornendo una piattaforma che supera la semplice analisi dei dati per abilitare veri e propri processi di creazione e ottimizzazione di conoscenza, in linea con la continua spinta all'innovazione che caratterizza il settore manifatturiero.

### 1.3 *Rilevanza dell'IA generativa nel settore manifatturiero*

L'intelligenza artificiale generativa sta emergendo come una tecnologia trasformativa nel settore manifatturiero, introducendo nuove opportunità per l'ottimizzazione dei processi produttivi, la progettazione innovativa e la gestione avanzata della supply chain. L'integrazione di modelli generativi consente di affrontare alcune delle sfide più rilevanti del settore, tra cui la necessità di ridurre i tempi di sviluppo dei prodotti, migliorare l'efficienza operativa e aumentare la capacità di adattamento alle mutevoli condizioni di mercato. La capacità di generare dati sintetici, simulare scenari complessi e supportare decisioni strategiche basate su modelli predittivi rende l'IA generativa uno strumento essenziale per le aziende che intendono potenziare la propria competitività e accelerare la transizione verso una produzione più intelligente e resiliente. In questo contesto, la letteratura esaminata mostra come l'adozione di soluzioni basate sull'IA generativa sia in costante crescita, con ricadute significative sull'efficienza operativa, la riduzione degli sprechi e la possibilità di personalizzare maggiormente la produzione.

Nell'ambito del miglioramento dei processi produttivi, l'integrazione di modelli generativi con i *digital twin* si rivela una leva strategica per l'ottimizzazione operativa. Questa sinergia consente di simulare con elevata precisione i flussi industriali, migliorando la gestione delle risorse, riducendo i tempi di fermo impianto e ottimizzando il consumo energetico. Parallelamente, l'adozione dei Large Language Models (LLM) sta trasformando la pianificazione e la supervisione della supply chain, automatizzando analisi complesse e abilitando una logistica più reattiva, capace di prevedere e gestire gli imprevisti in tempo reale. Inoltre, le tecnologie generative stanno accelerando la transizione verso una supply chain più sostenibile, favorendo strategie di economia circolare, ottimizzando l'approvvigionamento e riducendo sprechi attraverso previsioni avanzate della domanda. In questo scenario, la crescente collaborazione tra uomo e macchina, supportata da framework generativi, migliora l'adattabilità dei robot nelle linee di produzione, ottimizza il layout degli impianti e fornisce assistenza personalizzata agli operatori, contribuendo alla creazione di un sistema produttivo più autonomo, resiliente e sostenibile.

Nel campo della progettazione di nuovi prodotti, l'IA generativa sta rivoluzionando lo sviluppo progettuale, riducendo significativamente tempi e costi grazie alla generazione automatizzata di varianti ottimizzate. L'impiego delle GAN nella progettazione meccanica consente di ottenere strutture leggere e resistenti, con applicazioni strategiche nei settori aerospaziale e automobilistico. Parallelamente, l'integrazione con i *digital twin* permette di simulare il comportamento del prodotto in vari scenari operativi, riducendo il numero di prototipi fisici necessari e accelerando il ciclo di progettazione. Queste tecnologie favoriscono un processo più efficiente, data-driven e sostenibile, migliorando la capacità di adattamento ai vincoli produttivi e alle esigenze del mercato.

Un altro aspetto di rilievo è la simulazione di processi produttivi, in cui la GenAI consente di prevedere e gestire l'evoluzione dei processi industriali in condizioni variabili. L'impiego di modelli di diffusione e GAN permette di generare ambienti virtuali realistici, ottimizzando la pianificazione operativa e migliorando la resilienza delle linee produttive. Questo approccio si rivela particolarmente utile per testare la risposta dei sistemi a condizioni estreme, anticipando potenziali criticità e riducendo il rischio di inefficienze senza la necessità di interventi fisici.

La generazione di dati sintetici per l'addestramento dei modelli generativi rappresenta un'area di ricerca e applicazione fondamentale nell'ambito dell'intelligenza artificiale e del manufacturing. Questa tecnica consiste nella creazione artificiale di dati realistici per sopperire alla mancanza di dataset reali adeguati, ampliando la disponibilità di informazioni per migliorare le prestazioni e la robustezza dei modelli di machine learning. L'impiego di GAN e modelli di diffusione consente di generare dati che replicano fedelmente le caratteristiche statistiche di quelli reali, garantendo una maggiore variabilità e una migliore capacità di generalizzazione. L'adozione di dati sintetici risponde a diverse esigenze, tra cui la difficoltà di reperire dati sufficienti, le limitazioni legate alla privacy e alla riservatezza delle informazioni, e la necessità di rappresentare fenomeni rari che nei dataset reali risultano scarsamente documentati. Creare dataset sintetici significa quindi fornire ai modelli di intelligenza artificiale un ambiente di apprendimento più ricco e controllato, riducendo il rischio di *overfitting* e aumentando la loro affidabilità in scenari reali.

L'integrazione della generazione di dati sintetici nei processi industriali implica un cambiamento significativo nel modo in cui vengono sviluppati e testati gli algoritmi di analisi, permettendo di affinare la modellazione dei sistemi complessi e di migliorare le capacità predittive senza dipendere esclusivamente da dati empirici. Inoltre, questa tecnologia si inserisce in un contesto più ampio di digitalizzazione e automazione, contribuendo all'ottimizzazione delle operazioni produttive e alla creazione di ecosistemi manifatturieri più adattivi, resilienti e data-driven.

Nel campo della manifattura additiva, l'intelligenza Artificiale sta rivoluzionando il processo di progettazione e produzione, consentendo la creazione di materiali e geometrie ottimizzate per la stampa 3D industriale. Grazie all'uso di GAN e modelli di *deep learning*, è possibile individuare i parametri di stampa ideali, riducendo sprechi di materiale e migliorando la qualità del prodotto finale. L'integrazione tra modelli generativi e stampa 3D favorisce l'ottimizzazione delle strutture, rendendo i componenti più leggeri e performanti senza comprometterne la resistenza meccanica. Parallelamente, l'applicazione di Large Language Models (LLM) nell'ottimizzazione del G-code sta trasformando la gestione operativa della stampa, permettendo di correggere difetti in tempo reale e migliorare la precisione dei processi produttivi. Questi sviluppi non solo rafforzano l'affidabilità della produzione additiva, ma aprono nuove prospettive per la personalizzazione su larga scala, con impatti significativi nei settori biomedicale, aerospaziale e automobilistico. L'integrazione tra Intelligenza Artificiale e stampa

3D sta così delineando un futuro in cui la produzione diventa sempre più efficiente, adattiva e sostenibile.

Il controllo qualità, infine, è tra i campi in cui la GenAI sta registrando i risultati più evidenti. Le tecniche generative, infatti, consentono di identificare difetti nei prodotti finiti con maggiore efficienza, minimizzando l'impiego di ispezioni manuali e aumentando al contempo la precisione dei sistemi di controllo. La simulazione di difetti tramite GAN ha permesso di migliorare l'addestramento dei modelli di ispezione automatica, assicurando performance notevoli nell'individuazione di non conformità, persino in situazioni complesse. L'uso combinato con tecniche di visione artificiale e di apprendimento auto-supervisionato ha ulteriormente potenziato la capacità di rilevare anomalie particolarmente difficili da individuare con i metodi tradizionali.

Nel complesso, le evidenze emerse mostrano come l'IA generativa stia rimodellando profondamente i processi manifatturieri, agendo su progettazione, simulazione, manifattura additiva e controllo qualità. Sebbene restino aperte questioni relative all'integrazione con infrastrutture preesistenti e alla validazione dei modelli, gli studi disponibili suggeriscono che la GenAI sia destinata a rivestire un ruolo sempre più strategico nella transizione verso un comparto industriale fondato sui dati, capace di adattarsi con rapidità alle sfide del mercato e di costruire filiere produttive sempre più sostenibili.

#### 1.4 *Obiettivi della ricerca e metodologia*

Questa ricerca si propone di analizzare il ruolo e l'impatto dell'intelligenza artificiale generativa nel settore manifatturiero, attraverso una revisione sistematica della letteratura. L'obiettivo principale è fornire una visione strutturata e critica sulle applicazioni, i benefici e le sfide associate all'integrazione delle tecnologie generative nei processi produttivi, identificando al contempo le principali traiettorie di sviluppo e le opportunità di ricerca emergenti. Tale analisi si colloca in un contesto in cui l'IA generativa sta rapidamente evolvendo, introducendo nuove modalità di progettazione, simulazione e ottimizzazione dei processi industriali, con implicazioni significative sulla produttività, sulla sostenibilità e sulla trasformazione digitale del settore.

Per garantire un'analisi rigorosa e replicabile, la metodologia adottata si basa su una revisione della letteratura condotta seguendo dei principi di analisi sistematica. Secondo le linee guida consolidate di Snyder (2019), Torres-Carrion et al. (2018) e Paul e Criado (2020), è stato definito un protocollo di ricerca che prevede criteri trasparenti di selezione, inclusione ed esclusione delle fonti bibliografiche. L'analisi si sviluppa attraverso un approccio misto, combinando tecniche bibliometriche per mappare l'evoluzione della ricerca sull'IA generativa nel manufacturing e un'analisi qualitativa per individuare le principali tematiche, sfide e prospettive di sviluppo. La fase quantitativa è stata condotta attraverso l'analisi di pubblicazioni accademiche indicizzate su Scopus, con l'ausilio di strumenti come tabelle pivot per esaminare la distribuzione temporale e geografica delle pubblicazioni, gli autori più influenti, i canali di diffusione scientifica più rilevanti e le tecnologie generative più utilizzate. La componente qualitativa ha invece permesso di approfondire i contenuti degli articoli selezionati, evidenziando pattern emergenti e connessioni tra i diversi approcci tecnologici adottati.

Gli obiettivi specifici della ricerca si articolano lungo tre principali direttrici. In primo luogo, viene analizzato il panorama applicativo dell'IA generativa nel settore manifatturiero, con particolare attenzione a casi d'uso che spaziano dal miglioramento dei processi produttivi alla generazione di dati sintetici per l'addestramento di modelli, fino all'ottimizzazione della

prototipazione e del controllo qualità. Un secondo obiettivo è l'identificazione dei benefici derivanti dall'adozione di queste tecnologie, valutando il loro contributo in termini di efficienza operativa, riduzione dei costi e incremento dell'innovazione. Parallelamente, vengono esaminate le principali sfide tecnologiche, organizzative ed etiche che ne limitano l'adozione su larga scala. Infine, la ricerca si propone di tracciare una mappatura delle tecnologie e dei modelli più utilizzati attualmente in alcuni casi aziendali, analizzandone le peculiarità e le potenzialità future nel contesto industriale.

L'approccio metodologico adottato mira, dunque, a integrare rigore scientifico e visione critica, offrendo una sintesi delle conoscenze attuali sull'IA generativa nel manufacturing e delineando possibili direzioni di ricerca per il futuro. L'analisi delle fonti selezionate non si limita a una mera classificazione degli studi esistenti, ma si propone di evidenziare le connessioni tra i diversi filoni di ricerca, favorendo una comprensione più approfondita delle implicazioni tecnologiche e strategiche connesse all'uso di modelli generativi nei contesti produttivi.

## 1.5 *Struttura della tesi*

La presente tesi è articolata in sette capitoli, ciascuno dedicato all'analisi approfondita di un aspetto specifico dell'intelligenza artificiale generativa nel settore manifatturiero, con un approccio metodologico rigoroso volto a fornire una visione chiara e strutturata dell'argomento.

Dopo il primo capitolo introduttivo, il secondo capitolo offre una trattazione teorica dell'intelligenza artificiale generativa, delineando i suoi concetti fondamentali, le differenze rispetto ai modelli discriminativi e i principali approcci sviluppati nel tempo. Particolare attenzione è dedicata all'evoluzione storica della disciplina, ai fondamenti metodologici su cui si basa e alle tecniche che ne hanno reso possibile l'applicazione in ambito industriale. Il capitolo si conclude con una disamina delle potenzialità e dei limiti attuali della tecnologia, ponendo le basi concettuali per le successive analisi.

Il terzo capitolo è dedicato alla metodologia di ricerca utilizzata per la revisione della letteratura, illustrando il protocollo seguito per la selezione degli articoli, i criteri di inclusione ed esclusione adottati e le tecniche di analisi applicate. L'approccio metodologico integra tecniche bibliometriche e analisi qualitativa, con l'obiettivo di fornire una rappresentazione strutturata dello stato dell'arte e identificare le principali tendenze di ricerca nel campo dell'IA generativa applicata al manufacturing.

Il quarto capitolo si concentra sull'analisi bibliometrica della letteratura selezionata, esaminando la distribuzione temporale e geografica delle pubblicazioni, le principali sedi editoriali, gli autori più attivi e le tecnologie generative più studiate. Questa analisi consente di inquadrare lo sviluppo della ricerca in una prospettiva quantitativa, evidenziando la crescita dell'interesse scientifico e industriale per l'IA generativa nel settore manifatturiero e permettendo di individuare i principali filoni di studio.

Successivamente, il quinto capitolo presenta un'analisi qualitativa della letteratura, organizzata secondo macro-temi che riflettono le principali aree di applicazione della tecnologia. Vengono esaminati i contributi relativi alla progettazione di nuovi prodotti, alla generazione di dati sintetici, alla manifattura additiva, alla simulazione avanzata di processi industriali e al controllo qualità. L'obiettivo è quello di comprendere come le diverse tecniche generative vengano effettivamente integrate nei processi industriali, quali benefici possano apportare in termini di efficienza e innovazione e quali siano le criticità ancora aperte.

Il sesto capitolo amplia la discussione analizzando le opportunità e le criticità legate all'implementazione dell'IA generativa nei contesti industriali. L'attenzione è rivolta agli impatti della tecnologia sull'ottimizzazione dei processi produttivi, sulla sostenibilità, sulla scalabilità delle soluzioni e sull'innovazione strategica delle imprese manifatturiere. Oltre alle valutazioni di carattere teorico, il capitolo include un'analisi di casi aziendali che illustrano esempi concreti di applicazione dell'IA generativa nel settore. Attraverso lo studio di implementazioni reali in aziende leader, viene evidenziato il valore aggiunto della tecnologia e le modalità con cui essa può essere integrata nei processi produttivi. L'analisi dei casi permette inoltre di mettere in luce le strategie adottate dalle imprese per superare le difficoltà tecniche e organizzative connesse alla sua adozione.

La tesi si conclude con una sintesi dei risultati emersi, offrendo una riflessione sulle prospettive future dell'IA generativa nel settore manifatturiero e delineando le possibili direzioni di ricerca e sviluppo. L'obiettivo finale è fornire una comprensione strutturata e scientificamente fondata del ruolo che l'IA generativa sta assumendo nella trasformazione digitale dell'industria, contribuendo a definire le strategie più efficaci per sfruttarne appieno le potenzialità e affrontare le sfide ancora aperte.



## 2. L'intelligenza artificiale generativa

### 2.1 *Definizione e concetti fondamentali*

L'intelligenza artificiale generativa (GenAI) rappresenta una branca avanzata dell'intelligenza artificiale (IA) che si concentra sulla creazione di contenuti originali, quali testi, immagini, suoni e modelli tridimensionali. Questa capacità di generazione avviene attraverso l'apprendimento da grandi quantità di dati, permettendo ai modelli di replicare e innovare basandosi sulle caratteristiche intrinseche dei dati di addestramento (Goodfellow et al., 2014; Kingma e Welling, 2013).

Una distinzione fondamentale nell'ambito dell'intelligenza artificiale risiede tra i modelli generativi e quelli discriminativi due approcci complementari che si differenziano per il modo in cui apprendono dai dati e per le finalità che perseguono. I modelli discriminativi si concentrano sull'apprendimento della relazione diretta tra input e output, stimando la probabilità condizionata che un dato appartenga a una specifica classe. Questo approccio si basa prevalentemente sull'apprendimento supervisionato, un paradigma in cui il modello viene addestrato su un insieme di dati etichettati, ovvero coppie di input e output corretti, con l'obiettivo di apprendere una funzione che possa generalizzare su nuovi dati non visti (Ng e Jordan, 2001). In altre parole, il sistema impara a distinguere tra diverse categorie senza dover comprendere la distribuzione completa dei dati, limitandosi a modellare il confine decisionale tra le classi. Questa caratteristica li rende particolarmente adatti a compiti come la classificazione, la previsione, il riconoscimento di pattern e la rilevazione di anomalie. Ad esempio, un modello discriminativo può essere utilizzato per distinguere tra immagini di automobili e motociclette basandosi su caratteristiche specifiche (San Martín, 2023). Questi modelli si focalizzano sull'analisi delle relazioni tra le caratteristiche degli input e le rispettive etichette, ottimizzando la precisione nella classificazione o nella previsione. Dal punto di vista tecnologico, l'intelligenza artificiale discriminativa si basa su una varietà di algoritmi e architetture avanzate, che spaziano dai modelli probabilistici classici fino alle reti neurali profonde. Tecnologie fondamentali in questo ambito includono le reti neurali convoluzionali (CNN), utilizzate principalmente nella visione artificiale per analizzare immagini e video, e le reti neurali ricorrenti (RNN), che eccellono nell'elaborazione di dati sequenziali come il linguaggio naturale e le serie temporali. Questi modelli sono particolarmente efficaci perché apprendono direttamente dalle caratteristiche salienti degli input, consentendo di ottenere risultati altamente accurati in compiti di classificazione e riconoscimento (Guo et al., 2017). Un'altra tecnologia chiave nell'ambito discriminativo è rappresentata dai modelli basati su trasformatori, come BERT (Bidirectional Encoder Representations from Transformers) e RoBERTa, che hanno rivoluzionato il settore del Natural Language Processing (NLP). Questi modelli apprendono rappresentazioni contestuali sofisticate delle parole, permettendo una comprensione più profonda del testo rispetto ai tradizionali metodi basati su word embeddings statici (Azizah et al., 2023). Anche i modelli di apprendimento supervisionato, come le Support Vector Machines (SVM) e le Random Forest, rientrano nella categoria discriminativa. Queste tecniche, sebbene meno complesse delle reti neurali profonde, trovano ancora applicazione in contesti in cui i dati disponibili sono limitati o in cui si privilegia la trasparenza decisionale rispetto alla complessità del modello (Statnikov et al., 2008).

A differenza dei modelli discriminativi, i modelli generativi non si limitano a classificare i dati ma apprendono la distribuzione congiunta degli stessi, modellando sia le caratteristiche degli

input sia la loro relazione con le possibili categorie di output. Questo consente loro di essere utilizzati sia in apprendimento supervisionato, quando sono disponibili dati etichettati e il modello è addestrato a generare esempi appartenenti a classi specifiche, sia in apprendimento non supervisionato, quando il sistema apprende autonomamente la struttura latente dei dati senza l'ausilio di etichette predefinite (Goodfellow et al., 2014). L'apprendimento non supervisionato è particolarmente utile in scenari in cui la classificazione non è l'obiettivo principale, bensì l'identificazione di pattern nascosti o la generazione di nuove istanze coerenti con la distribuzione originale. Questa caratteristica apre la strada a numerose applicazioni, tra cui la generazione di immagini realistiche, la scrittura automatica di testi, la creazione di modelli tridimensionali complessi e la sintesi vocale (Radford et al., 2019). I modelli generativi, infatti, non si limitano a distinguere tra categorie ma apprendono la struttura intrinseca dei dati, permettendo loro di riprodurre con coerenza la varietà e la complessità delle informazioni originali. In sintesi, mentre i modelli discriminativi si focalizzano sull'ottimizzazione della separazione tra classi, i modelli generativi mirano a comprendere e replicare la distribuzione dei dati, rappresentando due approcci complementari nell'ambito dell'intelligenza artificiale.

## 2.2 *Storia e sviluppo dell'IA generativa*

Le prime forme di IA generativa, sviluppate principalmente tra gli anni '50 e '80, si basavano su modelli probabilistici come le catene di Markov e i modelli nascosti di Markov (HMM), applicati alla generazione automatica di sequenze come testo o musica (Jurafsky e Martin, 2008). Questi modelli funzionavano analizzando le transizioni tra stati, ovvero i passaggi tra elementi consecutivi di una sequenza, come lettere, parole o note musicali. Ad esempio, in un testo, il modello calcolava la probabilità che una determinata parola seguisse un'altra, basandosi sulle frequenze osservate nei dati di addestramento. Utilizzando queste probabilità di transizione, i modelli generavano nuove sequenze in modo da risultare coerenti con i pattern dei dati originali, producendo così testi leggibili o melodie plausibili. Tuttavia, erano limitati perché non riuscivano a considerare relazioni a lungo termine o a catturare strutture più complesse presenti nei dati. Ciò significava che il contenuto generato tendeva a essere semplice e meno coerente su scale più ampie (Jurafsky e Martin, 2008).

Prima dell'affermarsi di queste tecniche, l'idea di macchine capaci di imitare la creatività umana aveva già suscitato un interesse significativo nella comunità scientifica. Nel 1950, Alan Turing propose il celebre "Test di Turing", volto a valutare se una macchina fosse in grado di esibire un comportamento indistinguibile da quello umano. Tale concetto gettò le basi per lo sviluppo di modelli computazionali capaci di generare linguaggio naturale. Nei decenni successivi, la ricerca si concentrò sullo sviluppo di sistemi esperti e reti neurali primitive, con un'attenzione particolare alla rappresentazione della conoscenza e all'elaborazione del linguaggio naturale. Tra gli anni '70 e '90, l'introduzione dei sistemi basati su regole e dei primi modelli di apprendimento automatico fornì nuovi strumenti per la generazione automatizzata di contenuti. L'utilizzo delle reti bayesiane e dei modelli probabilistici avanzati contribuì a migliorare l'efficacia dei sistemi generativi, sebbene la loro capacità fosse ancora limitata dal potere computazionale dell'epoca (Kar et al., 2023).

Con l'avvento delle reti neurali artificiali negli anni '90, le Recurrent Neural Networks (RNN) e le loro varianti, come le Long Short-Term Memory (LSTM), hanno rivoluzionato la modellazione delle sequenze e delle dipendenze temporali, apportando significativi miglioramenti nella generazione di testo e nella traduzione automatica (Hochreiter e Schmidhuber, 1997). A differenza dei modelli probabilistici tradizionali come le catene di Markov, le RNN hanno introdotto la capacità di gestire contesti più ampi grazie alla loro

architettura ricorsiva. Tuttavia, le RNN presentavano una limitazione importante: durante l'addestramento, diventava difficile aggiornare i parametri relativi a informazioni lontane nel tempo, poiché il segnale di apprendimento (gradiente) tendeva a diminuire drasticamente man mano che si propagava all'indietro. Questo problema, noto come 'gradiente che svanisce', è stato superato con l'introduzione delle LSTM, proposte nel 1997, che hanno introdotto meccanismi specifici per conservare informazioni rilevanti per periodi più lunghi. Questi modelli sfruttano una struttura di memoria a lungo termine per catturare relazioni temporali su scale più lunghe, risultando particolarmente efficaci in applicazioni come il riconoscimento vocale e l'elaborazione del linguaggio naturale (Cao et al., 2023; Kılınc e Kececioğlu, 2023).

Si dovrà aspettare fino al 2014 per un'ulteriore e significativa svolta nel mondo dell'intelligenza artificiale generativa grazie all'ampia diffusione degli autoencoder variazionali (VAE), proposti inizialmente da Kingma e Welling nel 2013, e l'introduzione delle reti generative avversarie (GAN) da parte di Goodfellow et al. nel 2014. I VAE combinano l'apprendimento profondo (*deep learning*), il substrato tecnico su cui si basano molte delle architetture dell'IA generativa, con l'inferenza variazionale, un metodo statistico per approssimare distribuzioni posteriori complesse, permettendo di apprendere una rappresentazione latente continua dei dati. Questo approccio facilita la generazione di nuovi campioni simili a quelli del set di addestramento attraverso il campionamento dallo spazio latente, un dominio multidimensionale astratto in cui i dati originali vengono rappresentati in modo più compatto e strutturato (Kingma e Welling, 2013). L'introduzione delle reti generative avversarie ha avuto un impatto rivoluzionario nel campo dell'intelligenza artificiale generativa. Le GAN consistono in due reti neurali in competizione: un generatore che produce dati sintetici e un discriminatore che valuta la genuinità dei dati (Goodfellow et al., 2014). Questo meccanismo avversario ha permesso di generare immagini, audio e testo di qualità sorprendente. Tuttavia, mentre le GAN dominavano il panorama della generazione di contenuti, la ricerca ha continuato a esplorare nuove architetture per affrontare sfide legate alla comprensione e generazione di sequenze più complesse.

È in questo contesto di rapida innovazione che, nel 2017, è stata introdotta l'architettura Transformer (Vaswani et al., 2017), un modello progettato per superare le limitazioni delle reti neurali ricorrenti (RNN) e delle LSTM nella gestione di dipendenze a lungo termine. Questo approccio ha rappresentato un punto di svolta, non solo per l'elaborazione del linguaggio naturale, ma anche per l'evoluzione dell'IA generativa, aprendo la strada a modelli in grado di gestire dati complessi e multimodali in modo più efficiente. In particolare, l'avvento dei modelli pre-addestrati su grandi dataset ha permesso di ottenere risultati straordinari nella generazione di testo e contenuti multimediali. BERT, sviluppato da Devlin et al. (2019), ha rivoluzionato il NLP introducendo un approccio bidirezionale all'analisi del testo. Questo modello ha migliorato la comprensione del linguaggio contestuale, rendendo possibile la generazione di testi più coerenti e sofisticati (Kar et al., 2023)

Sfruttando le potenzialità dell'architettura Transformer, OpenAI ha dato vita ai modelli Generative Pre-trained Transformer (GPT). Nel 2019, con il lancio di GPT-2 (Radford et al., 2019), la comunità ha assistito a un notevole salto in avanti nella generazione di testo. Questo modello era in grado di produrre contenuti coerenti e contestuali, grazie all'addestramento su vasti dataset non supervisionati. L'entusiasmo è cresciuto ulteriormente con GPT-3 (Brown et al., 2020), che ha dimostrato una capacità sorprendente di comprendere e generare linguaggio naturale, avvicinandosi sempre più alla complessità dell'espressione umana.

Come sottolineato da Kılınc e Kececioğlu (2023), l'evoluzione dei modelli basati su Transformer ha ampliato enormemente le applicazioni dell'IA generativa. Non si tratta più solo

di generare testo, ma di influenzare settori come l'assistenza virtuale, la creazione di contenuti e l'automazione di processi creativi, trasformando il modo in cui interagiamo con la tecnologia.

Proseguendo su questa scia di innovazione, nel 2021 OpenAI ha presentato DALL·E (Ramesh et al., 2021), un modello rivoluzionario che unisce l'elaborazione del linguaggio naturale con la generazione di immagini.

Parallelamente, i modelli di diffusione sono emersi come una potente classe di modelli generativi per la sintesi di immagini e altri tipi di dati. Ho et al. (2020) hanno introdotto i Denoising Diffusion Probabilistic Models (DDPM), dimostrando come questi modelli possano produrre immagini ad alta risoluzione con un controllo dettagliato sul risultato finale, offrendo una generazione più stabile e priva di artefatti tipici di altre tecniche generative. Invece di affidarsi a meccanismi avversari come le GAN, questi modelli apprendono a generare dati invertendo un processo di diffusione che aggiunge progressivamente rumore ai dati di training. Il rumore, in questo contesto, non è un elemento di disturbo casuale ma una componente strutturale della tecnica: viene intenzionalmente introdotto durante l'addestramento per degradare gradualmente i dati originali e successivamente rimosso nel processo di generazione, ricostruendo i dati con maggiore fedeltà (Ho et al., 2020). Questo meccanismo, che simula un percorso inverso dal caos all'ordine, consente di ottenere risultati estremamente coerenti e di alta qualità. L'abilità dei modelli di diffusione di gestire efficacemente il rumore li rende particolarmente adatti per applicazioni avanzate, come la generazione di immagini sintetiche e il miglioramento della qualità di contenuti digitali.

Un contributo significativo alla generazione di immagini è stato dato da Rombach et al. (2022) con l'introduzione di Stable Diffusion, basato sui modelli di diffusione latente. Questo modello open-source ha reso possibile la sintesi di immagini ad alta risoluzione con un'efficienza computazionale tale da consentirne l'uso su hardware consumer. Di conseguenza, Stable Diffusion ha reso l'IA generativa avanzata accessibile a un pubblico più ampio, stimolando innovazione e creatività sia nella ricerca accademica che tra gli utenti comuni.

OpenAI, nel 2022, ha elevato ulteriormente il livello con DALL·E 2 (Ramesh et al., 2022). Questo modello ha migliorato significativamente la risoluzione e la fedeltà delle immagini generate, utilizzando una combinazione di modelli di diffusione e tecniche di apprendimento avanzate. Dando vita a immagini altamente dettagliate e realistiche, che hanno ampliato le applicazioni dell'IA generativa in campi come il design, l'arte e la pubblicità.

Solo nell'anno successivo, l'azienda, ha presentato GPT-4 (OpenAI, 2023a), segnando un ulteriore passo avanti nella serie GPT. Questo modello ha ampliato le capacità di comprensione e generazione del linguaggio naturale, supportando input multimodali che includono sia testo che immagini. Ciò ha permesso applicazioni ancora più sofisticate nell'assistenza virtuale, nella creazione di contenuti personalizzati e nell'automazione di processi complessi.

Proseguendo nel percorso evolutivo dell'IA generativa, nel settembre 2023 OpenAI ha annunciato DALL·E 3 (OpenAI, 2023b). Basato sulle avanzate capacità di GPT-4, DALL·E 3 offre una comprensione ancora più profonda dei prompt testuali complessi, consentendo la generazione di immagini che rispecchiano con maggiore precisione le descrizioni fornite dagli utenti. Questo modello affronta le limitazioni delle versioni precedenti, migliorando la coerenza e l'accuratezza delle immagini generate, specialmente nei dettagli fini e nelle interazioni tra oggetti. Una delle innovazioni più interessanti di DALL·E 3 è la sua integrazione più stretta con i modelli linguistici, che permette interazioni più naturali e intuitive. Il modello dimostra una capacità migliorata nel rappresentare testo all'interno delle immagini, nel generare scene complesse con più elementi e nel comprendere il contesto culturale e stilistico. Questo amplia le

sue applicazioni in campi come il design, l'educazione e l'intrattenimento, offrendo strumenti potenti per la creatività e l'espressione umana (OpenAI, 2023b).

### 2.3 *Modelli unimodali e multimodali: struttura e funzionamento*

I modelli generativi possono essere generalmente distinti in due ampie categorie a seconda della tipologia di dati su cui sono addestrati e per cui sono progettati: i modelli unimodali, specializzati su una singola tipologia di input (come immagini o testo), e i modelli multimodali, in grado di gestire e integrare simultaneamente più tipi di contenuti (immagini, testo, audio, video, ecc.).

I modelli unimodali si concentrano su un unico tipo di dato, permettendo di raggiungere risultati notevoli in termini di qualità e coerenza nella generazione all'interno di un singolo dominio. Ad esempio, nel settore delle immagini, le GAN (Goodfellow et al., 2014) hanno costituito uno dei primi approcci di grande impatto, in grado di generare immagini realistiche partendo da semplici vettori di rumore. Allo stesso modo, i VAE hanno introdotto un approccio probabilistico alla generazione di dati, costruendo una rappresentazione latente del dominio di input, dalla quale è possibile campionare per ottenere nuovi esempi (Kingma e Welling, 2013).

Oltre ai GAN e ai VAE, si sono affermate altre famiglie di modelli unimodali. I modelli auto regressivi, come quelli alla base di GPT-3 (Brown et al., 2020), hanno rivoluzionato la generazione di testo, passando dalla sintesi di semplici frasi alla produzione di documenti coerenti, risposte a domande e persino programmazione assistita. Questi modelli scompongono il problema della generazione in una serie di predizioni sequenziali: per il testo, ad ogni passo si predice un token (parola o sub-parola) successivo basandosi su quelli già generati, garantendo così un flusso narrativo coerente e contestuale.

Nel dominio visivo, un ulteriore avanzamento è stato apportato dai modelli di diffusione, come i Denoising Diffusion Probabilistic Models (DDPM) (Ho et al., 2020). Questi modelli si basano su un processo di denoising graduale: partendo da immagini completamente corrotte dal rumore, addestrano una rete a invertire tale processo, ricostruendo progressivamente la struttura dell'immagine originale. Il risultato è un modello capace di generare immagini di altissima qualità, spesso superiori a quelle ottenute con le GAN, con un'architettura relativamente più stabile e controllabile. Pur restando unimodali, i modelli di diffusione possono focalizzarsi su un singolo tipo di dato, come le immagini, offrendo un punto di partenza solido per ulteriori sviluppi.

Complessivamente, nei modelli unimodali la sfida principale consiste nel catturare le distribuzioni complesse dei dati in un singolo dominio, ottimizzando l'architettura e le funzioni obiettivo per ottenere un output di alta qualità, coerente e realistico.

La crescente disponibilità di dataset composti da dati eterogenei (es. immagini corredate da didascalie testuali, video con tracce audio, testo e immagini annotati con metadati) ha stimolato lo sviluppo di modelli capaci di interpretare e generare contenuti attraverso più modalità simultaneamente, ovvero modelli multimodali. Questi approcci consentono di superare i confini imposti dai modelli unimodali, offrendo la possibilità di correlare e integrare informazioni provenienti da diverse fonti.

Uno dei risultati più noti in questo ambito è costituito da DALL·E (Ramesh et al., 2021), un modello capace di generare immagini a partire da prompt testuali, combinando le capacità di comprensione del linguaggio naturale con le abilità di generazione di contenuti visivi. In modo analogo, Imagen (Saharia et al., 2022) ha ulteriormente elevato il livello qualitativo della

generazione *text-to-image*, dimostrando come l'integrazione di modelli avanzati di comprensione del linguaggio con meccanismi di diffusione nelle immagini possa produrre risultati estremamente fotorealistici.

L'emergere di architetture basate su Transformer (Vaswani et al., 2017) ha favorito l'unione di diverse modalità. Questi modelli, originariamente progettati per la lingua, sono stati estesi ai dati visivi e audiovisivi grazie a meccanismi di attenzione.

L'attenzione è un meccanismo che consente al modello di concentrarsi dinamicamente sulle parti più rilevanti dell'input, facilitando la comprensione di relazioni a lungo raggio tra elementi di un testo, di un'immagine o di un segnale audio (Vaswani et al., 2017). Questo approccio ha portato a miglioramenti sostanziali nella qualità della generazione, poiché il modello può "focalizzarsi" su regioni chiave dei dati, integrandone il significato in modo più coerente. Nel caso dell'integrazione multimodale, i meccanismi di attenzione permettono di collegare testi descrittivi a caratteristiche visive, audio o sensoriali, creando contenuti capaci di mantenere un senso logico e una coerenza interna anche quando si lavora con tipi di dati diversi (Ramesh et al., 2021). Ad esempio, modelli come ViLBERT (Lu et al., 2019) e altre architetture *vision-language* integrano flussi di informazione testuale e visiva in un unico spazio di rappresentazione, rendendo possibili compiti di generazione in cui testo e immagini si influenzano reciprocamente.

Oltre all'ambito testuale-visivo, i modelli multimodali si stanno espandendo verso domini come l'audio e il video. DiffWave (Kong et al., 2021), ad esempio, applica il principio dei modelli di diffusione al dominio sonoro, generando audio con caratteristiche desiderate a partire da input testuali o da parametri sintetici. Questi approcci aprono la strada a molteplici applicazioni, dal design sonoro alla generazione di musica coerente con un contesto visivo o narrativo. I modelli multimodali offrono dunque la possibilità di navigare e produrre contenuti in spazi semantici più complessi, dove il testo può guidare l'immagine, l'immagine può chiarire il testo, l'audio può definire l'atmosfera e così via. Tuttavia, la complessità architettonica e computazionale di questi modelli è maggiore, e la qualità delle prestazioni dipende fortemente dalla disponibilità di dataset multimodali ben strutturati, nonché dalla capacità di allineare correttamente le rappresentazioni latenti dei diversi domini.

La distinzione tra modelli unimodali e multimodali, quindi, non è solo una differenza nella tipologia di dati gestiti, ma anche nella complessità della progettazione, nell'addestramento e nell'efficacia dei risultati. I modelli unimodali si focalizzano profondamente su un singolo dominio e, grazie a questa focalizzazione, raggiungono spesso performance ottimali per quel tipo di dati. D'altro canto, i modelli multimodali, abbracciando simultaneamente diversi domini, arricchiscono notevolmente la gamma di applicazioni: dal *text-to-image* alla generazione audiovisiva sincronizzata, fino a sistemi in grado di dialogare con l'utente utilizzando più canali percettivi.

Man mano che i dataset diventano più ricchi e disponibili, e che le risorse computazionali aumentano, si prevede una crescente convergenza tra modelli unimodali e multimodali. Quest'ultimi non solo consentono di rispondere a esigenze applicative più complesse, ma favoriscono una comprensione più profonda della realtà, in cui le informazioni raramente si presentano isolate in una singola forma. Questa evoluzione, oltre ad avere implicazioni in settori creativi (come l'arte, la moda o il design), è destinata a giocare un ruolo centrale in contesti come il manufacturing, dove l'interpretazione multimodale di dati tecnici, visivi e testuali può supportare processi di progettazione, controllo e ottimizzazione sempre più sofisticati.

## 2.4 *Processo di generazione: il ciclo di vita di una IA generativa*

Nonostante la distinzione tra modelli unimodali e multimodali influenzi la progettazione e le capacità di un sistema generativo, il processo di sviluppo di modelli di intelligenza artificiale generativa segue comunque una struttura comune. In questo paragrafo si evidenziano le fasi chiave che portano alla creazione di sistemi capaci di generare contenuti realistici e coerenti. In particolare, si approfondisce il flusso che parte dalla raccolta e preprocessing dei dati, necessari per garantire un dataset di qualità, fino alla generazione e affinamento dell'output. Viene esaminata la progettazione dell'architettura del modello, con un focus su approcci consolidati come GAN, VAE, modelli di diffusione e Transformer, analizzandone il funzionamento e le peculiarità. La fase di addestramento viene descritta nei suoi aspetti fondamentali, illustrando le strategie di ottimizzazione utilizzate per migliorare le prestazioni del modello. Infine, si esplora il ruolo del postprocessing, utile per perfezionare i contenuti generati e adattarli a specifici contesti applicativi. L'obiettivo è fornire una visione strutturata e approfondita del ciclo di vita di un modello generativo, illustrando come le diverse architetture apprendano a trasformare un determinato input in un output coerente e definito.

### 2.4.1 Raccolta e preprocessing dei dati

La prima fase di questo flusso consiste nella selezione e preparazione del dataset. Si tratta di individuare dati di elevata qualità, rappresentativi del dominio d'interesse. Ad esempio, per addestrare un modello di immagini come una GAN o un modello di diffusione (Goodfellow et al., 2014; Ho et al., 2020), si raccolgono collezioni di immagini coerenti con il tipo di contenuto da generare (volti, componenti industriali, paesaggi). Nel caso dei modelli di linguaggio (Brown et al., 2020), si utilizza un ampio corpus di testi. Per i modelli multimodali, si ricorrerà a dataset contenenti coppie immagine-testo o sequenze audio allineate a trascrizioni.

Il preprocessing comprende attività come normalizzazione, ridimensionamento, pulizia dai dati rumorosi o inconsistenti e, se necessario, l'augmentazione dei dati per aumentare la varietà statistica del dataset. Questa fase è cruciale poiché la qualità e la diversità dei dati influiscono direttamente sulla capacità del modello di generalizzare e creare output convincenti (Rombach et al., 2022).

### 2.4.2 Architettura del modello

Successivamente bisogna considerare l'architettura del modello generativo, che può variare notevolmente in funzione della natura del dato (unimodale vs. multimodale) e degli obiettivi. Questa fase è determinante per stabilire non solo la qualità e la coerenza dell'output, ma anche la stabilità e la velocità con cui il modello convergerà durante il training.

Partendo dalle Generative Adversarial Networks (Goodfellow et al., 2014), si osserva una struttura basata su due reti neurali distinte, il generatore e il discriminatore, poste in competizione tra loro: il generatore, partendo da un semplice vettore di rumore, cerca di produrre dati sintetici con caratteristiche simili a quelli reali, mentre il discriminatore valuta l'autenticità di questi dati. Un corretto bilanciamento tra le due reti, la scelta attenta delle loro dimensioni, delle funzioni di attivazione e dei meccanismi di normalizzazione, nonché l'impiego di architetture convoluzionali profonde come DCGAN (Radford et al., 2015), contribuisce a rendere l'addestramento più stabile e a migliorare la qualità dell'output.

Un approccio differente è quello adottato nei Variational Autoencoders, dove si utilizza un'architettura encoder-decoder per apprendere una rappresentazione probabilistica dei dati in

uno spazio latente continuo. In questo contesto, l'encoder mappa i dati di input in distribuzioni latenti, mentre il decoder cerca di ricostruire il dato originale partendo da campioni di tali distribuzioni. La scelta dei parametri di questo “collo di bottiglia” latente, nonché la definizione di una funzione obiettivo che bilanci la qualità della ricostruzione con la regolarizzazione della distribuzione latente (ELBO), influisce sulla capacità del VAE di generare contenuti vari e coerenti (Kingma e Welling, 2013).

Un ulteriore paradigma è offerto dai modelli di diffusione, come i Denoising Diffusion Probabilistic Models (DDPM) (Ho et al., 2020), nei quali la generazione si basa sul progressivo denoising di dati sempre più rumorosi. Qui si preferisce spesso un'architettura di tipo U-Net, concepita in origine per segmentare immagini mediche e poi adattata al contesto generativo (Ronneberger et al., 2015). La U-Net riceve immagini contaminate dal rumore e, a ogni step, ne rimuove una parte, ricostruendo a ritroso il dato a partire da una condizione di totale corruzione. Con approcci più recenti, come i Latent Diffusion Models (Rombach et al., 2022), la fase di generazione viene traslata in uno spazio latente più compatto, riducendo il carico computazionale e migliorando l'efficienza del processo.

Un'attenzione particolare va anche alle architetture basate sui Transformer, inizialmente introdotte per il linguaggio naturale, ma oggi applicate con successo a domini come visione e audio. Questi modelli sfruttano meccanismi di attenzione, ossia funzioni che, data una sequenza di elementi (parole, patch di pixel, frame audio), assegnano pesi differenti a seconda dell'importanza relativa di ciascun elemento nel contesto globale. La progettazione di un Transformer generativo implica la definizione del numero di livelli, della dimensione delle rappresentazioni interne e del numero di “teste” di attenzione parallele, nonché dei token speciali per indicare l'inizio, la fine o il tipo di dato (Vaswani et al., 2017).

Quando si passa a dati multimodali, come testo e immagini, diventa essenziale definire architetture che consentano di allineare i due domini in uno spazio latente condiviso. Modelli come CLIP (Radford et al., 2021) allenano due reti separate, una per il testo e una per l'immagine, in modo da creare rappresentazioni confrontabili, mentre approcci come DALL·E (Ramesh et al., 2021) trasformano le immagini in sequenze di codici visivi assimilabili a token testuali e utilizzano un singolo Transformer per processare entrambi i tipi di input. In questi casi, la progettazione deve tenere conto di come bilanciare e integrare le diverse modalità, spesso mediante componenti di *cross-attention* in cui il modello “guarda” a una modalità, ad esempio il testo, per generare o interpretare contenuti nell'altra, come l'immagine.

### 2.4.3 Addestramento del modello

Una volta definita l'architettura del modello, si passa alla fase di addestramento, durante la quale il sistema apprende a generare dati plausibili minimizzando una funzione obiettivo, la quale regola il processo di apprendimento e influenza la qualità della generazione. Questo obiettivo varia in base alla tipologia di modello. Nel caso delle GAN, ad esempio, il compito è quello di risolvere un gioco min-max tra un generatore, incaricato di produrre dati sintetici a partire da un semplice vettore di rumore, e un discriminatore, deputato a distinguere tra dati reali e dati generati artificialmente. Durante l'addestramento, la funzione di perdita guida i due componenti verso un equilibrio in cui il generatore diventa in grado di ingannare il discriminatore e produrre contenuti sempre più realistici (Goodfellow et al., 2014). I Variational Autoencoders (VAE) adottano un approccio diverso: il loro obiettivo è massimizzare la cosiddetta Evidence Lower Bound (ELBO), una misura che bilancia la qualità della ricostruzione del dato iniziale con la regolarizzazione dello spazio latente. In questo modo, il

VAE impara una rappresentazione probabilistica interna del dominio dei dati, da cui è poi possibile campionare per generare nuovi esempi realistici (Kingma e Welling, 2013). Nei modelli di diffusione, come i Denoising Diffusion Probabilistic Models (DDPM), l'ottimizzazione è finalizzata a minimizzare un obiettivo di denoising, che incoraggia la rete a ricostruire in modo accurato i dati puliti partendo da versioni progressivamente corrotte dal rumore. Questo processo di apprendimento invertito, in cui si impara a rimuovere il disturbo aggiunto artificialmente durante la fase di training, consente di ottenere dati sintetici di elevata qualità (Ho et al., 2020). Nel caso di modelli basati su Transformer, specie quelli auto regressivi utilizzati per la generazione testuale o multimodale, l'addestramento si fonda sul principio della Maximum Likelihood Estimation (MLE), vale a dire sulla massimizzazione della verosimiglianza dei dati osservati, in modo che il modello predica correttamente i token successivi in una sequenza. Ciò permette di produrre contenuti coerenti, contestualizzati e ricchi di sfumature semantiche (Brown et al., 2020).

L'ottimizzazione di queste funzioni obiettivo avviene attraverso algoritmi come Adam o Stochastic Gradient Descent (SGD), metodi iterativi che aggiornano i pesi del modello nella direzione che riduce l'errore (Kingma e Ba, 2014; Goodfellow et al., 2016).

#### 2.4.4 Generazione dell'output

Una volta completata la fase di addestramento, il modello è pronto per generare nuovi contenuti, un processo che varia a seconda dell'architettura utilizzata. Nei modelli GAN, l'input di partenza è di solito un vettore di rumore casuale che, attraversando il generatore, viene trasformato in un dato sintetico simile a quelli del dominio di riferimento, ad esempio un'immagine (Goodfellow et al., 2014). Nei VAE, invece, si campiona un punto dallo spazio latente apprendendo come questo spazio possa generare dati realistici una volta decodificati (Kingma e Welling, 2013). Nei modelli di diffusione si ripercorre a ritroso il processo di corruzione simulato in fase di addestramento: si parte da puro rumore e, step dopo step, si denoisa l'input fino a ottenere un contenuto nitido e coerente (Rombach et al., 2022). Nel caso dei Transformer, fornire un prompt iniziale, che può essere costituito da un breve testo, un'immagine o entrambi, permette al modello di proseguire la generazione in maniera coerente con il contesto imposto (Vaswani et al., 2017).

#### 2.4.5 Postprocessing e affinamento dell'output

Una volta generato l'output dal modello addestrato, il processo non necessariamente termina con la semplice presentazione del risultato così com'è. L'output generato da modelli di intelligenza artificiale può essere ulteriormente rifinito tramite strategie di postprocessing, volte a migliorare la qualità, ridurre artefatti o adattare i dati a specifiche esigenze applicative.

In contesti produttivi o industriali, si utilizzano spesso tecniche di postprocessing per perfezionare i contenuti sintetizzati, garantendo che rispettino gli standard qualitativi attesi (Brühl, 2023). Nel caso dei dati visivi, ad esempio, l'output di una GAN o di un modello di diffusione può presentare imperfezioni, artefatti o incoerenze. Modelli di super-risoluzione, come quelli introdotti da Wang et al. (2018), migliorano la qualità delle immagini sintetiche aumentando la risoluzione senza introdurre distorsioni. Analogamente, nel caso della generazione testuale, il postprocessing linguistico si occupa di affinare l'output in termini di grammatica, coerenza e adeguatezza terminologica. Correttori ortografici o modelli specializzati nella verifica della coesione semantica, come quelli basati su Transformer, possono migliorare

ulteriormente il testo generato (Brown et al., 2020). Questo tipo di rifinitura diventa essenziale in contesti dove il testo deve rispettare specifiche tecniche o standard industriali.

Infine, nei modelli multimodali, il postprocessing si estende sia all'immagine sia al testo. Nel caso delle immagini, le tecniche descritte possono perfezionare la qualità visiva; nel caso del testo, possono adattare le descrizioni per renderle più pertinenti e comprensibili (Ramesh et al., 2021). In applicazioni come la fabbricazione additiva o il controllo qualità, il postprocessing include spesso fasi di validazione automatica, dove i contenuti generati vengono confrontati con specifiche tecniche o standard interni (Brühl, 2023).

#### 2.4.6 Confronto tra i modelli e implicazioni

Nonostante la struttura generale rimanga simile, le differenze interne tra i modelli incidono sul tipo di risultati ottenibili. Le GAN offrono spesso immagini molto realistiche ma possono soffrire di instabilità nell'addestramento, i VAE garantiscono una buona copertura della distribuzione ma tendono a produrre risultati più sfocati. I modelli di diffusione mostrano un'eccellente qualità di generazione e stabilità, sebbene possano essere più costosi dal punto di vista computazionale. I Transformer auto regressivi eccellono nella generazione testuale coerente e stanno rapidamente estendendo le loro capacità a domini multimodali, grazie a meccanismi di attenzione che permettono di integrare informazioni provenienti da fonti eterogenee (Brown et al., 2020; Vaswani et al., 2017).

In definitiva, pur partendo da principi comuni nel flusso di generazione, le specificità di ogni architettura, dalla natura dei dati al tipo di funzione obiettivo, fino all'architettura interna, portano a risultati con caratteristiche differenti. Tale varietà consente di selezionare e progettare modelli su misura per le esigenze del settore manifatturiero, sia in termini di resa qualitativa, che di interpretabilità e scalabilità. La Tabella 2.1 presenta una sintesi comparativa dei principali modelli di intelligenza artificiale generativa, organizzati secondo una prospettiva evolutiva.

Tabella 2.1. Modelli di Intelligenza Artificiale Generativa: sintesi comparativa

<b>MODELLO / TECNOLOGIA</b>	<b>Principio chiave</b>	<b>Ambito applicativo</b>	<b>Punti di forza</b>	<b>Limiti principali</b>
<b>HMM / MARKOV (1950-1980)</b>	Transizioni probabilistiche	Testo, musica	Semplicità	No relazioni a lungo termine
<b>LSTM (1997)</b>	Memoria a lungo termine	NLP, audio	Gestione sequenze	Costosi da addestrare; vanishing gradient
<b>VAE (2013)</b>	Spazio latente + inferenza	Immagini, audio	Generazione fluida	Qualità limitata rispetto a GAN
<b>GAN (2014)</b>	Apprendimento competitivo	Immagini, audio	Realismo elevato	Instabilità in addestramento
<b>TRANSFORMER (2017)</b>	Self-attention	NLP, generazione	Contesto globale	Complessità computazionale

<b>GPT (2019)</b>	Pretraining + autoregressivo	Testo, assistenti	Coerenza testuale	"Allucinazioni" testuali
<b>DIFFUSIONE (DDPM) (2020)</b>	Inversione del rumore	Immagini	Alta fedeltà	Tempi di generazione lunghi
<b>STABLE DIFFUSION (2022)</b>	Diffusione latente	Immagini	Efficiente, open	Meno versatile dei modelli generalisti
<b>DALL·E 2 (2022)</b>	Testo → immagine	Design, arte	Comprensione semantica	Generazione del testo su immagini (parziale)
<b>GPT-4 / DALL·E 3 (2023)</b>	Multimodalità	Assistenza, creatività	Contesto profondo	Accesso ristretto

## 2.5 *Obiettivi e ambiti di applicazione*

L'intelligenza artificiale generativa si configura come una tecnologia versatile con un ampio spettro di applicazioni che attraversano diversi settori, trasformando processi tradizionali, migliorando l'efficienza operativa e stimolando l'innovazione. Gli obiettivi principali della GenAI includono la generazione di contenuti nuovi e realistici, l'ottimizzazione di processi complessi, il supporto decisionale avanzato e la personalizzazione su larga scala. Questi obiettivi trovano applicazione in diversi ambiti, dall'automazione industriale alla creatività digitale, dall'ottimizzazione dei processi aziendali alla personalizzazione dell'esperienza utente, contribuendo a trasformare profondamente settori chiave come la sanità, la finanza e l'ingegneria.

Nel settore della robotica, i modelli generativi, come le GAN, trovano applicazione per migliorare l'apprendimento dei robot in ambienti complessi. In particolare, le GAN possono essere collegate all'apprendimento per rinforzo inverso, consentendo ai robot di apprendere comportamenti ottimali basandosi su dimostrazioni umane. Questo approccio migliora la capacità dei robot di interpretare dati complessi e di navigare in ambienti incerti, promuovendo interazioni più naturali e adattative (Finn et al., 2016). I modelli generativi come i Variational Autoencoders (VAE) sono utilizzati per apprendere rappresentazioni condivise che facilitano l'interazione reattiva tra umani e robot. Tecniche avanzate come il framework MoVEInt sfruttano i VAE combinati con Mixture Density Networks (MDN) per generare politiche multimodali in grado di adattare i movimenti del robot alle osservazioni umane. Questo approccio consente di catturare la complessità e la multimodalità delle interazioni dimostrate, migliorando l'adattabilità e la capacità del robot di rispondere in modo naturale e contestuale (Prasad et al., 2024). Inoltre, l'uso di modelli di diffusione come i DDPM consente una maggiore precisione nella simulazione di ambienti complessi, supportando le operazioni robotiche in scenari realistici (Ho et al., 2020). Parallelamente, l'intelligenza artificiale generativa sta trasformando profondamente il settore dei media e del marketing, rivoluzionando la creazione e la personalizzazione dei contenuti multimediali. Grazie a modelli avanzati, è possibile generare automaticamente video, musica e grafica altamente personalizzati, migliorando la scalabilità e l'impatto delle campagne pubblicitarie (Grewal et al., 2024). Uno degli aspetti più innovativi è la capacità della GenAI di supportare la personalizzazione delle esperienze utente in tempo reale, ottimizzando le strategie di marketing digitale. Ad esempio, la piattaforma SoMin.ai utilizza

profili di personalità multivisione e modelli generativi per creare contenuti che si adattano alle caratteristiche psicologiche degli utenti, aumentando l'*engagement* e le conversioni (Farseev et al., 2021). Questa evoluzione nel settore non solo migliora l'efficacia delle campagne di marketing, ma permette anche la creazione di contenuti pubblicitari mirati, rendendo il marketing digitale più preciso e reattivo alle esigenze del pubblico (Kshetri et al., 2024).

In ambito industriale, questa tecnologia sta trasformando il design e la produzione attraverso l'introduzione di sistemi generativi avanzati. Tecniche come i modelli di diffusione consentono di esplorare configurazioni progettuali che ottimizzano l'efficienza e riducono gli sprechi, contribuendo a design innovativi per strutture e componenti che soddisfano requisiti tecnici complessi (Li et al., 2024). Nel manufacturing intelligente, trova applicazione nell'ottimizzazione dei processi produttivi e nel miglioramento della sostenibilità. Come evidenziato da Akhtar (2024), l'IA generativa permette di ridurre i costi e migliorare la qualità dei prodotti attraverso l'automazione avanzata e il rilevamento in tempo reale dei difetti, promuovendo una maggiore efficienza e resilienza operativa. D'altra parte, Decardi-Nelson et al. (2024) sottolineano come i modelli generativi avanzati, combinati con tecniche di simulazione, siano fondamentali per prevedere comportamenti complessi nei processi produttivi, identificare anomalie e ottimizzare le prestazioni di sistema, riducendo l'impatto ambientale e i tempi di inattività.

Inoltre, la GenAI trova applicazione nella produzione additiva, dove modelli generativi ottimizzano la progettazione di componenti complessi e migliorano i processi di stampa 3D, aumentando la funzionalità e l'efficienza dei prodotti finali (Westphal e Seitz, 2024).

Le architetture generative stanno, inoltre, ridefinendo il panorama artistico attraverso strumenti avanzati per la creazione e la personalizzazione di contenuti visivi. Modelli come StyleDrop, integrati con sistemi di generazione testo-immagine, permettono di trasferire con precisione uno stile specifico a nuove immagini, catturando dettagli come schemi cromatici, texture e strutture globali a partire da un'unica immagine di riferimento. Questa capacità facilita l'esplorazione di nuovi linguaggi visivi e supporta la creazione di contenuti personalizzati per diverse applicazioni creative (Sohn et al., 2023).

Parallelamente, il metodo StyleAligned affronta una delle principali sfide nella generazione testo-immagine: garantire una coerenza stilistica tra diverse immagini generate. Attraverso l'uso condiviso dell'attenzione durante il processo di diffusione, StyleAligned mantiene un allineamento di stile tra immagini diverse, senza necessità di ottimizzazioni complesse. Questo approccio si rivela fondamentale per applicazioni artistiche e commerciali che richiedono una coerenza estetica su serie di immagini (Hertz et al., 2023). Anche il settore educativo è fortemente influenzato da questa innovazione tecnologica che può favorire percorsi di apprendimento sempre più personalizzati. Strumenti come chatbot e modelli linguistici avanzati migliorano l'accesso a risorse didattiche, offrendo assistenza interattiva e personalizzata agli studenti. Secondo Ray (2023), l'uso di chatbot basati su AI consente agli studenti di ricevere risposte immediate e pertinenti, contribuendo a colmare lacune linguistiche o di comprensione. Inoltre, come evidenziato da Wang et al. (2023), queste tecnologie sono fondamentali per supportare studenti internazionali, affrontando barriere culturali e linguistiche attraverso traduzioni contestuali e feedback personalizzati. Questi sviluppi rendono l'apprendimento più inclusivo, adattabile e accessibile a una vasta gamma di contesti educativi. Per quanto riguarda le applicazioni nel campo della sanità questa tecnologia sta trasformando il modo in cui vengono affrontate diagnosi e trattamenti, introducendo approcci più avanzati ed efficienti. Un esempio significativo è rappresentato dall'applicazione delle Deep Convolutional Generative Adversarial Networks (DCGAN) per generare immagini iperspettrali sintetiche di lesioni cutanee. Queste

immagini supportano la diagnosi del cancro della pelle, superando le limitazioni di dataset ridotti e migliorando l'accuratezza dei sistemi di classificazione basati su *deep learning* (La Salvia et al., 2022). Inoltre, la GenAI è impiegata nella scoperta di farmaci, accelerando la progettazione di molecole terapeutiche innovative e personalizzando i trattamenti medici per adattarli alle specifiche esigenze dei pazienti. Queste applicazioni non solo migliorano la qualità delle diagnosi e dei trattamenti, ma offrono strumenti avanzati per la simulazione e la pianificazione sanitaria, contribuendo a una medicina sempre più predittiva e personalizzata (Sengar et al., 2024).

Nel settore della scienza dei materiali, l'impiego di framework di apprendimento automatico, come le GAN, i VAE e i modelli di diffusione, ha notevolmente accelerato la scoperta e la progettazione di nuovi materiali. Queste tecniche permettono di generare e prevedere le proprietà dei materiali, accelerando l'esplorazione di combinazioni di materiali potenzialmente innovative che sarebbero difficilmente identificabili con i metodi tradizionali. Ad esempio, i modelli generativi facilitano i processi di progettazione inversa, integrando regole fisiche e tecniche di aumento dei dati per prevedere i comportamenti dei materiali e sintetizzare nuove strutture. Queste applicazioni non solo migliorano l'efficienza della ricerca sui materiali, ma forniscono anche soluzioni innovative per affrontare le sfide legate alla sostenibilità e alla creazione di materiali ad alte prestazioni (Liu et al., 2023).

Nel settore dell'ospitalità e del turismo, le architetture generative vengono utilizzate per migliorare l'esperienza del cliente attraverso la personalizzazione dei servizi e l'ottimizzazione delle operazioni logistiche, supportando decisioni strategiche e operative (Dwivedi et al., 2023.). Ad esempio, i chatbot basati su modelli generativi possono gestire prenotazioni, rispondere a richieste dei clienti e fornire raccomandazioni personalizzate, migliorando l'efficienza e la soddisfazione del cliente. Inoltre, la GenAI supporta la pianificazione di itinerari turistici personalizzati e la gestione dinamica delle risorse ospedaliere, aumentando l'efficacia operativa e la qualità del servizio.

In ambito finanziario, uno degli utilizzi della GenAI è il miglioramento dell'efficienza dei sistemi di rilevamento delle frodi, rendendoli più precisi e reattivi. Grazie alla capacità di generare dati sintetici, è possibile addestrare modelli di apprendimento automatico su dataset più ricchi e diversificati, superando le limitazioni delle fonti tradizionali. Ratner et al. (2016) introducono il concetto di *data programming*, una metodologia che consente la creazione rapida di dataset etichettati, applicabile per rafforzare i sistemi antifrode automatizzati. Inoltre, secondo Sengar et al. (2024), i modelli generativi possono simulare scenari di mercato complessi, offrendo agli analisti finanziari ambienti realistici per testare strategie di investimento e ottimizzare le decisioni, contribuendo a una gestione del rischio più efficace.

Nella sicurezza informatica, l'IA generativa svolge un ruolo fondamentale nella generazione di dati sintetici per addestrare modelli avanzati di rilevamento delle minacce. Questa tecnologia consente di simulare attacchi informatici realistici e di identificare vulnerabilità nelle infrastrutture di rete. Sengar et al. (2024) evidenziano che strumenti come le GAN possono creare scenari sintetici che aiutano le organizzazioni a migliorare le loro difese, rafforzando la resilienza dei sistemi informatici contro attacchi sempre più sofisticati.

Nel campo dell'ambiente e della sostenibilità, vengono impiegate simulazioni climatiche avanzate e strategie per la mitigazione dei cambiamenti climatici. Modelli come le reti generative avversarie e i modelli di diffusione permettono di creare dataset sintetici, migliorare le previsioni climatiche e ottimizzare l'uso di risorse naturali, come acqua ed energia, attraverso analisi e simulazioni avanzate (Liu et al., 2023). Questo approccio consente di accelerare la

scoperta di soluzioni sostenibili, migliorando la capacità di gestire scenari complessi di sfruttamento delle risorse.

Infine, nel settore del retail, la GenAI è utilizzata per personalizzare le esperienze di acquisto e ottimizzare la gestione delle scorte e dei layout dei negozi. Attraverso l'analisi avanzata dei dati comportamentali dei clienti, i modelli generativi possono suggerire configurazioni dei negozi che migliorano l'efficienza operativa e l'esperienza d'acquisto, massimizzando l'engagement dei consumatori e l'efficienza complessiva del sistema di vendita (Kshetri et al., 2024).

## 2.6 *Vantaggi e benefici dell'uso dell'IA generativa*

L'adozione globale dell'Intelligenza Artificiale (IA) e dei modelli generativi ha registrato una crescita significativa nell'ultimo anno, segnalando un cambiamento radicale rispetto al passato. Secondo il report di McKinsey & Company (2024), il 72% delle organizzazioni intervistate ha adottato l'IA in almeno una funzione aziendale, rispetto al 55% del 2023, con una crescita parallela nell'uso delle tecnologie generative, che raggiunge ora il 65% delle aziende. Inoltre, metà delle organizzazioni intervistate utilizza l'IA in almeno due o più funzioni aziendali, evidenziando un'integrazione sempre più ampia e strategica nelle operazioni quotidiane. Questa rapida diffusione è accompagnata da vantaggi concreti e misurabili. Le aziende che implementano queste tecnologie riportano significative riduzioni nei costi operativi e aumenti dei ricavi, specialmente nelle risorse umane, nella gestione della supply chain e dell'inventario. I benefici più significativi si osservano proprio in queste aree, con incrementi di ricavi superiori al 5%. Inoltre, molte organizzazioni riescono a mettere in produzione soluzioni di generative in tempi rapidi, generalmente tra uno e quattro mesi, dimostrando un notevole potenziale di efficienza e impatto strategico.

Uno dei benefici più importanti di questi modelli è la capacità di ottimizzare i cicli di progettazione e sviluppo. Gli strumenti generativi permettono di creare rapidamente prototipi, iterazioni e varianti, migliorando la velocità e la qualità dei processi produttivi. Ad esempio, funzionalità come Generative Fill di Adobe Firefly consentono agli utenti di sperimentare con idee e concetti utilizzando semplici comandi testuali, riducendo significativamente i tempi necessari per sviluppare nuovi prodotti. Inoltre, questa tecnologia fornisce supporto decisionale rapido e preciso, favorendo l'adozione di strumenti sofisticati anche da parte di utenti senza competenze tecniche avanzate (Accenture, 2024).

Un ulteriore vantaggio rilevante è la possibilità di creare ecosistemi di agenti IA. Questi sistemi, composti da reti di agenti intelligenti interconnessi, consentono di gestire intere fasi della catena del valore, automatizzando processi complessi e aumentando la produttività. Ad esempio, gli agenti IA possono rilevare difetti di produzione, gestire ordini e ottimizzare la distribuzione dei prodotti, abilitando modelli di "*lights-out manufacturing*". Questo approccio non solo riduce i costi operativi, ma consente anche di esplorare nuovi mercati e migliorare le interazioni con i clienti (Accenture, 2024).

Secondo il report di Deloitte del 2024 sullo stato dell'intelligenza artificiale generativa, l'adozione di sistemi generativi sta già mostrando benefici tangibili per molte organizzazioni a livello globale. In particolare, il 56% delle aziende intervistate identifica il miglioramento dell'efficienza e della produttività come il principale obiettivo a breve termine, mentre il 70% di quelle con un'elevata competenza in IA generativa ha registrato un miglioramento significativo nei prodotti e servizi offerti. Inoltre, il 63% ha osservato un aumento dell'innovazione e della crescita strategica, sottolineando il ruolo cruciale di questa tecnologia nel potenziare la

competitività aziendale. I risparmi ottenuti dalla sua implementazione vengono spesso reinvestiti in innovazione (45%) e miglioramenti operativi (43%), dimostrando un circolo virtuoso tra l'adozione tecnologica e l'espansione delle capacità organizzative.

Un altro dei grandi vantaggi dell'IA generativa è la capacità di arricchire i dataset con dati sintetici di alta qualità, riducendo la dipendenza da informazioni reali rare o costose. Tecnologie come le reti generative avversarie e i modelli di diffusione permettono di creare immagini fotorealistiche, sequenze audio realistiche e testi coerenti, ampliando la varietà di input per l'addestramento di modelli di apprendimento automatico (Kar et al., 2023).

Oltre a potenziare la generazione di dati, l'IA generativa consente di simulare scenari complessi, supportando la pianificazione strategica in diversi settori. Creando dati coerenti con varie condizioni operative, è possibile testare modifiche organizzative, strategie di approvvigionamento o processi di distribuzione senza impatti diretti sulle attività reali. Ad esempio, la capacità di simulare variazioni della domanda o dei costi delle materie prime contribuisce a migliorare la resilienza delle filiere produttive (Lee et al., 2014).

Infine, la tecnologia generativa riveste un ruolo strategico nella formazione e nella preparazione operativa. La possibilità di simulare condizioni specifiche aiuta non solo ad addestrare modelli avanzati, ma anche a formare operatori e tecnici ad affrontare scenari critici. Tecnologie come le GAN e i modelli di diffusione permettono di testare risposte a situazioni di emergenza o cambiamenti improvvisi, riducendo i rischi e migliorando il know-how interno (Noh et al., 2017; Reed et al., 2016). Questo approccio non solo ottimizza l'efficienza operativa e la capacità di risposta, ma favorisce anche un ciclo continuo di sperimentazione e innovazione, promuovendo soluzioni creative e scalabili.

## 2.7 *Limiti e sfide dell'IA generativa*

Nonostante il potenziale rivoluzionario, l'intelligenza artificiale generativa presenta sfide significative che ne ostacolano l'adozione sicura e affidabile.

Secondo il report McKinsey & Company del 2023, la preparazione aziendale per l'adozione diffusa dell'IA generativa e la gestione dei relativi rischi rimane limitata. Solo il 21% delle aziende intervistate dichiara di aver implementato politiche strutturate per regolamentare l'uso delle tecnologie generative da parte dei dipendenti, sottolineando la necessità di un approccio più responsabile e strategico all'implementazione di queste tecnologie.

Uno dei problemi principali riguarda le "allucinazioni," ovvero l'output di informazioni apparentemente plausibili ma errate o prive di fondamento. Studi recenti hanno identificato che tali fenomeni emergono da conflitti intrinseci nei modelli di apprendimento, dalla mancanza di aggiornamenti nei dati o dalla fusione di informazioni multimodali contrastanti (Wang et al., 2024). In particolare, le allucinazioni rappresentano un rischio elevato in settori critici come la sanità e la finanza, dove errori possono portare a gravi conseguenze operative. Per affrontare il problema, diverse strategie sono state sviluppate, tra cui l'uso di tecniche di apprendimento da feedback umano rinforzato (RLHF) e l'implementazione di meccanismi di controllo post-generazione per validare i risultati prodotti dai modelli (Bruno et al., 2023). Tuttavia, mitigare tali problemi resta una sfida, data la complessità intrinseca dei modelli di grande scala e la loro opacità operativa.

McKinsey & Company, nel report del 2024, sottolineano come l'inaffidabilità dell'output generato è considerata uno dei principali rischi associati all'adozione dell'IA generativa, con il 63% delle organizzazioni che lo identifica come una preoccupazione rilevante, un aumento del

7% rispetto al 2023. Tuttavia, solo il 38% delle aziende dichiara di avere in atto misure concrete per mitigarlo, evidenziando una lacuna significativa nella gestione del rischio, sebbene si registri un incremento del 6% rispetto all'anno precedente. Inoltre, quasi un quarto delle organizzazioni ha già sperimentato conseguenze negative legate all'inaffidabilità di questi modelli, dimostrando l'urgenza di strumenti di verifica e controllo più efficaci. La mancata risoluzione di questi problemi non solo limita l'impatto positivo della tecnologia, ma espone le aziende a rischi reputazionali, operativi e legali.

Un'altra sfida rilevante riguarda la sicurezza e la privacy dei dati. Secondo il report di KPMG (2024), il 79% delle organizzazioni identifica la cybersecurity come una priorità fondamentale, evidenziando il rischio di utilizzi malevoli o di violazioni legate alla GenAI. Inoltre, il 76% delle aziende segnala preoccupazioni significative riguardo alla privacy dei dati, specialmente quando si utilizzano fornitori terzi per le tecnologie generative. La trasparenza e la spiegabilità dei modelli, sottolineate nel report IBM (2024), rappresentano un ulteriore ostacolo, specialmente in settori regolamentati come la sanità e la finanza, dove è essenziale comprendere e giustificare le decisioni prese dall'IA per garantire conformità normativa e costruire fiducia tra utenti e stakeholder.

Sul piano etico e sociale, l'IA generativa può amplificare bias già presenti nei dati di addestramento, contribuendo a forme di discriminazione e riproducendo ingiustizie esistenti (Weidinger et al., 2021). Un'analisi di Deloitte (2024) evidenzia come la gestione dei bias sia ancora una sfida aperta per molte organizzazioni, con impatti significativi sulla percezione pubblica e sull'accettazione sociale della tecnologia. Inoltre, la sostenibilità ambientale rappresenta un limite crescente: l'addestramento e l'esecuzione di modelli generativi richiedono enormi risorse computazionali, contribuendo a un'impronta ecologica significativa. Accenture (2024) sottolinea come le organizzazioni debbano adottare strategie più sostenibili, bilanciando innovazione tecnologica ed efficienza energetica.

Infine, la dimensione normativa e regolatoria rappresenta una sfida complessa. La mancanza di standard globali per la regolamentazione della GenAI crea incertezze legali e operative per le aziende, obbligandole a navigare tra normative locali spesso frammentate e disomogenee (Feuerriegel et al., 2024). In particolare, il Regolamento sull'Intelligenza Artificiale dell'Unione Europea (AI Act) pone requisiti stringenti per garantire trasparenza, sicurezza e conformità normativa, ma evidenzia anche lacune nella gestione dei rischi specifici dei modelli generativi, come le "allucinazioni" o l'uso improprio dei dati (Novelli et al., 2024). Questa frammentazione normativa è aggravata dalla coesistenza di altri regolamenti, come il Product Liability Directive (PLD), che introduce ulteriori obblighi per i produttori, generando complessità operative per le organizzazioni che operano a livello internazionale. Questi elementi sottolineano l'urgenza di un quadro normativo globale che armonizzi le diverse legislazioni e promuova un approccio coerente alla regolamentazione della GenAI.

### 3. Approccio metodologico alla revisione della letteratura

In questo capitolo si illustra l'approccio metodologico adottato per condurre la revisione della letteratura sull'uso dell'intelligenza artificiale generativa (IA generativa) nel settore manifatturiero. La metodologia adottata per la revisione della letteratura mira a garantire rigore scientifico, trasparenza e replicabilità, elementi essenziali per ottenere una visione chiara e approfondita dell'utilizzo di questa tecnologia nel settore manifatturiero.

La revisione della letteratura non è solo uno strumento per sintetizzare le conoscenze esistenti, ma anche un metodo per identificare lacune e proporre nuove direzioni di ricerca. Snyder (2019) sottolinea che una revisione ben condotta offre una solida base per sviluppare conoscenza e teoria, riducendo la frammentazione delle ricerche. Il metodo utilizzato per questa revisione della letteratura si basa su principi di analisi sistematica, adattati per rispondere alla natura interdisciplinare e dinamica del tema dell'intelligenza artificiale generativa applicata al settore manifatturiero. Seguendo le linee guida consolidate di Snyder (2019), Torres-Carrion et al. (2018) e Paul e Criado (2020), è stato definito un protocollo di ricerca che include criteri trasparenti di inclusione ed esclusione, la selezione rigorosa delle fonti bibliografiche e l'integrazione di un approccio misto, combinando analisi quantitativa e qualitativa. L'analisi quantitativa è stata condotta attraverso tecniche bibliometriche, utilizzando strumenti come tabelle pivot per analizzare il numero di pubblicazioni per anno, le riviste e conferenze principali, gli autori più prolifici e la distribuzione geografica degli studi. Questo ha permesso di mappare l'evoluzione temporale e spaziale della ricerca, identificando i principali contributori e canali di diffusione del tema. Parallelamente, l'approccio qualitativo ha consentito di approfondire i contenuti degli articoli selezionati, individuando pattern tematici, sfide emergenti e implicazioni pratiche legate alle applicazioni dell'IA generativa nel settore manifatturiero. L'integrazione di queste due prospettive ha garantito una comprensione completa e strutturata del fenomeno, unendo la robustezza dei dati quantitativi alla ricchezza interpretativa dell'analisi qualitativa.

#### 3.1 *Obiettivi della revisione della letteratura*

Questa revisione della letteratura si propone di investigare le implicazioni dell'uso dell'intelligenza artificiale generativa nel settore manifatturiero, un ambito in rapida evoluzione che sta trasformando profondamente le dinamiche produttive e decisionali. A tal fine, sono stati definiti tre obiettivi specifici: indagare le principali applicazioni di questa tecnologia nel manifatturiero; analizzare i vantaggi e le maggiori difficoltà di adozione della GenAI; definire e dettagliare le principali tecnologie e modelli generativi studiati e utilizzati attualmente. Questi obiettivi sono stati definiti per garantire un'analisi organica e strutturata, che non solo esplori lo stato dell'arte delle tecnologie generative nel settore manifatturiero, ma identifichi anche eventuali lacune nella letteratura esistente. Inoltre, la revisione intende proporre nuove direzioni di ricerca, promuovendo un approccio critico e consapevole verso l'adozione di queste tecnologie in contesti industriali complessi.

##### 3.1.1 Applicazioni principali dell'IA generativa nel settore manifatturiero

Innanzitutto, questa revisione intende mappare le applicazioni pratiche delle tecnologie generative nel contesto industriale, identificando i casi d'uso più rilevanti. Tra gli ambiti di

applicazione considerati figurano il miglioramento dei processi produttivi, la generazione di dati sintetici per l'addestramento di modelli, la simulazione di processi produttivi e la produzione additiva. Particolare attenzione è rivolta anche all'integrazione dell'IA generativa nelle fasi di progettazione di nuovi prodotti e controllo qualità, due aspetti fondamentali per l'ottimizzazione dell'intero ciclo produttivo. Attraverso questa analisi, si mira a identificare le aree in cui queste tecnologie hanno il maggiore impatto e a comprendere come vengono adottate in contesti industriali differenti.

### 3.1.2 Benefici e sfide derivanti dall'utilizzo dell'IA generativa

Un altro obiettivo cruciale che ci si propone è quello di analizzare i principali benefici e le sfide connesse all'integrazione dell'intelligenza artificiale generativa nel settore manifatturiero. L'obiettivo è indagare come queste tecnologie possano migliorare la flessibilità produttiva, ottimizzare il design e la progettazione di nuovi prodotti, supportare la manutenzione predittiva e abilitare strategie di produzione più efficienti. Parallelamente, si intende esplorare le principali difficoltà di implementazione, tra cui la dipendenza dalla disponibilità e qualità dei dati, i costi computazionali elevati e le problematiche di integrazione con le infrastrutture esistenti. Un'attenzione particolare è dedicata anche alle resistenze organizzative e alla necessità di nuove competenze specialistiche per una piena adozione dell'IA generativa nel manifatturiero. Attraverso questa analisi, la revisione mira a fornire una panoramica sulle opportunità offerte da queste tecnologie e sulle sfide che le aziende devono affrontare per sfruttarne appieno il potenziale.

### 3.1.3 Tecnologie e modelli di IA generativa più utilizzati

La revisione, inoltre, si propone di fornire una panoramica dettagliata delle principali tecnologie e modelli di IA generativa attualmente in uso nel settore manifatturiero. Tra questi, particolare attenzione è rivolta alle Generative Adversarial Networks (GAN), ai modelli basati su trasformatori come GPT, e ai Variational Autoencoders (VAE), che stanno trovando applicazione in diverse aree produttive. Un aspetto emergente è l'integrazione di queste tecnologie con altre metodologie avanzate, come i *digital twin*, l'Industrial Internet of Things (IIoT) e le tecniche di ottimizzazione computazionale, che permettono di combinare simulazioni fisiche con l'apprendimento automatico per migliorare la precisione dei modelli predittivi e la gestione delle risorse produttive. Inoltre, le recenti evoluzioni della ricerca suggeriscono un crescente interesse verso i modelli generativi ibridi, che combinano diverse architetture per ottenere risultati più accurati e adattabili alle specifiche esigenze industriali.

L'obiettivo di questa revisione è comprendere quali modelli si siano dimostrati più efficaci nel rispondere alle esigenze specifiche del settore manifatturiero e quali tecnologie emergenti possano aprire nuove prospettive di sviluppo.

### 3.1.4 Obiettivi metodologici

La revisione adottata si propone di perseguire specifici obiettivi metodologici che garantiscano rigore e qualità nell'analisi della letteratura. Innanzitutto, è stata posta particolare enfasi sulla trasparenza, descrivendo in maniera dettagliata ogni fase del processo, dalla definizione delle parole chiave alla selezione delle fonti bibliografiche e dei criteri di inclusione ed esclusione.

Un ulteriore obiettivo è rappresentato dalla rilevanza, assicurando che gli studi selezionati siano strettamente legati all'applicazione dell'IA generativa nel contesto industriale e manifatturiero. Questo criterio guida il processo di selezione per evitare dispersioni e concentrare l'attenzione su contributi che possano apportare valore tangibile alla comprensione delle tecnologie generative in ambito produttivo. In tal senso, particolare attenzione è stata rivolta alla valutazione critica degli articoli per verificare che rispondessero alle finalità della revisione.

Infine, il metodo mira alla completezza, coprendo la letteratura scientifica più significativa, includendo articoli provenienti da diverse aree geografiche, conference proceedings e riviste di settore, entro l'orizzonte temporale stabilito. Tale completezza consente di ottenere una panoramica diversificata, integrando contributi teorici, studi empirici e casi applicativi per garantire una visione olistica dell'impatto dell'IA generativa nel settore manifatturiero.

L'analisi dei risultati si baserà su una lettura approfondita e qualitativa degli articoli selezionati, valutando aspetti metodologici, contenutistici e applicativi. Non verranno utilizzati strumenti avanzati per l'analisi di grandi dataset, come il *topic modeling*, poiché la revisione prevede un numero limitato di studi, permettendo così un'analisi più dettagliata e critica. Questo approccio consente di mettere in evidenza tendenze emergenti, lacune nella letteratura e potenziali direzioni di ricerca futura.

### 3.1.5 Struttura del processo di revisione

Il processo di revisione si articola in diverse fasi, basandosi sulle linee guida proposte da Snyder (2019) e Torres-Carrion et al. (2018). In primo luogo, viene definito un protocollo di ricerca che comprende la selezione delle banche dati, l'identificazione delle parole chiave e la definizione dei criteri di ricerca. Successivamente, si procede con uno screening preliminare, analizzando titoli e abstract per identificare gli articoli che affrontano direttamente il tema dell'IA generativa applicata al manufacturing. La fase successiva prevede una lettura integrale dei lavori più rilevanti, con una valutazione qualitativa per escludere eventuali articoli non pertinenti o di bassa qualità metodologica. Infine, i risultati vengono analizzati e sintetizzati attraverso tecniche bibliometriche o di analisi tematica, consentendo di individuare tendenze emergenti e lacune presenti nella letteratura.

La scelta di adottare un processo rigoroso di revisione risponde all'esigenza di fornire un quadro consolidato della ricerca sull'IA generativa nel settore manifatturiero. Questo approccio permette di comprendere le interconnessioni tra i diversi filoni di studio, riducendo al contempo la parzialità nella selezione degli articoli grazie all'adozione di criteri chiari e condivisi. Inoltre, consente di identificare con precisione le principali sfide e opportunità, come questioni legate alla qualità dei dati, ai limiti tecnologici e alle competenze richieste nelle aziende, offrendo una panoramica aggiornata e approfondita dello stato dell'arte ottenuti.

## 3.2 Criteri di selezione degli articoli scientifici

La presente sezione illustra la strategia di ricerca bibliografica e i relativi criteri di inclusione/esclusione adottati per individuare gli articoli pertinenti all'applicazione dell'intelligenza artificiale generativa nel settore manifatturiero. Come indicato da Snyder (2019) e Paul e Criado (2020), definire una procedura di selezione chiara e replicabile risulta essenziale per garantire la trasparenza metodologica.

### 3.2.1 Fonti di ricerca

Considerata la necessità di coprire un ampio spettro di studi ingegneristici e gestionali, la ricerca bibliografica è stata condotta principalmente sulla banca dati Scopus, ritenuta una delle risorse più complete e autorevoli per la letteratura scientifica di area tecnica e manageriale (Torres-Carrion et al., 2018). Scopus offre una copertura estesa e multidisciplinare, includendo articoli pubblicati su riviste peer-reviewed, atti di conferenza, capitoli di libri e altre fonti accademiche rilevanti, rendendola una scelta ideale per la revisione sistematica.

L'adozione di un'unica banca dati è stata motivata non solo dal suo elevato livello di copertura, ma anche dalla qualità delle fonti indicizzate, che garantisce l'accesso a contenuti scientifici validati attraverso rigorosi processi di revisione tra pari. Scopus, infatti, raccoglie contributi provenienti da diverse discipline, inclusi campi specifici come l'ingegneria industriale, la gestione dell'innovazione e l'intelligenza artificiale, fornendo una base ricca e diversificata per l'analisi. Inoltre, la sua interfaccia avanzata e le funzionalità di ricerca permettono di eseguire query complesse, applicare filtri tematici e temporali, e organizzare i risultati in modo sistematico. In aggiunta, la scelta di concentrare la ricerca su Scopus è stata supportata dalla necessità di mantenere un processo gestibile e replicabile, senza compromettere la qualità e la pertinenza degli articoli analizzati.

Infine, si sottolinea che la copertura multidisciplinare di Scopus consente di integrare studi provenienti da diverse aree geografiche e settori applicativi, favorendo una comprensione più completa e globale delle applicazioni dell'IA generativa nel contesto manifatturiero. La presenza di articoli pubblicati in riviste internazionali di alto impatto garantisce inoltre una panoramica aggiornata delle ricerche più rilevanti e innovative, contribuendo a tracciare le tendenze emergenti e le sfide future del settore.

### 3.2.2 Parole chiave utilizzate

La definizione delle parole chiave rappresenta una fase cruciale per garantire che la ricerca bibliografica sia mirata ed esaustiva, evitando al contempo l'inclusione di contributi non pertinenti. In questo studio, i termini utilizzati sono stati selezionati sulla base della loro ricorrenza nella letteratura esistente e della loro rilevanza per il tema dell'intelligenza artificiale generativa nel settore manifatturiero. La selezione delle parole chiave è stata guidata dai suggerimenti metodologici di Paul e Criado (2020), che sottolineano l'importanza di bilanciare specificità e ampiezza per catturare una gamma adeguata di studi rilevanti.

La query di ricerca è stata costruita utilizzando una combinazione di termini relativi all'IA generativa e alle sue applicazioni industriali. La formulazione della query è stata la seguente:

```
("Generative AI" OR "Generative Artificial Intelligence" OR "GANs" OR "ChatGPT") AND ("Manufacturing" OR "Industrial Applications")
```

Questa formulazione ha permesso di identificare studi che trattano sia aspetti generali delle tecnologie generative sia applicazioni specifiche in ambito produttivo.

Per affinare ulteriormente i risultati e garantire una maggiore pertinenza, sono stati applicati filtri specifici: in primo luogo, un filtro temporale e linguistico, limitando la ricerca agli anni 2018–2025 e selezionando esclusivamente articoli e atti di conferenza pubblicati in lingua inglese. Inoltre, per garantire la qualità e la rilevanza delle fonti, sono stati considerati

unicamente studi pubblicati su riviste accademiche o presentati in conferenze scientifiche. Questo approccio consente di focalizzarsi sull'evoluzione recente e rapida delle tecnologie generative, assicurando che i risultati siano aggiornati e allineati con le tendenze attuali.

La prima iterazione della ricerca ha prodotto 255 risultati, ma un'analisi preliminare dei titoli e degli abstract ha evidenziato che diversi contributi trattavano l'IA generativa in maniera tangenziale o si focalizzavano su contesti non pertinenti, come la sanità, l'istruzione o i social media. Per affrontare questo problema e rendere la ricerca più mirata, è stato introdotto un filtro di esclusione utilizzando la clausola "AND NOT" come segue:

AND NOT ( "Healthcare" OR "Education" OR "Social Media" ).

L'implementazione di questo ulteriore filtro ha consentito di ridurre il numero di articoli a 230 studi, eliminando quei contributi palesemente riferiti ad ambiti estranei al focus manifatturiero. Questo approccio è stato adottato per assicurare che la selezione iniziale fosse il più possibile coerente con gli obiettivi della revisione, evitando di sprecare risorse analizzando articoli che non offrivano valore diretto per la ricerca. Inoltre, la combinazione di termini generali (ad esempio, "Generative AI") con termini specifici relativi al manufacturing ha garantito una copertura adeguata di contributi sia teorici che pratici.

### 3.2.3 Criteri di inclusione

Parallelamente alla definizione delle query per la ricerca bibliografica, sono stati individuati e stabiliti criteri di inclusione specifici, pensati per garantire la coerenza con il protocollo di revisione descritto nei paragrafi precedenti. Questi criteri, fondamentali per la selezione degli articoli da analizzare, sono esposti di seguito.

1. Rilevanza tematica: gli articoli selezionati dovevano necessariamente fare riferimento in modo esplicito alle tecnologie di intelligenza artificiale generativa, includendo strumenti e metodologie come Generative Adversarial Networks (GAN), ChatGPT, modelli generativi di vario tipo e altre soluzioni affini. Inoltre, i lavori dovevano trattare applicazioni, implicazioni pratiche o prospettive future di queste tecnologie nel settore manifatturiero o industriale. Questo criterio ha permesso di focalizzare la ricerca su contributi scientifici che esplorano l'intersezione tra il progresso tecnologico dell'IA generativa e il contesto specifico della produzione industriale.
2. Ambito temporale: è stata definita una finestra temporale compresa tra il 2018 e il 2025. Questo periodo riflette l'evoluzione particolarmente rapida delle tecnologie legate all'IA generativa e include sia gli studi pionieristici in materia sia le più recenti pubblicazioni che potrebbero offrire una visione aggiornata e prospettica. L'inclusione di studi più datati è stata volutamente limitata per assicurare che i dati e le analisi risultassero attuali e rilevanti rispetto agli sviluppi tecnologici odierni.
3. Tipologia di pubblicazione: per garantire l'affidabilità e la qualità scientifica delle fonti, sono stati presi in considerazione unicamente articoli pubblicati su riviste peer-reviewed o atti di conferenze accademiche. Questo approccio è stato adottato per evitare contributi di natura non accademica o privi di un rigoroso processo di revisione da parte di esperti del settore. Le riviste e i procedimenti di conferenza

rappresentano, infatti, una garanzia in termini di robustezza metodologica e validità dei risultati.

4. **Lingua:** la ricerca si è concentrata esclusivamente su studi pubblicati in lingua inglese. Questa scelta è stata motivata dall'intento di favorire l'internazionalità delle fonti, assicurare una maggiore comparabilità tra i risultati e allinearsi con le migliori pratiche di revisione sistematica, come suggerito da Snyder (2019). La lingua inglese rappresenta infatti il principale veicolo di diffusione della ricerca scientifica a livello globale, specialmente in ambiti tecnologici.
5. **Accessibilità:** è stato infine considerato un criterio legato alla disponibilità degli articoli. Gli studi selezionati dovevano essere accessibili in full text tramite la piattaforma Scopus o attraverso abbonamenti istituzionali. Questo requisito è stato introdotto per garantire la possibilità di condurre un'analisi qualitativa approfondita, evitando limitazioni legate alla mancanza di accesso ai contenuti completi.

L'adozione di questi criteri di inclusione ha avuto lo scopo di circoscrivere il corpus degli articoli a quelli maggiormente rilevanti, autorevoli e accessibili, facilitando una revisione critica che rispetti gli standard metodologici e qualitativi richiesti.

#### 3.2.4 Processo di selezione e valutazione qualitativa

Il processo di selezione e valutazione qualitativa degli articoli è stato strutturato in diverse fasi, seguendo le linee guida raccomandate da Torres-Carrion et al. (2018) e Snyder (2019).

La prima fase ha riguardato uno screening preliminare: una volta applicata la query definitiva, comprensiva dei filtri e della clausola NOT, si è proceduto con l'analisi dei titoli e degli abstract di ciascun articolo individuato. Questo passaggio iniziale ha avuto l'obiettivo di identificare rapidamente gli articoli non pertinenti al focus specifico della ricerca, ovvero l'applicazione dell'IA generativa in ambito manifatturiero. È stato quindi possibile escludere contributi che si limitavano a trattare tematiche di machine learning generale, senza alcun riferimento a modelli generativi o alle loro applicazioni industriali. A seguito di questa fase, il numero degli articoli potenzialmente rilevanti è stato ridotto a 138.

Successivamente, è stata avviata la selezione finale degli articoli e la loro valutazione qualitativa. Gli articoli superstiti sono stati analizzati in maniera più approfondita, mediante una lettura integrale dei testi. In questa fase, si è posta particolare attenzione alla qualità metodologica degli studi, valutando specifici aspetti fondamentali. Tra questi, la chiarezza degli obiettivi dichiarati e la solidità del disegno di ricerca sono stati elementi chiave per identificare articoli che potessero offrire contributi significativi alla revisione. Inoltre, è stata verificata la coerenza del contenuto con il tema centrale della ricerca, ovvero l'utilizzo di tecnologie di IA generativa nel settore manifatturiero.

Durante questa seconda fase, alcuni articoli sono stati esclusi dopo una valutazione più dettagliata. Le ragioni dell'esclusione comprendevano, ad esempio, un focus su settori industriali diversi da quello manifatturiero, un utilizzo superficiale delle tecnologie di IA generativa o trattazioni teoriche prive di connessione con casi d'uso o implicazioni pratiche nel contesto produttivo. Inoltre, alcuni articoli sono stati esclusi in quanto non accessibili integralmente. In alcuni casi, infatti, gli articoli integrali erano disponibili solo a pagamento o risultavano inaccessibili tramite le risorse messe a disposizione dall'istituzione universitaria.

La selezione finale ha quindi consentito di ottenere un campione di 104 articoli che rappresentano la base per l'analisi bibliometrica e la discussione tematica, i cui dettagli verranno presentati nei Capitoli 4 e 5 della tesi.

Questo approccio, basato su una valutazione qualitativa manuale rigorosa, ha permesso di filtrare gli articoli realmente incentrati sulla tematica di interesse, garantendo coerenza e validità alla revisione. Tale metodologia ha avuto il duplice scopo di assicurare una base solida per l'analisi successiva e di minimizzare il rischio di includere contributi marginali o di scarso valore per la ricerca, rafforzando così la rilevanza scientifica dei risultati

### 3.3 *Strumenti e tecniche di analisi dei dati*

L'analisi dei dati e delle informazioni raccolte si è svolta principalmente in due fasi: la gestione dei riferimenti e la sintesi dei contenuti. Per queste attività è stato impiegato un approccio relativamente semplice ma efficace, basato sull'uso di Microsoft Excel.

#### 3.3.1 Gestione e organizzazione dei riferimenti

Dopo aver definito le query di ricerca ed estratto i risultati dalla banca dati Scopus, i riferimenti bibliografici (titolo, autori, abstract, anno di pubblicazione, rivista o conferenza, numero di citazioni, ecc.) sono stati importati o copiati in un foglio Excel. A ciascun articolo è stato assegnato un ID univoco per garantire la tracciabilità lungo l'intero processo di screening.

Nello stesso file sono state create colonne specifiche per annotare l'esito di ciascuna fase di selezione, tra cui:

- Valutazione preliminare (titolo/abstract: “incluso” / “escluso” / “dubbio”),
- Valutazione qualitativa (lettura full-text: “incluso” / “escluso”),
- Motivazione dell'esclusione (fuori tema, mancanza di contenuto metodologico, indisponibilità full-text, ecc.).

In questo modo, è stato possibile tenere traccia in modo sistematico di ogni decisione di inclusione o esclusione, garantendo trasparenza e replicabilità.

#### 3.3.2 Analisi preliminare e creazione di categorie tematiche

Successivamente, si è proceduto a una lettura più approfondita dei lavori inclusi al termine dello screening. Durante questa fase, all'interno di Excel sono state aggiunte ulteriori colonne per annotare le informazioni fondamentali che emergono dai testi, ad esempio:

- Ambito applicativo (ad es. controllo di qualità, produzione additiva, progettazione di prodotto, ecc.);
- Tecnologia/Modello di IA generativa (es. GAN, LMM, VAE, ecc.);
- Tipo di contributo (studio teorico, caso studio, modello sperimentale, framework concettuale, review);
- Contributo (una breve descrizione del contenuto e del valore aggiunto apportato dal documento).

Tali categorie hanno permesso di classificare in modo sistematico gli articoli, facilitando successivamente l'individuazione di trend e la sintesi dei risultati (Paul e Criado, 2020). Per esempio, tramite le funzioni di filtro e tabelle pivot di Excel, è stato possibile raggruppare e contare gli articoli in base alla tipologia di IA generativa, al sottosectore manifatturiero trattato, o al tipo di pubblicazione.

### 3.3.3 Sintesi e interpretazione qualitativa

La sintesi dei dati è stata condotta principalmente a livello descrittivo e qualitativo, date le finalità esplorative della tesi e il numero gestibile di articoli inclusi. In particolare: è stata realizzata una rilettura critica di ciascun articolo, alla ricerca di pattern ricorrenti (ad es. vantaggi, limiti, implicazioni pratiche) e di eventuali divergenze metodologiche o di risultati;

i contributi più significativi e i casi studio più interessanti sono stati annotati in note sintetiche o schede nel foglio Excel, evidenziando aspetti come la presenza di dati sperimentali, la dimensione del campione esaminato, o la robustezza della validazione dei risultati.

Questa fase qualitativa ha consentito di approfondire il ruolo giocato dall'IA generativa nel settore manifatturiero, individuando le applicazioni più diffuse (ad esempio, generazione di dati sintetici per il training di modelli, rilevazione di difetti di produzione, progettazione di prodotti industriali, ecc.) e le principali criticità emergenti (limiti tecnologici, richiesta di competenze specifiche, ecc.).

### 3.3.4 Esclusione di tecniche bibliometriche avanzate

Sebbene in altri contesti sia frequente l'utilizzo di software bibliometrici come VOSviewer o CitNetExplorer, che consentono di analizzare in modo approfondito le reti di citazioni e le connessioni tra autori e articoli, o di metodologie avanzate come il *text mining* e il *topic modeling*, in questo studio si è preferito adottare un metodo di analisi prevalentemente manuale. Questa scelta è stata motivata dalla natura esplorativa del lavoro, che punta a comprendere in modo qualitativo le principali tendenze, applicazioni e sfide legate all'IA generativa nel contesto manifatturiero, piuttosto che a elaborare una mappatura quantitativa o algoritmica delle pubblicazioni scientifiche disponibili.

Un ulteriore fattore determinante è stato il numero relativamente contenuto di articoli inclusi nella revisione, che ha reso l'analisi qualitativa gestibile senza la necessità di ricorrere a strumenti avanzati o modelli statistici complessi. L'impiego di Excel, con le sue funzionalità di organizzazione e codifica dei dati, è risultato adeguato a classificare i contributi in base ai macrotemi individuati. Questa soluzione ha permesso di condurre un'analisi strutturata ma al tempo stesso flessibile, utile per esaminare i dettagli specifici di ciascun articolo senza perdere di vista il quadro generale.

Un altro motivo per questa scelta risiede nell'esigenza di mantenere il focus sulla comprensione profonda e qualitativa dei contenuti piuttosto che sulla mera identificazione di schemi quantitativi. L'approccio manuale ha permesso di esaminare attentamente i contenuti degli articoli, concentrandosi sugli aspetti chiave e sui dettagli rilevanti che avrebbero potuto essere trascurati da un'analisi automatizzata, specialmente in un campo relativamente giovane e interdisciplinare come quello dell'IA generativa.

Infine, come suggerito da Snyder (2019), in contesti esplorativi o in cui il volume di articoli è limitato, è spesso più efficace privilegiare approcci che garantiscano un'interpretazione critica e un contatto diretto con i dati piuttosto che affidarsi esclusivamente a strumenti automatizzati. Sebbene l'utilizzo di software avanzati rimanga una risorsa preziosa per analisi su larga scala o altamente quantitative, il metodo adottato per questa revisione risponde in modo più coerente alle esigenze specifiche dello studio, garantendo al contempo trasparenza e replicabilità nel processo di analisi.

### 3.4 *Limiti metodologici e considerazioni*

Nel presente paragrafo si discuteranno i principali limiti metodologici, legati sia alle scelte di design della ricerca sia alle tecniche di analisi impiegate.

#### 3.4.1 Selezione di un'unica banca dati

Il principale limite metodologico di questa revisione riguarda l'impiego di una sola banca dati, ovvero Scopus, come fonte principale per l'identificazione dei contributi scientifici. Sebbene Scopus rappresenti una delle piattaforme più ampie e multidisciplinari disponibili, con una copertura significativa di articoli, conferenze e capitoli di libri, l'esclusione di altre risorse rilevanti potrebbe aver determinato una parziale perdita di informazioni. La scelta di utilizzare una sola piattaforma di ricerca si basa principalmente su ragioni di praticità e sulla necessità di mantenere il processo gestibile, ma comporta il rischio che alcuni articoli significativi, pubblicati su riviste non indicizzate in Scopus o indicizzate in modo incompleto, siano stati esclusi.

Questo rischio è noto nella letteratura come *publication bias* e può portare a una rappresentazione parziale dello stato dell'arte. Ad esempio, alcune riviste emergenti o specializzate in ambiti specifici del manufacturing e dell'intelligenza artificiale generativa potrebbero non essere adeguatamente rappresentate in Scopus, con il risultato che certe prospettive o approcci innovativi restano fuori dal perimetro dell'analisi. Inoltre, l'assenza di una triangolazione con altre banche dati potrebbe ridurre l'eterogeneità dei risultati, limitando la varietà degli approcci, delle metodologie e dei contesti studiati.

Sarebbe quindi auspicabile, in ricerche future, integrare i risultati ottenuti attraverso Scopus con quelli di altre piattaforme, sia generali che specifiche.

#### 3.4.2 Restrizioni di lingua e periodo

Un ulteriore aspetto critico riguarda le restrizioni applicate sia alla lingua dei contributi che all'intervallo temporale considerato. In particolare, questa revisione si è limitata agli articoli redatti in lingua inglese e pubblicati nel periodo compreso tra il 2018 e il 2025. Tale scelta è stata motivata dall'esigenza di concentrarsi sulle ricerche più recenti e maggiormente rilevanti a livello internazionale, in quanto l'inglese rappresenta la lingua dominante nelle pubblicazioni scientifiche di settore, e l'intervallo temporale selezionato consente di analizzare lavori aggiornati e pertinenti in un campo in rapida evoluzione come quello dell'intelligenza artificiale generativa.

Tuttavia, è necessario riconoscere che queste restrizioni potrebbero aver escluso contributi altrettanto significativi. Studi redatti in altre lingue, come l'italiano, il tedesco o il cinese, possono offrire prospettive specifiche o dati empirici rilevanti per determinati contesti geografici o settori industriali, ma non sono stati inclusi a causa delle limitazioni linguistiche. Inoltre, alcune ricerche pubblicate prima del 2018 potrebbero fornire informazioni utili per comprendere meglio l'evoluzione storica e teorica delle tecnologie di IA generativa applicate al manufacturing, ma sono state escluse per garantire che la revisione fosse incentrata su contributi aggiornati e strettamente legati agli sviluppi più recenti. Le limitazioni temporali, sebbene giustificate dalla necessità di mantenere la revisione focalizzata e gestibile, possono comportare il rischio di trascurare alcune applicazioni pionieristiche o concettualizzazioni iniziali che potrebbero essere state sviluppate prima del 2018.

Per mitigare tali limiti, futuri studi potrebbero adottare un approccio più inclusivo, estendendo la ricerca a contributi pubblicati in diverse lingue e ampliando l'intervallo temporale per includere anche articoli antecedenti al 2018. In alternativa, un'analisi mirata di letteratura in lingue specifiche, o su periodi più ampi, potrebbe integrare i risultati di questa revisione, arricchendo ulteriormente la comprensione dell'impatto e delle applicazioni dell'IA generativa nel settore manifatturiero

### 3.4.3 Approccio manuale e assenza di strumenti bibliometrici avanzati

La decisione di adottare un approccio manuale per la gestione dei dati e l'analisi, basato principalmente sull'uso di Excel, offre alcuni vantaggi legati al controllo diretto e alla possibilità di classificare e analizzare gli articoli con un grado elevato di personalizzazione. Questo approccio permette di prendere in considerazione elementi qualitativi e sfumature che spesso sfuggono agli strumenti automatizzati, come l'identificazione di contesti particolarmente rilevanti o l'interpretazione di contributi teorici e applicativi con attenzione ai dettagli. Tuttavia, questa scelta presenta alcune limitazioni, specialmente quando il numero di articoli da analizzare è elevato, rendendo meno efficiente e scalabile il processo di analisi (Paul e Criado, 2020).

L'assenza di tecniche avanzate, come quelle offerte dai software bibliometrici o dagli strumenti di *text mining* e *topic modeling*, limita la capacità di ottenere una visione quantitativa e sintetica delle connessioni esistenti tra autori, riviste e tematiche. Tali strumenti consentono infatti di mappare le reti di citazione e identificare cluster tematici o tendenze emergenti, fornendo un quadro d'insieme più sistematico. Inoltre, queste tecniche potrebbero essere utili per individuare automaticamente i temi ricorrenti all'interno della letteratura, riducendo il rischio di bias interpretativi.

In questo contesto, il ricorso a Excel per la gestione dei dati, pur funzionale in termini di semplicità e accessibilità, potrebbe non essere sufficiente per affrontare l'analisi di un numero crescente di contributi, soprattutto in un settore in rapida crescita come quello dell'IA generativa. In futuro, sarebbe auspicabile integrare l'approccio manuale con strumenti più sofisticati, al fine di ampliare la portata dell'analisi e rendere i risultati più completi e affidabili. Un approccio misto, che combini l'analisi manuale con tecnologie automatizzate, potrebbe rappresentare un compromesso ideale per bilanciare controllo qualitativo e rigore quantitativo.

### 3.4.4 Possibile incompletezza dei risultati

Nonostante l'adozione di una strategia di ricerca ben definita, basata su parole chiave mirate e sull'utilizzo della clausola "NOT" per escludere contesti non pertinenti, esiste il rischio di non catturare tutti i contributi rilevanti. Questo limite è intrinseco a qualsiasi strategia basata sulle keyword, poiché i termini utilizzati dai ricercatori per descrivere le tecnologie o le applicazioni dell'IA generativa possono variare significativamente. Ad esempio, alcune pubblicazioni potrebbero utilizzare terminologie alternative o più specifiche per riferirsi a concetti correlati, come "reti neurali profonde" o "sistemi generativi avanzati", senza menzionare esplicitamente l'IA generativa. Analogamente, lavori che trattano applicazioni nel settore manifatturiero potrebbero non esplicitare chiaramente il contesto produttivo, rendendo più difficile l'identificazione attraverso una ricerca basata esclusivamente su parole chiave.

Questa incompletezza è amplificata dalla natura interdisciplinare e in rapida evoluzione del settore. L'IA generativa, infatti, è oggetto di interesse non solo in ambito industriale, ma anche in settori come il design, la robotica e la simulazione, che potrebbero offrire spunti utili ma non

essere inclusi se i termini specifici di ricerca non coincidono con quelli adottati. Inoltre, l'elevata varietà di terminologie utilizzate nei diversi ambiti disciplinari rende più complesso garantire l'eshaustività dei risultati, soprattutto quando si esplorano campi emergenti e non ancora consolidati.

Un ulteriore elemento di criticità è rappresentato dal rischio di omissioni dovute alla mancata indicizzazione completa di alcuni articoli nelle banche dati. Nonostante la definizione di criteri stringenti per la selezione degli studi e l'impiego di clausole per escludere contesti non pertinenti, non è possibile escludere del tutto la possibilità che alcuni contributi rilevanti siano stati trascurati. Questo è particolarmente vero per studi pionieristici o pubblicazioni su riviste meno note o non ancora pienamente indicizzate.

Per mitigare questo limite, futuri studi potrebbero adottare una strategia più ampia, includendo sinonimi o termini correlati durante la definizione delle keyword e utilizzando tecniche avanzate come l'analisi semantica o l'intelligenza artificiale per identificare automaticamente i contributi pertinenti. Inoltre, una validazione incrociata tra più banche dati potrebbe contribuire a ridurre il rischio di omissioni, aumentando la completezza dei risultati e garantendo una visione più rappresentativa dello stato dell'arte.

#### 3.4.5 Bias di selezione ed eterogeneità della letteratura

Infine, è importante evidenziare che la valutazione qualitativa manuale, pur essendo guidata da criteri di inclusione ed esclusione chiaramente definiti, è inevitabilmente influenzata dal giudizio del ricercatore. Nonostante gli sforzi per garantire un approccio il più possibile oggettivo e trasparente, una certa dose di soggettività è intrinseca al processo di interpretazione dei contenuti e all'assegnazione delle categorie tematiche (Paul e Criado, 2020). Questo rischio si manifesta soprattutto nella classificazione degli articoli che trattano più tematiche simultaneamente o che si collocano ai confini di uno specifico ambito di applicazione.

In aggiunta, l'eterogeneità della letteratura su un tema emergente come l'IA generativa applicata al manufacturing costituisce un'ulteriore sfida. La varietà di approcci, che spazia da ricerche sperimentali e studi empirici a proposte teoriche e overview di settore, rende complessa una standardizzazione completa dei criteri di valutazione e aumenta il rischio che alcuni contributi vengano interpretati in modo diverso in base al loro contesto o alla loro metodologia. Ad esempio, gli articoli che descrivono applicazioni pratiche potrebbero essere valutati diversamente rispetto a quelli che si concentrano su prospettive teoriche o su innovazioni tecnologiche di carattere generale.

Questa eterogeneità è ulteriormente accentuata dal fatto che l'IA generativa è un campo interdisciplinare, che coinvolge discipline diverse come l'intelligenza artificiale, l'ingegneria industriale, l'economia e il design. Ogni disciplina adotta approcci, terminologie e metodi distinti, rendendo difficile la costruzione di un quadro uniforme e comparabile. Per mitigare il rischio di bias di selezione, sarebbe utile prevedere, in futuri studi, una revisione incrociata tra più ricercatori o l'uso di strumenti standardizzati per codificare e analizzare i contributi, garantendo una maggiore uniformità nell'interpretazione dei risultati.

In definitiva, benché la metodologia adottata sia stata progettata per minimizzare il bias e gestire la complessità della letteratura, è necessario riconoscere che l'eterogeneità intrinseca del tema e il ruolo del giudizio umano rappresentano limiti inevitabili, che potrebbero influire sull'uniformità e sulla generalizzabilità delle conclusioni.

### 3.4.6 Considerazioni conclusive sui limiti metodologici

I limiti metodologici individuati nella revisione della letteratura rappresentano un elemento cruciale per comprendere la portata e le implicazioni dello studio condotto. L'adozione di una singola banca dati, la restrizione linguistica e temporale, l'utilizzo di un approccio prevalentemente manuale e la possibilità di omissioni nei risultati evidenziano come la complessità dell'argomento richieda un continuo bilanciamento tra rigore metodologico e praticità operativa. Questi vincoli, sebbene inevitabili in un contesto esplorativo come quello in esame, non invalidano la validità generale della ricerca, ma sottolineano aree che necessitano di approfondimenti futuri per garantire un quadro sempre più completo e rappresentativo dello stato dell'arte.

Un aspetto di particolare rilievo è costituito dall'interdisciplinarietà e dalla natura emergente del tema, che comportano un'eterogeneità delle fonti e delle metodologie analizzate. Questa caratteristica rende particolarmente complesso il tentativo di standardizzare i criteri di selezione e valutazione della letteratura, lasciando spazio a un inevitabile grado di soggettività. Tuttavia, ciò rappresenta anche una fonte di ricchezza, permettendo di cogliere la diversità di approcci e prospettive che caratterizzano un campo in rapida evoluzione come quello dell'intelligenza artificiale generativa applicata al manufacturing.

Questi limiti trovano un'importante evoluzione nel passaggio al capitolo successivo, dedicato all'analisi bibliometrica. Se, da un lato, le criticità metodologiche hanno influenzato la fase di revisione della letteratura, dall'altro rappresentano il punto di partenza per un'indagine quantitativa più strutturata e sistematica. Il capitolo 4 si propone infatti un'analisi quantitativa dei dati bibliografici raccolti, esplorando le dinamiche temporali, geografiche, disciplinari e tecnologiche della produzione scientifica relativa all'IA generativa nel manufacturing.

In questo senso, l'analisi bibliometrica rappresenta non solo un complemento alla revisione della letteratura, ma anche un tentativo di superare alcune delle limitazioni evidenziate nel presente capitolo. Attraverso l'impiego di tecniche di analisi dei dati, il capitolo successivo si pone l'obiettivo di fornire una panoramica più ampia e articolata delle tendenze emergenti. Tale approccio non mira a compensare integralmente i limiti metodologici, ma intende offrire un quadro d'insieme che, unito all'analisi qualitativa, consenta di delineare con maggiore precisione lo stato dell'arte e le prospettive future.

## 4. Analisi bibliometrica

Il presente capitolo è dedicato all'analisi bibliometrica dei contributi selezionati durante la fase di revisione sistematica, con l'obiettivo di delineare un quadro quantitativo e descrittivo della produzione scientifica sull'intelligenza artificiale generativa applicata al settore manifatturiero. Sebbene lo studio si inserisca in un contesto metodologico più ampio, in cui le tecniche di ricerca e selezione della letteratura sono già state illustrate, qui ci si concentra specificamente sul “dove, quando e come” tali studi sono stati pubblicati, nonché su “chi” siano gli autori più attivi o sul “quali” tecnologie generative siano state effettivamente prese in riferimento. L'analisi bibliometrica rappresenta un passaggio fondamentale per comprendere le tendenze emergenti della disciplina, individuare i filoni di ricerca predominanti e offrire indicazioni sulla maturità del campo di studi.

Per condurre un'analisi bibliometrica rigorosa e strutturata, i dati raccolti sono stati elaborati attraverso l'uso di tabelle pivot, che hanno consentito di organizzare e sintetizzare le informazioni estratte dagli articoli selezionati. Questa tecnica si è rivelata essenziale per identificare le principali tendenze nella produzione scientifica, permettendo di aggregare i dati secondo diverse dimensioni di interesse, quali l'evoluzione cronologica delle pubblicazioni, le sedi editoriali, la distribuzione geografica della ricerca, gli autori più attivi e le tecnologie generative maggiormente studiate. L'applicazione delle tabelle pivot ha permesso di strutturare l'analisi in modo sistematico, agevolando il confronto tra variabili e facilitando l'individuazione di schemi ricorrenti o discrepanze significative. Attraverso l'impiego di filtri e funzioni di aggregazione, è stato possibile ottenere una visione dettagliata e comparativa delle pubblicazioni, consentendo di trasformare un ampio corpus di dati grezzi in indicatori chiave utili per interpretare l'evoluzione del dibattito scientifico.

Nelle pagine seguenti si approfondisce, dunque, dapprima la quantità di articoli anno per anno, per evidenziare come la ricerca sia progredita e in quali momenti storici si siano intensificati gli studi. Successivamente, vengono analizzate le riviste e le conferenze in cui i contributi sono stati pubblicati, così da comprendere la diffusione disciplinare del tema. Un terzo aspetto, altrettanto rilevante, riguarda gli autori e i contributori principali, in cui si focalizza l'attenzione su eventuali punte di eccellenza o nuclei di ricerca fortemente coesi. Si passa poi alla distribuzione per paese, utile per interpretare la geografia della produzione scientifica in relazione ai contesti industriali e di ricerca. Infine, si esamina la tipologia di tecnologie generative maggiormente rappresentate negli studi, approfondendo la presenza di modelli come le Generative Adversarial Networks (GAN), i Large Language Models (LLM) o i Variational Autoencoders (VAE).

Questa disamina bibliometrica consente dunque di collocare gli articoli selezionati in uno scenario globale, mostrando come la ricerca sull'IA generativa in ambito manifatturiero sia evoluta e dove si stiano concentrando gli sforzi di studiosi e professionisti. I risultati qui illustrati costituiscono il preludio all'analisi qualitativa e tematica sviluppata nei capitoli successivi, in cui verranno evidenziate con maggiore dettaglio le aree di applicazione, le sfide tecniche e le opportunità di sviluppo di queste tecnologie nel mondo manifatturiero.

### 4.1 *Numero di pubblicazioni per anno*

La prima dimensione considerata riguarda la distribuzione delle pubblicazioni nel periodo 2019–2025. Sebbene i criteri di inclusione fossero stati impostati per coprire il periodo 2018–

2025, nessun contributo del 2018 è stato selezionato durante l'analisi di inclusione dei documenti. Questo risultato può essere attribuito alla limitata disponibilità di articoli pertinenti pubblicati in quell'anno, che riflette probabilmente una fase ancora embrionale dello sviluppo e dell'applicazione dell'IA generativa nel settore manifatturiero. Di conseguenza, l'analisi grafica (Figura 4.1) inizia dal 2019, anno in cui si osservano i primi contributi significativi.

Dall'osservazione del grafico emerge una presenza inizialmente contenuta di studi tra il 2019 e il 2020, corrispondente a una fase ancora primordiale per le applicazioni dell'IA generativa in ambito manifatturiero. Nel 2021 si registra un leggero incremento, che conferma un graduale consolidamento dell'interesse verso queste tecnologie, seppur i valori rimangano relativamente modesti rispetto agli anni successivi. Il trend appare più marcato a partire dal 2022, momento in cui si assiste a un aumento tangibile di articoli, potenzialmente riconducibile alla maggiore diffusione delle Generative Adversarial Networks (GAN) e di modelli come GPT, che hanno iniziato a suscitare l'interesse di diverse comunità scientifiche e industriali. Nel 2023 la crescita sembra proseguire, suggerendo che gli studi si stiano progressivamente diversificando e integrando con ricerche più applicative, volte a dimostrare l'efficacia delle soluzioni generative in contesti produttivi reali.

Il picco più rilevante si osserva nel 2024, anno per il quale sono già disponibili un numero consistente di contributi, superiore a quello di qualsiasi altro periodo considerato. Tale risultato potrebbe riflettere sia l'eco di ricerche avviate negli anni precedenti, sia l'accelerazione nello sviluppo di sistemi generativi più avanzati, in grado di risolvere problematiche complesse legate per esempio alla progettazione, al controllo qualità e alla manutenzione predittiva. Infine, il dato parziale relativo al 2025, considerato il momento della ricerca (fine 2024 e gennaio 2025), riflette inevitabilmente la limitata indicizzazione di pubblicazioni più recenti.

Nel complesso, l'analisi cronologica indica un crescente interesse accademico e industriale verso l'uso di soluzioni generative in ambito manifatturiero, con un'espansione più marcata negli ultimi due-tre anni. Questo andamento temporale rispecchia la rapida evoluzione della disciplina, sospinta dai continui progressi nel campo del *deep learning* e dalla crescente disponibilità di dati industriali su cui addestrare modelli generativi.

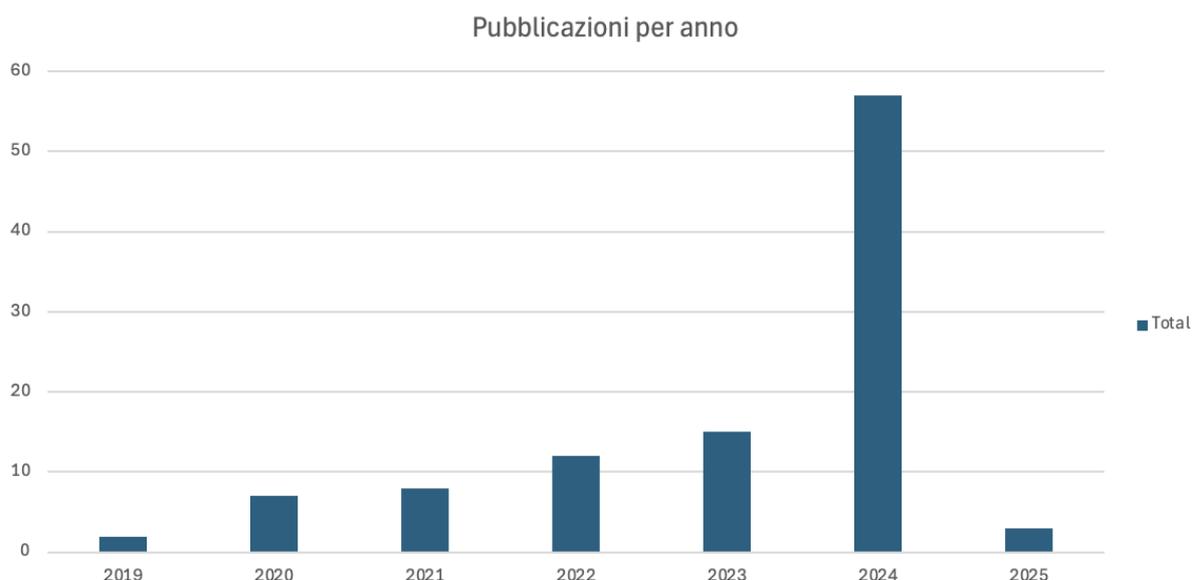


Figura 4.1: Andamento delle pubblicazioni annuali (2019-2025)

## 4.2 Riviste e conferenze principali

La seconda dimensione analizzata riguarda le sedi di pubblicazione (Figura 4.2), ovvero le riviste e le conferenze che hanno accolto gli articoli inclusi nella revisione. I dati raccolti mostrano una varietà di canali editoriali, a testimonianza del carattere interdisciplinare della ricerca sull'IA generativa applicata al manufacturing. Si osserva la presenza di atti di conferenza specializzate nel settore dell'automazione industriale e della produzione intelligente, nonché di riviste accademiche che spaziano dall'ingegneria gestionale all'informatica applicata.

Tra le sedi più frequenti compare IFAC-PapersOnLine, che rappresenta un punto di riferimento consolidato per contributi relativi al controllo dei processi, all'automazione e all'ottimizzazione industriale. Segue Applied Sciences (Switzerland), rivista multidisciplinare che accoglie ricerche inerenti numerose aree ingegneristiche, compresa l'automazione dei processi produttivi. Anche la International Journal of Advanced Manufacturing Technology registra un buon numero di pubblicazioni, in linea con il suo orientamento verso l'innovazione produttiva e l'adozione di tecniche computazionali avanzate.

Altre sedi, come IEEE Access o i procedimenti di conferenze quali la Advanced Semiconductor Manufacturing Conference (ASMC), evidenziano un interesse specifico per settori ad alto contenuto tecnologico, come la microelettronica e la gestione dei processi di produzione di semiconduttori. La presenza di testate più orientate all'informatica industriale, come Big Data and Cognitive Computing, conferma la rilevanza delle tecniche generative in un panorama in cui l'analisi e la generazione di dati costituiscono un aspetto chiave per il miglioramento continuo dei processi.

Questo insieme eterogeneo di sedi di pubblicazione riflette, dunque, la natura trasversale del tema e suggerisce che l'IA generativa stia attirando l'attenzione di comunità scientifiche molto diverse, unite dall'interesse per l'automazione dei processi e l'innovazione tecnologica nelle linee di produzione.

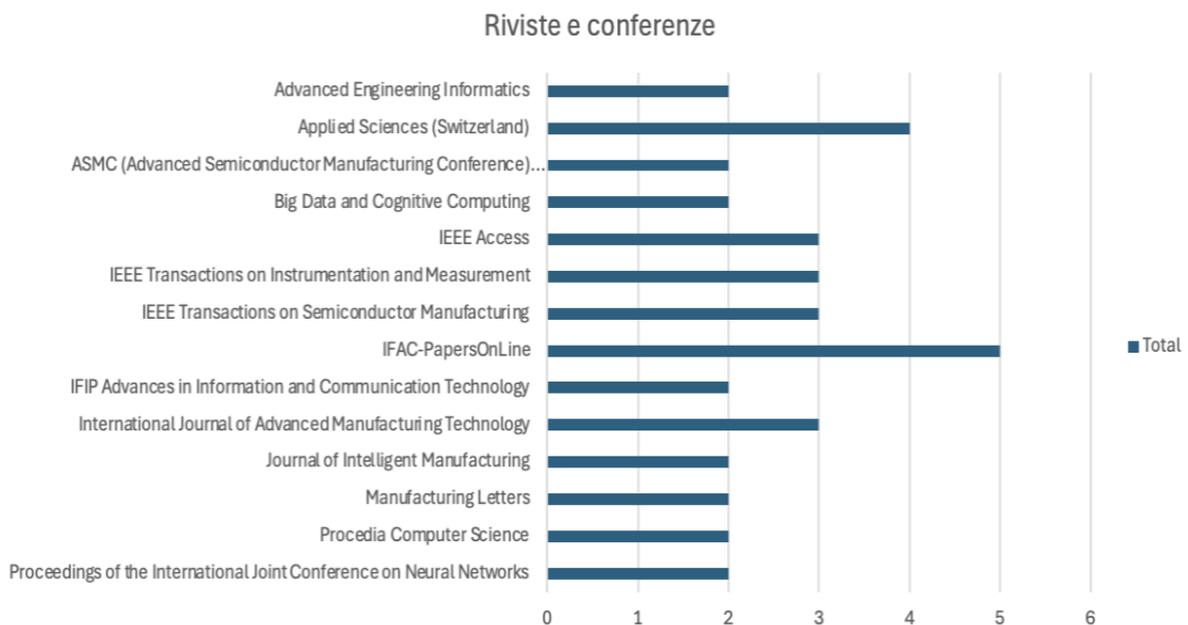


Figura 4.2: Distribuzione delle pubblicazioni per riviste e conferenze

### 4.3 *Autori e contributori principali*

La terza dimensione d'interesse riguarda l'analisi degli autori più prolifici in tema di Intelligenza Artificiale generativa applicata al settore manifatturiero. Dall'osservazione dei dati rappresentati nella Figura 4.3 emerge che la maggior parte dei ricercatori conta uno o due contributi ciascuno, a sottolineare come questa linea di ricerca, pur in crescita, risulti ancora frammentata tra diversi gruppi e istituzioni.

L'analisi del numero di pubblicazioni per autore mette in rilievo un piccolo gruppo di studiosi che si distingue rispetto alla maggioranza, poiché ciascuno di essi risulta coautore di due articoli anziché di uno solo. In particolare, George Lăzăroiu, Tom Gedeon, Katarina Valaskova, Jakub Horák, Katarina Zvarikova e Marek Nagy hanno pubblicato assieme due contributi di natura teorica, volti a esplorare tematiche quali il *digital twin*, l'*extended reality*, la simulazione di processi basata su agenti e, soprattutto, l'uso di tecnologie di Intelligenza Artificiale generativa in relazione ai sistemi di produzione e all'industria del futuro. Entrambi gli studi approfondiscono aspetti inerenti alla costruzione di un "*immersive industrial metaverse*" e la convergenza tra Internet of Robotic Things (IoRT), algoritmi di produzione e tecnologie di mercato, delineando possibili implicazioni economiche e organizzative. La circostanza che questi sei autori abbiano partecipato alle stesse pubblicazioni testimonia l'esistenza di un nucleo di ricerca coeso, concentrato su uno specifico insieme di argomenti. Sebbene ciò non indichi necessariamente che ciascun ricercatore non svolga altre attività di ricerca indipendenti, suggerisce tuttavia una stretta collaborazione mirata ad approfondire l'interconnessione tra sistemi cyber-fisici, realtà immersiva e IA generativa applicata al manufacturing. Il fatto che i lavori in questione siano di carattere teorico conferma la volontà di fornire un quadro concettuale solido, idoneo a orientare futuri sviluppi sia in ambito sperimentale sia in contesti industriali concreti.

Questo scenario suggerisce una comunità scientifica in fase di consolidamento, in cui poche figure iniziano a emergere come punti di riferimento sul tema. È plausibile ritenere che tali autori operino in università o centri di ricerca particolarmente focalizzati sulla convergenza tra intelligenza artificiale e processi industriali, condividendo spesso collaborazioni con partner industriali o altri atenei. Il fatto che la maggior parte dei contributi sia firmata da autori distinti, talvolta provenienti da diversi contesti geografici e disciplinari, evidenzia la vocazione multidisciplinare del settore e la presenza di un potenziale di crescita verso collaborazioni sempre più internazionali.

Lo spazio ancora relativamente aperto per nuovi studi e per la creazione di ulteriori gruppi di ricerca potrebbe favorire, nei prossimi anni, l'emergere di nuovi autori di riferimento, che potrebbero consolidare la letteratura e renderne più visibile l'evoluzione. La mappatura degli autori suggerisce quindi una linea di ricerca ancora giovane, nella quale i contributori attivi possono assumere rapidamente un ruolo di leadership scientifica.

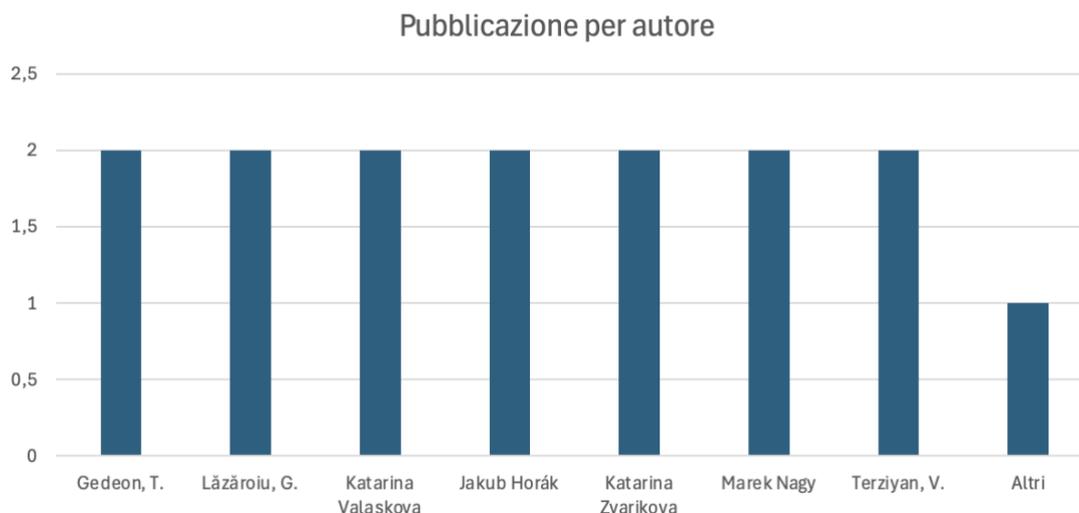


Figura 4.3: Distribuzione delle pubblicazioni per autore

#### 4.4 *Distribuzione delle pubblicazioni per paese*

Un'altra dimensione della presente analisi bibliometrica prende in esame la distribuzione geografica degli studi. Complessivamente, il numero di paesi coinvolti nella ricerca è pari a 41, ma la maggior parte di essi presenta solo uno o due studi. Per questo motivo, si è scelto di rappresentare principalmente i paesi con un numero più significativo di pubblicazioni, in modo da evidenziare le principali tendenze e i centri di eccellenza in questo ambito.

La distribuzione dei dati rappresentati nella Figura 4.4 mostra un quadro in cui alcuni paesi emergono con un numero di contributi significativamente superiore rispetto ad altri, rivelando centri di eccellenza e interessi di ricerca mirati. Tra questi, spiccano la Cina e gli Stati Uniti, che presentano il maggior numero di pubblicazioni e sottolineano il forte interesse per le tecnologie generative in contesti manifatturieri avanzati. È plausibile che ciò rifletta la disponibilità di finanziamenti, infrastrutture e competenze specialistiche, oltre alla vivacità di mercati industriali in continuo sviluppo.

La presenza di altre realtà, come la Germania e l'India, conferma che l'interesse per l'IA generativa in ambito produttivo non si limita alle tradizionali potenze industriali, ma coinvolge anche paesi in crescita che vedono in queste tecnologie un'opportunità per potenziare la propria competitività economica. Alcuni contributi provengono inoltre da nazioni come Australia, Regno Unito o Francia, a testimonianza di un panorama variegato e di un interesse diffuso su scala globale. Non mancano paesi asiatici, quali la Corea del Sud, la Malesia o Taiwan, che, sebbene con un numero ridotto di pubblicazioni, potrebbero rappresentare poli emergenti in termini di applicazione dell'IA generativa al manufacturing, specie in settori come l'elettronica e la robotica.

In generale, il grafico suggerisce una tendenza in cui l'industria manifatturiera, soprattutto nei settori ad alta intensità tecnologica, sta rapidamente adottando o sperimentando tecnologie generative, con un'attenzione particolare a quei contesti nazionali che storicamente hanno fatto dell'innovazione e della capacità produttiva i propri punti di forza. Il fatto che diversi paesi presentino un contributo più limitato in termini numerici non implica necessariamente un disinteresse, ma potrebbe riflettere un ritardo nell'adozione di questi strumenti o una minor disponibilità di fondi e strutture di ricerca dedicate. È comunque possibile che, con la progressiva maturazione dell'IA generativa e l'aumento dei casi d'uso pratici, si assista a un'ulteriore

espansione geografica delle pubblicazioni, coinvolgendo in misura maggiore anche altre regioni del mondo.

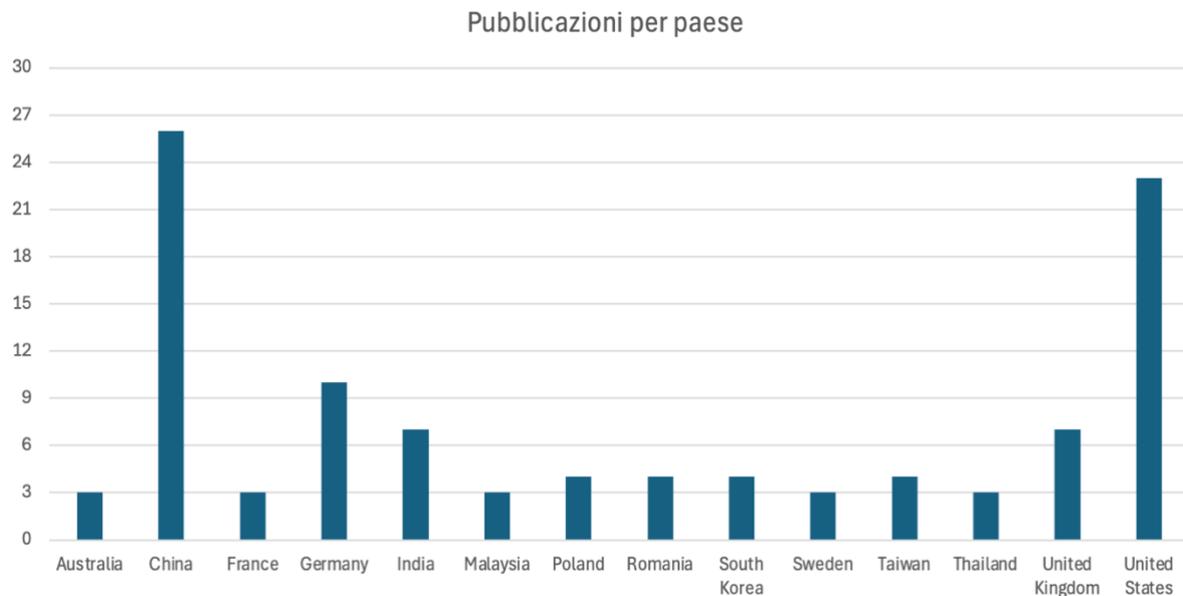


Figura 4.4: Distribuzione delle pubblicazioni per paese

#### 4.5 *Tecnologie generative utilizzate*

L'ultima dimensione della presente analisi bibliometrica prende in esame la classificazione degli articoli secondo la tecnologia generativa di riferimento illustrata. La Figura 4.5 mostra un panorama eterogeneo, nel quale spiccano alcuni modelli come le Generative Adversarial Networks (GAN), mentre altri approcci rivestono un ruolo più limitato. I risultati dell'analisi, sintetizzati nella figura dedicata, indicano che oltre la metà dei contributi (53%) si concentra principalmente sulle GAN, segno di un consolidato interesse verso questa famiglia di modelli, spesso impiegata per generare dati sintetici, svolgere operazioni di *data augmentation* o creare scenari di simulazione capaci di migliorare la progettazione e il controllo dei processi produttivi.

Una quota rilevante (22%) riguarda gli studi che citano o applicano i Large Language Models (LLM), i quali, nonostante siano nati in contesti di elaborazione del linguaggio naturale, iniziano a essere considerati anche per attività che richiedono la generazione di testo o l'interpretazione di dati in ambienti industriali. L'inclusione di LLM in ambito manifatturiero può essere correlata all'automazione della documentazione di processo, alla gestione delle istruzioni di produzione o al supporto a decisioni di pianificazione e manutenzione, benché numerosi studi risultino ancora in fase iniziale e meno consolidati rispetto a quelli basati su GAN.

Un ulteriore gruppo di articoli (13%) non specifica in modo dettagliato la tecnologia generativa di riferimento, limitandosi a parlare in termini generali di "IA generativa" o "modelli generativi". In queste pubblicazioni si riscontra spesso una discussione di carattere concettuale o metodologico, volta a esplorare in modo ampio le potenzialità delle tecniche generative nel miglioramento dei processi manifatturieri, senza però soffermarsi sulle caratteristiche tecniche o sull'implementazione di un particolare modello.

Un 9% dei contributi risulta invece focalizzato su una combinazione di più modelli generativi. Questa categoria comprende ricerche in cui le GAN vengono integrate con altre reti neurali o

dove si affiancano metodologie come i Variational Autoencoders (VAE) e i Large Language Models, al fine di massimizzare la flessibilità o la capacità di adattamento a contesti produttivi molto specifici. Questi studi rivelano un tentativo di sfruttare le sinergie tra diversi approcci generativi, sia per aumentare la robustezza dei risultati, sia per coprire un ampio spettro di esigenze, dalla generazione di immagini e dati sintetici fino all'analisi di documentazione tecnica.

Infine, una piccola percentuale (3%) è costituita da lavori che menzionano o applicano modelli di diffusione, un'architettura relativamente recente e spesso associata all'elaborazione di immagini e segnali complessi. Nonostante il numero esiguo di articoli, la presenza di questi modelli indica la spinta della comunità scientifica a esplorare soluzioni innovative anche in contesti produttivi, dove la generazione di contenuti sintetici di elevata qualità potrebbe risultare decisiva, ad esempio, per ridurre i costi e i tempi di sviluppo di prototipi o per migliorare i sistemi di diagnostica e manutenzione.

Complessivamente, il panorama che emerge evidenzia la netta preponderanza delle GAN come tecnologia cardine, seguita da un crescente interesse verso i modelli di linguaggio di grandi dimensioni, e dall'uso più sperimentale o ibrido di altre architetture. Questa distribuzione rispecchia l'evoluzione dello scenario delle reti generative, in cui le GAN sono ormai affermate da diversi anni, mentre altre soluzioni, come gli LLM o i modelli di diffusione, stanno trovando un terreno di applicazione ancora relativamente nuovo in ambito manifatturiero.

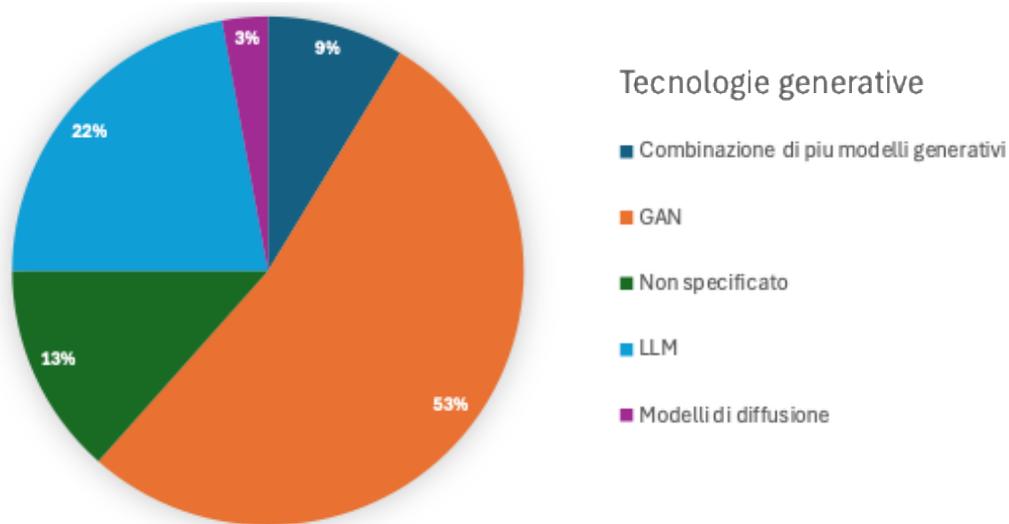


Figura 4.5: Modelli generativi più utilizzati nella ricerca sul manufacturing

#### 4.6 Sintesi dell'analisi bibliometrica

In conclusione, i risultati della presente analisi bibliometrica offrono un quadro articolato dell'evoluzione e della diffusione dell'IA generativa nel settore manifatturiero, fornendo una base quantitativa per le riflessioni che verranno sviluppate nei prossimi capitoli. L'osservazione della progressione temporale delle pubblicazioni (2019–2025) evidenzia come, pur in una fase iniziale di sperimentazione nel biennio 2019–2020, si assista a un incremento costante a partire dal 2021. Il picco rilevante nel 2024, unito ai dati parziali già disponibili per il 2025, indica una crescita particolarmente rapida dell'interesse sia scientifico sia industriale verso le tecnologie generative, in linea con l'evoluzione complessiva del *deep learning* e la disponibilità crescente

di dati industriali. Questa tendenza suggerisce che l'IA generativa sia ormai percepita non solo come un ambito di ricerca promettente, ma anche come un insieme di soluzioni mature e in grado di affrontare sfide concrete della produzione industriale, quali l'ottimizzazione dei processi, la manutenzione predittiva e la progettazione rapida di nuovi prodotti.

Dal punto di vista delle sedi di pubblicazione, emerge un panorama fortemente interdisciplinare, in cui si affiancano riviste di automazione industriale, periodici di ingegneria gestionale e conferenze specialistiche che coprono temi dall'informatica applicata fino al controllo dei processi e all'ottimizzazione produttiva. Questa varietà attesta la convergenza di prospettive differenti: da un lato, le sedi orientate al controllo di processo e all'automazione industriale mostrano come l'IA generativa venga inserita in contesti tradizionalmente legati al miglioramento e al monitoraggio delle linee di produzione; dall'altro, riviste più aperte a ricerche multidisciplinari testimoniano la natura trasversale delle soluzioni di IA generativa, utilizzate tanto per generare dati sintetici, quanto per integrare le tecniche di simulazione con la realtà aumentata o virtuale. Tale eterogeneità rappresenta un segnale importante della vitalità del settore, che trova un riscontro concreto nella presenza di atti di conferenza di ambito industriale, riviste ingegneristiche e pubblicazioni orientate al mondo dell'informatica.

L'analisi degli autori più prolifici mette in luce un quadro in cui la comunità scientifica risulta ancora in fase di consolidamento, con la maggior parte dei ricercatori che firma uno o due contributi e un nucleo più ristretto di studiosi che spicca per la collaborazione su più lavori. Il fatto che gli autori più attivi tendano a collaborare tra loro suggerisce l'esistenza di poli di ricerca iniziali, dai quali potrebbero germogliare nuove partnership, soprattutto in ottica internazionale.

La distribuzione geografica delle pubblicazioni, che vede in testa la Cina e gli Stati Uniti, riflette una certa concentrazione nelle aree tradizionalmente più avanzate sotto il profilo industriale e tecnologico. Non sorprende che i due maggiori colossi economici risultino pionieri nell'adozione di strumenti di IA generativa, grazie alla disponibilità di finanziamenti, infrastrutture e personale altamente specializzato. Al contempo, la presenza di paesi come la Germania o l'India, e di altre realtà europee e asiatiche in misura minore, indica che l'interesse si sta diffondendo su scala globale, spesso legato a contesti produttivi di nicchia o a settori emergenti come la microelettronica o la robotica. Questo dato suggerisce non solo una tendenza verso un'adozione sempre più ampia di tali tecnologie, ma anche la possibilità che, con il consolidarsi di risultati tangibili, ulteriori paesi possano rafforzare il proprio contributo scientifico e industriale, alimentando una competizione virtuosa e alimentando lo scambio di conoscenze su scala mondiale.

Infine, la classificazione delle pubblicazioni in base alle tecnologie generative adoperate completa il quadro, mostrando la netta prevalenza delle Generative Adversarial Networks (GAN) e la crescente attenzione verso i Large Language Models (LLM). Le GAN, ormai consolidate nell'ambito della generazione di immagini, dati sintetici e scenari di simulazione, sono risultate centrali in oltre la metà degli studi analizzati, evidenziando applicazioni che spaziano dalla creazione di dataset aumentati per l'addestramento di modelli di controllo, fino alla simulazione di condizioni di produzione difficilmente replicabili in laboratorio. Parallelamente, l'interesse per i LLM, sebbene più recente e sviluppato originariamente nel campo dell'elaborazione del linguaggio naturale, inizia a tradursi anche nel manufacturing, ad esempio per automatizzare la documentazione di processo o gestire informazioni complesse in fase di progettazione e manutenzione. La presenza minoritaria di modelli di diffusione o di architetture ibride (GAN combinate con VAE o con LLM) apre a prospettive di ricerca più sperimentali, dove si tenta di sfruttare le sinergie tra diverse tipologie di reti generative per affrontare problemi industriali sempre più sofisticati.

Nel complesso, queste cinque dimensioni di forniscono un ritratto dettagliato di una disciplina in rapida espansione. L'IA generativa applicata al settore manifatturiero non è più un tema di nicchia ma si sta affermando come oggetto di studio di interesse globale, coinvolgendo campi che vanno dal design di prodotto alla manutenzione predittiva, fino alla creazione di ecosistemi produttivi immersivi e "intelligenti". L'integrazione tra competenze informatiche, ingegneristiche e manageriali appare un fattore cruciale per favorire il passaggio dalla sperimentazione di laboratorio a soluzioni implementabili in contesti reali, dove l'ottimizzazione dei processi e la gestione efficiente delle risorse rappresentano questioni sempre più strategiche.

I risultati di questa analisi bibliometrica costituiscono, dunque, la solida base conoscitiva su cui si fonda la successiva disamina qualitativa e tematica. Nei prossimi capitoli, verranno esplorati in maniera più approfondita i contenuti delle pubblicazioni, le sfide tecniche incontrate e le soluzioni proposte, mettendo in luce le implicazioni pratiche delle tecnologie generative sul tessuto industriale. Tale passaggio consentirà di comprendere non solo lo stato dell'arte sul piano teorico, ma anche il livello di maturità raggiunto dalle diverse linee di ricerca, i limiti ancora da superare e le opportunità per future evoluzioni. Da questa prospettiva, il contributo bibliometrico presentato si conferma indispensabile per orientare le scelte di chi, nel mondo accademico o in quello aziendale, si propone di investire in tecnologie di IA generativa e di fare leva sui vantaggi competitivi che esse possono apportare al sistema manifatturiero



## 5. **Analisi della letteratura: sintesi e tendenze emergenti**

Il capitolo che segue si propone di analizzare in modo approfondito i contributi emersi dalla revisione della letteratura, con l'obiettivo di individuare e discutere i principali macro-temi in cui si collocano le ricerche relative all'intelligenza artificiale generativa nel settore manifatturiero. A valle delle fasi di selezione e valutazione qualitativa descritte nei capitoli precedenti, si è giunti a un campione di articoli che offre un quadro diversificato del ruolo che l'IA generativa può assumere nei processi industriali, dalla progettazione di nuovi prodotti alle strategie di controllo qualità e di simulazione dei processi. L'insieme dei contributi analizzati ha permesso di riconoscere le modalità con cui gli studi spaziano tra applicazioni pratiche, modelli sperimentali, framework concettuali e valutazioni teoriche, delineando un panorama ricco di possibili traiettorie di sviluppo.

Nel corso di tale analisi, è emersa con chiarezza la necessità di classificare gli articoli in base al loro focus tematico e al tipo di contributo proposto. Il lavoro di sintesi, effettuato dopo una lettura integrale e un'osservazione critica della metodologia impiegata in ciascun paper, ha consentito di raggruppare le pubblicazioni in macro-temi ricorrenti. Questa suddivisione rappresenta, da un lato, una lettura organica delle principali aree di interesse esplorate dalla comunità scientifica e, dall'altro, un modo per evidenziare le potenzialità dell'IA generativa in specifiche fasi della catena del valore manifatturiera.

Dall'analisi condotta è emerso che alcune aree di applicazione risultano essere particolarmente rappresentative e oggetto di un ampio interesse da parte della letteratura. In particolare, la generazione di dati sintetici per l'addestramento dei modelli e il miglioramento dei processi produttivi si configurano come due dei filoni più consolidati, riflettendo l'attenzione crescente verso l'uso dell'IA generativa per ottimizzare i processi industriali, potenziare i sistemi di machine learning e ridurre la dipendenza da dati reali, spesso costosi o difficili da ottenere. Al contrario, altri ambiti, pur essendo considerati promettenti, hanno registrato un numero inferiore di contributi rispetto ai primi. Tra questi, la produzione additiva e la simulazione avanzata di processi industriali risultano meno esplorate in relazione all'IA generativa. Questo potrebbe essere dovuto a fattori quali la complessità dell'integrazione delle tecnologie generative nei flussi produttivi additivi o la predominanza di approcci più tradizionali nella simulazione avanzata, che potrebbero rendere l'adozione dell'IA generativa meno immediata rispetto ad altri contesti. L'analisi ha altresì messo in luce filoni di ricerca maggiormente applicativi e studi più teorici, nei quali l'attenzione si concentra sulla proposta di framework e modelli concettuali dedicati all'adozione dell'IA generativa in ambienti industriali.

Nel presente capitolo, pertanto, ciascun macro-tema viene trattato in modo sistematico, illustrando le principali scoperte e i risultati conseguiti, nonché i trend emergenti in termini di tecnologie utilizzate, tipologia di contributo e possibili implicazioni per il futuro del settore. A tal fine, si farà riferimento a tabelle sintetiche in cui sono riportati gli autori dei paper, le tecnologie generative più rilevanti (ad esempio GAN, VAE, Large Language Models), il tipo di contributo proposto (studio teorico, caso studio, modello sperimentale, framework concettuale o review) e il punto di forza di ciascuno studio. Questo strumento di classificazione consente di mettere in evidenza la varietà delle applicazioni e, al contempo, di delineare i denominatori comuni che caratterizzano il ricorso all'IA generativa all'interno dei contesti produttivi.

Nella parte finale di ogni sezione, si è ritenuto opportuno dedicare uno spazio all'illustrazione di alcuni casi studio particolarmente significativi, in modo da mostrare come le tecnologie generative vengano effettivamente implementate nelle linee di produzione o nelle fasi di progettazione. Questi casi studio offrono una panoramica concreta su come ricercatori e aziende affrontino le sfide dell'integrazione dell'IA generativa, segnalando i risultati raggiunti in termini di miglioramento delle prestazioni, riduzione dei costi, aumento dell'efficienza e delle opportunità di innovazione. L'analisi che segue, pertanto, fornirà un quadro dettagliato degli approcci e delle soluzioni attualmente proposti in letteratura, mettendo in luce le ragioni per cui l'IA generativa si configuri come uno strumento promettente nell'ottimizzazione dei processi manifatturieri.

## 5.1 *Progettazione di nuovi prodotti*

L'integrazione dell'intelligenza artificiale generativa nei processi di progettazione industriale sta ridefinendo in modo profondo lo sviluppo di nuovi prodotti, consentendo di superare i paradigmi tradizionali e aprendo a designer e ingegneri possibilità finora inesplorate. Questa tecnologia permette di esplorare con rapidità un vasto numero di alternative progettuali, migliorando l'efficienza generale del processo e riducendo in modo sensibile i tempi e i costi di sviluppo.

Attraverso algoritmi avanzati di apprendimento automatico e modelli generativi, l'IA consente di accelerare le fasi di ideazione, simulazione e ottimizzazione strutturale, offrendo un incremento di innovazione e personalizzazione nel design industriale. Un ulteriore valore aggiunto consiste nella maggiore integrazione tra progettazione e produzione, resa possibile dall'impiego di gemelli digitali e di tecniche di machine learning. Questi strumenti facilitano la previsione del comportamento del prodotto in varie condizioni operative, migliorandone le prestazioni meccaniche e la sostenibilità complessiva.

La Tabella 5.1 fornisce una panoramica delle principali pubblicazioni scientifiche analizzate nella revisione della letteratura, evidenziando le tecnologie impiegate, il tipo di contributo fornito dagli studi e il loro impatto nei processi di progettazione industriale.

In questo contesto, l'analisi della letteratura mette in evidenza i principali trend che stanno ridefinendo il futuro della progettazione industriale e l'impatto dell'intelligenza artificiale generativa su materiali, componenti e sistemi produttivi.

Un primo aspetto di rilievo riguarda l'integrazione dell'intelligenza artificiale generativa con i *digital twin*, con l'obiettivo di migliorare i processi di progettazione e di gestione del prodotto lungo il suo intero ciclo di vita. Questa direzione di ricerca si basa sull'utilizzo combinato di simulazioni digitali e modelli generativi per esplorare in modo più efficace lo spazio delle possibili configurazioni progettuali, anticipando criticità e migliorando la qualità del design. Gli studi dimostrano come l'IA generativa possa supportare l'ottimizzazione della progettazione attraverso l'analisi di scenari virtuali, consentendo di ridurre il numero di iterazioni fisiche necessarie per la validazione del prodotto e migliorando la capacità di adattamento ai vincoli produttivi e alle esigenze del mercato (Kasar e Kumar, 2024; Witkowski e Wodecki, 2024)

Parallelamente, un altro ambito di ricerca di crescente interesse riguarda l'uso delle reti generative per l'ideazione e l'ottimizzazione del design. L'intelligenza artificiale generativa si sta rivelando uno strumento efficace per esplorare nuovi spazi di progettazione, facilitando la creazione di soluzioni innovative e migliorando le proprietà strutturali e funzionali dei prodotti. In particolare, l'impiego delle GAN nella progettazione meccanica consente di generare geometrie ottimizzate in termini di resistenza e leggerezza, riducendo il peso dei componenti

senza comprometterne le prestazioni. Alcuni studi dimostrano come la combinazione di GAN con tecniche di analisi agli elementi finiti permetta di migliorare l'efficienza strutturale dei prodotti, accelerando il processo di ottimizzazione e riducendo i costi di sviluppo (Yüksel e Börklü, 2024; Challapalli et al., 2021). Un ulteriore sviluppo in questa direzione è rappresentato dall'uso di modelli generativi per la progettazione avanzata di materiali, con applicazioni che spaziano dalla creazione di microstrutture ottimizzate per batterie agli ioni di litio alla generazione di configurazioni per componenti strutturali con prestazioni superiori in termini di assorbimento energetico e resistenza meccanica (Kench et al., 2024; Challapalli et al., 2021).

Una altra tendenza emergente riguarda l'impiego dell'intelligenza artificiale generativa per la sostenibilità e la personalizzazione della produzione. La ricerca sta dimostrando come l'IA generativa possa essere utilizzata per sviluppare strategie di progettazione più sostenibili, riducendo gli sprechi e ottimizzando l'uso delle risorse. L'integrazione di tecniche generative nei processi di design sta favorendo l'adozione di modelli di produzione personalizzati e flessibili, in grado di rispondere meglio alle esigenze individuali dei consumatori e, al contempo, di minimizzare l'impatto ambientale dei prodotti. Alcuni studi evidenziano come l'uso dell'IA generativa in piattaforme di prodotto intelligenti stia promuovendo l'adozione dell'economia circolare, consentendo una gestione più efficiente delle risorse e una maggiore modularità dei prodotti (Akhtar et al., 2024). Parallelamente, altre ricerche stanno esplorando l'applicazione dell'IA neuro-simbolica per la progettazione di sistemi sostenibili, dimostrando come l'integrazione tra modelli generativi e tecniche di ragionamento simbolico possa contribuire alla riduzione dell'impatto ambientale dei processi produttivi (Brad et al., 2025).

L'analisi della letteratura conferma quindi che la ricerca sull'intelligenza artificiale generativa applicata alla progettazione di nuovi prodotti si sta sviluppando attorno a tre assi principali: l'integrazione con i *digital twin* per la gestione ottimizzata del ciclo di vita del prodotto, l'uso delle reti generative per esplorare nuovi spazi di design e migliorare le prestazioni strutturali e l'impiego dell'IA generativa per promuovere la sostenibilità e la personalizzazione della produzione. Queste direzioni di ricerca suggeriscono una progressiva evoluzione dei processi di progettazione verso modelli più data-driven, automatizzati e orientati alla riduzione dell'impatto ambientale, delineando scenari in cui l'IA generativa si afferma come un elemento chiave per l'innovazione nel settore manifatturiero.

Tabella 5.1. Sintesi delle ricerche sull'IA generativa applicata alla progettazione di nuovi prodotti.

<b>Autori</b>	<b>Tecnologie principali</b>	<b>Tipo di contributo</b>	<b>Contributo</b>
Kasar, e Kumar, (2024)	Combinazione di GenAI e Digital Twin	Modello sperimentale	Propone un sistema innovativo (FabAi) che integra IA generativa e gemelli digitali per ottimizzare la progettazione per la produzione, riducendo costi e tempi.
Witkowski, e Wodecki, (2024)	Large Language Models (LLM)	Framework concettuale	Propone un framework che integra GenAI nella gestione dei prodotti, con un focus sulla gestione della conoscenza e la collaborazione interdisciplinare.

Broo, (2023)	GAN	Caso studio	Illustra come l'IA generativa possa stimolare il processo creativo e migliorare l'ideazione di prodotti complessi, ispirando nuove forme e funzionalità per prototipi innovativi.
Kench et al., 2024	GAN	Modello sperimentale	Il paper propone un approccio innovativo per ottimizzare le microstrutture degli elettrodi utilizzando GenAI, riducendo significativamente i tempi e i costi di simulazione rispetto ai metodi tradizionali.
Akhtar et al., 2024	Generica GenAI	Framework concettuale	Il paper propone un framework che collega SPP, GenAI e l'economia circolare, mostrando come l'integrazione di queste tecnologie possa promuovere la sostenibilità ambientale e migliorare la progettazione dei prodotti.
Brad et al., 2025	Generica GenAI	Modello sperimentale	Il paper propone un approccio integrato Neuro-Symbolic AI per progettare un sistema di estrazione sostenibile.
Baugarten-Leon et al., 2024	Large Language Models (LLM)	Modello sperimentale	Il documento propone un flusso di lavoro innovativo per la progettazione e produzione di circuiti integrati utilizzando modelli LLM.
Challapalli et al., 2021	GAN	Modello sperimentale	Il documento propone un framework di progettazione inversa che combina GAN e regressione per esplorare un vasto spazio di design.
Yüksel, e Börklü, (2024)	GAN	Modello sperimentale	Il paper introduce un framework iterativo che integra 3DGAN e FEA per generare design strutturali innovativi.

### 5.1.1 Casi studio rappresentativi

L'analisi dei casi studio nel settore della progettazione di nuovi prodotti mette in evidenza il contributo dell'intelligenza artificiale generativa nel ridefinire i processi di sviluppo e ottimizzazione delle configurazioni strutturali. L'impiego di modelli generativi ha consentito di esplorare soluzioni progettuali innovative, superando i limiti degli approcci convenzionali e introducendo nuovi paradigmi nella personalizzazione dei prodotti, nell'ottimizzazione delle prestazioni meccaniche e nell'integrazione con strategie di sostenibilità. Gli studi analizzati dimostrano come l'intelligenza artificiale generativa possa supportare la creazione di strutture avanzate, migliorare l'interazione tra progettazione e produzione e favorire una maggiore efficienza nell'utilizzo delle risorse, con applicazioni che spaziano dall'industria aerospaziale a quella automobilistica e robotica.

Uno degli ambiti più innovativi riguarda l'ottimizzazione delle strutture cellulari mediante tecniche di machine learning inverso, come dimostrato dal lavoro di Challapalli et al. (2021). Il

loro approccio basato su reti neurali generative avversarie (GAN) e modelli di regressione ha permesso di individuare configurazioni di celle unitarie con elevate frequenze naturali e capacità di assorbimento energetico, migliorando le prestazioni rispetto ai design convenzionali ispirati alla biomimetica. Le simulazioni e i test sperimentali hanno evidenziato un incremento della frequenza naturale tra il 30% e il 100% e un miglioramento dell'assorbimento energetico fino al 300%, risultati che sottolineano il potenziale dell'IA generativa nel progettare soluzioni strutturali avanzate. L'applicazione pratica di queste metodologie in settori come l'aerospaziale e automobilistico dimostra come la generazione automatizzata di configurazioni geometriche possa superare i limiti dell'ottimizzazione topologica tradizionale, offrendo soluzioni ad alte prestazioni difficilmente individuabili con approcci convenzionali. Parallelamente, Akhtar et al. (2024) hanno analizzato l'interazione tra intelligenza artificiale generativa e piattaforme di prodotto intelligenti nel supportare la personalizzazione e l'economia circolare. Il loro studio introduce il concetto di Smart Product Platforming (SPP), un modello basato su big data analytics e machine learning, evidenziando come l'IA generativa possa rivoluzionare la progettazione di nuovi prodotti, rendendola più efficiente, flessibile e sostenibile. In particolare, l'utilizzo di modelli generativi permette di ottimizzare il design in funzione delle esigenze dei consumatori, riducendo sprechi e migliorando l'impiego delle risorse. L'analisi, condotta su oltre 200 professionisti del settore automobilistico in Cina, ha mostrato che l'adozione di SPP consente di bilanciare innovazione, efficienza produttiva e sostenibilità. I risultati suggeriscono che l'integrazione tra piattaforme intelligenti e IA generativa rappresenta un'opportunità strategica per sviluppare prodotti più adattabili e sostenibili, favorendo una transizione verso modelli produttivi più avanzati.

L'uso dell'IA generativa non si limita all'ottimizzazione strutturale, ma si estende anche alla fase di ideazione e progettazione creativa, come evidenziato dallo studio di Broo (2023). L'autore ha analizzato il ruolo delle tecnologie generative nel processo creativo, dimostrando come strumenti di *deep learning* possano fungere da supporto alla fase concettuale della progettazione, generando ispirazioni visive e soluzioni inedite. Il caso studio relativo alla progettazione di un robot ispirato alla morfologia delle meduse ha evidenziato il potenziale della collaborazione tra esseri umani e IA nel generare idee progettuali non convenzionali. Sebbene l'intelligenza artificiale non sostituisca la capacità creativa dell'uomo, il suo utilizzo nella fase iniziale di concept design consente di ampliare lo spazio delle possibilità, accelerando il processo di innovazione e fornendo alternative progettuali che altrimenti non emergerebbero con i metodi tradizionali. Un ulteriore contributo dell'IA generativa nella progettazione industriale è stato analizzato da Yüksel e Börklü (2024) hanno analizzato l'impiego dell'intelligenza artificiale generativa nella progettazione industriale, sviluppando un approccio che combina *deep learning* generativo e analisi agli elementi finiti (FEA). Il loro studio ha dimostrato che l'uso iterativo di GAN e simulazioni FEA può migliorare le prestazioni meccaniche di componenti strutturali, con particolare riferimento ai giunti utilizzati nell'industria aerospaziale. In un caso studio, il modello ha permesso di ottimizzare le configurazioni geometriche dei componenti, aumentando il fattore di sicurezza del 20% e riducendo la dipendenza dai test fisici. L'integrazione tra GAN e FEA rappresenta un passo significativo nella progettazione basata su dati, suggerendo che i modelli generativi possono accelerare il processo di sviluppo e migliorare le prestazioni strutturali attraverso l'automazione delle fasi di simulazione.

I casi studio analizzati confermano il ruolo strategico dell'intelligenza artificiale generativa nella progettazione industriale, evidenziando il suo impatto su diversi livelli: dalla creazione di strutture ottimizzate alla personalizzazione su larga scala, fino al supporto nella fase di ideazione creativa. Le applicazioni di queste tecnologie si dimostrano particolarmente efficaci nel migliorare le prestazioni meccaniche, ridurre i tempi di sviluppo e ottimizzare il consumo di

risorse, contribuendo alla transizione verso modelli produttivi più sostenibili e flessibili. Tuttavia, nonostante i progressi, restano aperte alcune sfide legate all'integrazione delle soluzioni generate con le metodologie produttive tradizionali, alla verifica delle prestazioni in contesti reali e all'ottimizzazione dei processi di validazione sperimentale. Il futuro della progettazione industriale potrebbe essere caratterizzato dall'armonizzazione tra modelli generativi, simulazioni avanzate e processi produttivi, con l'obiettivo di massimizzare l'efficienza e l'innovazione nel settore manifatturiero.

## 5.2 Generazione di dati sintetici per l'addestramento dei modelli

Nell'analisi della letteratura, emerge con chiarezza una stretta connessione tra la generazione di dati sintetici per l'addestramento dei modelli e il controllo qualità. Molti studi evidenziano come la creazione di dataset artificiali sia impiegata per migliorare le prestazioni dei modelli di rilevamento dei difetti, simulando anomalie difficilmente reperibili nei dataset reali e riducendo la dipendenza da dati etichettati manualmente. Tuttavia, per garantire una visione strutturata della letteratura, queste due tematiche sono state trattate separatamente: la generazione di dati sintetici è stata analizzata primariamente in funzione della sua capacità di migliorare l'addestramento e la robustezza dei modelli GenAI, mentre il controllo qualità è stato discusso in termini di metodologie e applicazioni specifiche per il rilevamento di difetti e il miglioramento della qualità produttiva. Questa distinzione consente di evidenziare i contributi specifici della generazione di dati sintetici come tecnica di supporto generale per l'intelligenza artificiale nel manifatturiero, senza limitare il suo impatto alle sole applicazioni di controllo qualità. Al tempo stesso, permette di analizzare le strategie di ispezione automatizzata come un ambito più ampio, nel quale la generazione di dati sintetici rappresenta solo una delle molteplici soluzioni adottate per migliorare l'efficacia dei modelli di rilevamento dei difetti.

Nell'ambito del manifatturiero, l'addestramento efficace dei modelli di intelligenza artificiale dipende fortemente dalla disponibilità di dati di alta qualità, diversificati e rappresentativi delle reali condizioni operative. Tuttavia, molte aziende industriali si trovano di fronte a limitazioni significative nella raccolta e gestione di dati, dovute a fattori come costi elevati, problemi di privacy e la scarsa disponibilità di anomalie nei dataset, specialmente in contesti di controllo qualità e manutenzione predittiva.

Per affrontare queste sfide, la generazione di dati sintetici si sta affermando come una soluzione chiave per migliorare l'addestramento dei modelli AI. Questa tecnica permette di creare dataset artificiali che simulano caratteristiche reali, ampliando così la variabilità dei dati senza la necessità di acquisizioni costose o complesse. In particolare, tecnologie come le reti generative avversarie (GAN) e i modelli di diffusione stanno rivoluzionando il settore, consentendo di ottenere immagini e segnali sintetici di elevata qualità per applicazioni quali la classificazione dei difetti, l'analisi predittiva dei guasti e l'imputazione di dati mancanti. L'evoluzione di queste metodologie sta portando a un'integrazione sempre più sofisticata con altre tecniche di intelligenza artificiale, favorendo la creazione di dataset più bilanciati, la riduzione del rischio di *overfitting* e il miglioramento complessivo delle performance dei modelli di *deep learning*.

La Tabella 5.2 sintetizza i principali studi relativi a questa tematica. In questo contesto, l'analisi della letteratura evidenzia alcuni trend chiave che stanno ridefinendo il ruolo della generazione di dati sintetici nel settore manifatturiero.

Un primo aspetto di rilievo riguarda il ruolo centrale delle reti generative avversarie (GAN), che si confermano come una delle tecnologie più adottate per la creazione di dataset sintetici.

Diversi studi dimostrano come le GAN siano in grado di migliorare la qualità e la diversità dei dati, permettendo di generare immagini sintetiche efficaci per l'addestramento di modelli di classificazione e ispezione visiva. In particolare, le applicazioni nel contesto del rilevamento dei difetti industriali risultano particolarmente rilevanti, con soluzioni che permettono di simulare anomalie quali microfratture e imperfezioni nei materiali, supportando il miglioramento delle prestazioni dei modelli di *deep learning* impiegati nei processi di controllo qualità (Cho et al., 2023; Ntavelis et al., 2020).

Un ulteriore sviluppo in questa direzione è rappresentato dall'impiego di modelli ibridi, che combinano le GAN con altre tecniche per ottenere dataset più bilanciati e rappresentativi delle reali condizioni operative. Alcuni studi evidenziano come l'integrazione delle GAN con metodologie di *data augmentation* possa contribuire a migliorare la generalizzazione dei modelli di classificazione e a ridurre il rischio di *overfitting*, soprattutto in scenari caratterizzati da dataset limitati (Du et al., 2023). Parallelamente, l'adozione di approcci combinati con reti neurali convoluzionali (CNN) ha permesso di potenziare l'accuratezza dei modelli impiegati nel rilevamento dei difetti industriali, sfruttando le capacità generative delle GAN per migliorare l'addestramento dei classificatori (Tseng et al., 2023; Terziyan e Vitko, 2023).

Parallelamente, si assiste a un'evoluzione delle metodologie basate su modelli di diffusione, che rappresentano un'alternativa sempre più rilevante rispetto alle GAN. Alcuni studi dimostrano come questi modelli siano in grado di generare dataset sintetici con livelli di dettaglio e fedeltà significativamente elevati, risultando particolarmente efficaci nella simulazione di difetti industriali complessi. La loro capacità di produrre immagini di qualità superiore rispetto alle GAN li rende strumenti particolarmente adatti alla generazione di immagini SEM, impiegate per la caratterizzazione di semiconduttori e materiali avanzati (Dey et al., 2024; Junhyung Moon et al., 2024).

Un altro ambito di crescente interesse riguarda l'impiego dei dati sintetici nella manutenzione predittiva, dove la disponibilità di dataset contenenti anomalie e guasti risulta spesso limitata. Diversi studi dimostrano come l'uso delle GAN consenta di generare segnali sintetici di accelerazione e vibrazione, contribuendo a migliorare la capacità dei modelli di machine learning nel rilevamento precoce dei guasti (Deeluea et al., 2022; Sarda et al., 2021). Parallelamente, altre ricerche evidenziano il ruolo delle tecniche di generazione sintetica nell'imputazione di dati mancanti nei dataset temporali industriali, una strategia che permette di mantenere la coerenza e l'affidabilità dei dati impiegati nei sistemi di monitoraggio predittivo (Sarda et al., 2021).

L'adozione della generazione di dati sintetici nel settore manifatturiero sta evolvendo rapidamente, trasformandosi da soluzione complementare a tecnologia chiave per il miglioramento delle performance dei modelli di intelligenza artificiale. Le GAN continuano a essere uno strumento fondamentale per la creazione di dataset realistici, ma il panorama si sta ampliando con l'introduzione di modelli di diffusione e approcci ibridi, capaci di offrire un livello di dettaglio e fedeltà sempre più elevato. Con il continuo affinamento di queste metodologie e la loro integrazione con altri sistemi AI, il ruolo dei dati sintetici diventerà sempre più cruciale nel garantire efficienza, affidabilità e innovazione nei sistemi di produzione del futuro.

Tabella 5.2. Sintesi delle ricerche sull'IA generativa applicata alla generazioni di dati sintetici per l'addestramento dei modelli

<b>Autori</b>	<b>Tecnologie principali</b>	<b>Tipo di contributo</b>	<b>Contributo</b>
Tse et al., 2024	GAN	Modello sperimentale	Propone l'uso di GAN ottimizzati per generare dati sintetici che supportano la creazione di gemelli digitali, migliorando la capacità di pianificazione e ottimizzazione dei processi produttivi nel settore dei semiconduttori.
Sasiaowapak et al., 2023	Combinazione GenAI con Stable Diffusion e Segment-Anything Model (SAM)	Modello sperimentale	Dimostra che l'uso di dataset sintetici generati da modelli avanzati come Segment-Anything e Stable Diffusion migliora significativamente il controllo qualità industriale, superando limitazioni di privacy e scarsità di dati.
Ntavelis et al., 2020	GAN	Modello sperimentale	Propone un approccio che permette di generare immagini sintetiche in scenari industriali con dati limitati, migliorando i dataset per il controllo qualità e la manutenzione predittiva, con un incremento delle performance nei classificatori di difetti.
Da Silva et al., 2021	GAN	Modello sperimentale	Il paper introduce un modello GAN progettato per generare anomalie sintetiche nei video e migliorare la rilevazione di difetti nelle linee di produzione industriali. Il contributo include anche la creazione di tre nuovi dataset video con simulazioni realistiche di anomalie.
Pinetz et al., 2019	GAN	Modello sperimentale	Dimostra che le strategie di augmentation basate su GAN (specialmente RGAN) migliorano significativamente le prestazioni dei CNN in scenari con dati limitati, superando metodi classici di data augmentation.
Junhyung Moon et al., 2024	Modelli di diffusione	Modello sperimentale	Propone un approccio innovativo per la generazione di dataset sintetici a partire da un numero limitato di immagini di produzione utilizzando Stable Diffusion e LoRA.
Faltings et al., 2022	GAN	Modello sperimentale	Dimostra che un approccio ibrido con fino al 75% di dati sintetici mantiene una performance comparabile a quella con dati reali al 100%, riducendo i costi di raccolta e annotazione dei dati.

R. Singh et al., 2020	GAN	Modello sperimentale	Propone l'uso di GAN per generare difetti sintetici realistici, riducendo i costi associati alla creazione manuale di difetti e migliorando i dataset per l'addestramento di modelli di classificazione.
Terziyan e Vitko, (2023)	GAN	Modello sperimentale	Il paper propone un'estensione innovativa ai modelli CNN e GAN tradizionali, migliorando la loro capacità di riconoscere e rappresentare causalità tra le caratteristiche delle immagini.
Cho et al., 2023	GAN	Modello sperimentale	SyNDGAN utilizza maschere di segmentazione per generare immagini di difetti realistiche da immagini normali, migliorando sia la qualità che la diversità dei dati sintetici.
Du et al., 2023	GAN	Modello sperimentale	Il paper introduce Con-GAN, un framework innovativo per la generazione di immagini sintetiche di difetti, superando problemi come il collasso di modalità e la bassa qualità delle immagini in dataset limitati.
Hemleben et al., 2023	GAN	Modello sperimentale	DAGGER combina AE e GAN per generare dati sintetici di alta qualità con piccoli dataset di addestramento, superando le limitazioni di dimensionalità e scarsità di dati.
Lin et al., 2019	GAN	Modello sperimentale	Il paper introduce DEGAN, un framework per generare immagini sintetiche di alta qualità di microfratture su anelli magnetici.
Chen e Chen, 2024	GAN	Modello sperimentale	Il documento presenta un approccio innovativo che utilizza GAN per generare dati realistici relativi a wafer e chip, supportando la simulazione e l'ottimizzazione dei processi di produzione semiconduttori.
Tseng et al., 2023	GAN	Modello sperimentale	L'articolo dimostra come l'uso di GAN per la generazione di dati sintetici migliori significativamente la qualità e l'efficacia del rilevamento di difetti metallici tramite CNN.
Sarda et al., 2021	GAN	Modello sperimentale	L'articolo propone un metodo basato su GAN per l'imputazione di dati mancanti nei dataset temporali multivariati di un'industria siderurgica.
Le et al., 2020	GAN	Modello sperimentale	L'articolo propone un approccio basato su GAN e transfer learning per generare dati sintetici e migliorare il rilevamento automatico di difetti con dataset limitati.

Zhang et al., 2024	GAN	Modello sperimentale	L'articolo introduce AMING, un modello GAN adattivo per imputare dati mancanti in contesti industriali, utilizzando un dataset del processo di idrocracking.
Lyu et al., 2024	GAN	Modello sperimentale	L'articolo introduce GPSC-GAN, un modello che genera campioni multimodali bilanciati per migliorare l'accuratezza dei modelli di dGenAI nosi dei guasti basati sul deep learning.
Kampker et al., 2023	GAN	Modello sperimentale	Il framework proposto sfrutta GAN per creare immagini di rivestimenti sintetici e dataset parametrici, migliorando la capacità di analisi e simulazione nel contesto della produzione di elettrodi.
Deeluea et al., 2022	GAN	Modello sperimentale	L'articolo propone un sistema di manutenzione predittiva basato su GAN per risolvere la scarsità di dati anomali nei segnali di accelerazione.
Dey et al., 2024	Modelli di diffusione	Modello sperimentale	L'articolo propone un approccio basato su modelli di diffusione (DDPM) per generare immagini SEM sintetiche che replicano difetti stocastici e caratteristiche fisiche dei wafer semiconduttori.
Jinyeong Yu et al., 2022	GAN	Modello sperimentale	Il paper introduce un approccio innovativo che combina ANN e GAN per superare le limitazioni della scarsità di dati nei processi di simulazione MPCR.
H. Yu et al., 2024	Combinazione GAN e Gaussian Splatting (3DGS)	Modello sperimentale	Introduce un sistema innovativo per la generazione di asset 3D Gaussian, offrendo velocità e precisione superiori rispetto ai metodi esistenti, con applicazioni in realtà virtuale, simulazioni e design industriale.
Howland et al., 2023	GAN	Modello sperimentale	Il paper introduce un framework che combina GAN con etichettatura condizionale per produrre immagini SEM sintetiche che simulano microstrutture associate a specifici parametri di processo
Hsiao e K. Wang, 2024	Modelli di diffusione	Modello sperimentale	Il modello generativo HotspotFusion, creando dati sintetici per simulare scenari produttivi, migliora l'accuratezza delle previsioni sui difetti CMP, riduce i tempi di ciclo della progettazione di semiconduttori di 20-30 giorni e consente interventi correttivi in anticipo.

Lu et al., 2022	GAN	Modello sperimentale	Il paper propone un framework innovativo per il rilevamento di anomalie. MSGAN migliora la qualità dei dati sintetici e risolve problemi di squilibrio nei dataset, aumentando la precisione della rilevazione di anomalie del 97.2%.
Jiambo Yu e Liu, 2022	GAN	Modello sperimentale	Il documento propone MGGAN per affrontare il problema del bilanciamento delle classi nei dataset di produzione di wafer, migliorando l'accuratezza del riconoscimento dei difetti fino al 93.43% utilizzando ResNet101 su dati generati.
Y. Yang e Sun, 2024	Combinazione Modelli di diffusione, GAN e VAE	Modello sperimentale	Il documento propone KDCDDM, un modello innovativo che utilizza una combinazione di diffusione latente e distillamento di conoscenza per la generazione di dati sintetici per il rilevamento dei difetti nei semiconduttori.
W. Li et al., 2024	GAN	Modello sperimentale	L'articolo propone ASM-GAN, un modello in grado di generare immagini con difetti mai visti durante l'addestramento, preservando la fedeltà e la diversità delle immagini sintetizzate.
Liang et al., 2020	GAN	Modello sperimentale	Il paper presenta il modello WT-GAN-CNN, che genera immagini time-frequency sintetiche per il training di CNN, migliorando la dGenAI nosi con elevata precisione (fino al 100%) anche in presenza di rumore e variazioni operative, superando altri approcci esistenti.
Saiz et al., 2021	GAN	Modello sperimentale	Il paper dimostra come l'integrazione di StyleGAN2 e DiffAugment possa migliorare significativamente la segmentazione dei difetti.
Tang et al., 2021	GAN	Modello sperimentale	Il framework combina tecniche di conversione del segnale in immagini in scala di grigi con l'espansione dei dati tramite WGAN-GP, migliorando significativamente la capacità di dGenAI nosi dei guasti nei cuscinetti a rulli.
Sayed et al., 2024	GAN	Modello sperimentale	Propone un sistema ibrido che combina CGAN e algoritmi di machine learning ottimizzati con HHO, migliorando significativamente la capacità di rilevamento dei guasti in sistemi industriali complessi, con un'accuratezza del 95.24%.

### 5.2.1 Casi studio rappresentativi

Nell'analisi dei documenti esaminati emergono diversi casi studio che mettono in luce il ruolo della generazione di dati sintetici nell'addestramento di modelli di intelligenza artificiale per applicazioni manifatturiere. In contesti industriali caratterizzati da una disponibilità limitata di dati reali, la capacità di generare campioni sintetici rappresenta una soluzione efficace per migliorare l'affidabilità e la generalizzazione dei modelli di rilevamento difetti. Gli studi analizzati esplorano approcci innovativi basati su Generative Adversarial Networks (GAN) e modelli contrastivi, con l'obiettivo di ottimizzare la creazione di dataset sintetici per l'ispezione automatizzata e il controllo qualità.

Uno dei primi ambiti di applicazione riguarda la generazione sintetica di difetti per il riconoscimento automatico, come dimostrato dallo studio di R. Singh et al. (2020), che ha sviluppato un modello GAN in grado di sintetizzare difetti comuni nei processi di assemblaggio e test di semiconduttori. L'approccio proposto ha ridotto la necessità di creare artificialmente difetti fisici, spesso costosi e difficili da replicare, permettendo di produrre immagini di contaminazioni da materiali estranei, graffi e difetti di incollaggio. L'integrazione dei dati sintetici con sistemi di visione artificiale ha consentito di addestrare reti convoluzionali con una maggiore capacità di generalizzazione, riducendo significativamente il tasso di errore nelle fasi di test e migliorando l'affidabilità dell'ispezione visiva.

Un ulteriore avanzamento nell'utilizzo delle GAN per la generazione di immagini difettose è stato introdotto da Lu et al. (2022), che ha sviluppato un framework basato su MSGAN (Modified Self-Guided GAN), un modello migliorato di WGAN-GP per affrontare il problema della scarsità e dello squilibrio nei dataset di anomalie industriali. Il framework proposto combina una fase di addestramento offline con un'inferenza online incrementale, migliorando la capacità di rilevamento di anomalie nei sensori di robot industriali. Gli esperimenti condotti su dataset reali hanno evidenziato un incremento dell'accuratezza del modello, dimostrando che l'integrazione di campioni sintetici generati dal MSGAN può ridurre il tasso di falsi negativi e migliorare la robustezza del sistema di rilevamento.

Analogamente, Le et al. (2020) hanno applicato Wasserstein GAN (WGAN) per la generazione di dati sintetici in scenari di rilevamento difetti su superfici industriali, con particolare attenzione alla riduzione della scarsità di campioni etichettati. Integrando tecniche di transfer learning e ensemble learning, il loro approccio ha permesso di migliorare significativamente la capacità dei modelli di classificare difetti superficiali, anche in presenza di dataset ridotti. I test condotti su difetti di lamiere decorative e giunti di saldatura hanno dimostrato una riduzione del False Negative Rate (FNR) fino allo 0,47%, rispetto a un tasso del 20% ottenuto con metodi tradizionali.

Infine, Liang et al. (2020) hanno proposto il modello WT-GAN-CNN, che combina la Wavelet Transform (WT) con GAN e reti neurali convoluzionali (CNN) per la diagnosi di guasti nei macchinari rotanti, come cuscinetti e gearbox. Questo metodo trasforma segnali vibrazionali in immagini time-frequency mediante la WT, generando campioni sintetici con GAN per potenziare l'addestramento di un modello CNN. I risultati sperimentali hanno mostrato che questo approccio migliora la capacità del modello di identificare guasti multipli e precoci, mantenendo alte prestazioni anche in condizioni operative variabili e ambienti rumorosi. Rispetto ad altri modelli tradizionali di diagnosi predittiva, il WT-GAN-CNN ha ottenuto un'accuratezza superiore del 97,89% nella classificazione di difetti, dimostrando il valore della generazione di dati sintetici per l'affidabilità della manutenzione predittiva.

I risultati ottenuti dai casi studio analizzati dimostrano come la generazione di dati sintetici rappresenti una soluzione strategica per il superamento delle sfide legate alla scarsità di dati nei processi di addestramento dei modelli di *deep learning* per il controllo qualità. L'adozione di GAN avanzate, modelli contrastivi e strategie di apprendimento auto-supervisionato ha permesso di migliorare la qualità dei dataset sintetici e l'accuratezza delle reti neurali, garantendo una maggiore affidabilità nei contesti produttivi reali.

### 5.3 *Miglioramento dei processi produttivi*

L'Intelligenza Artificiale Generativa sta emergendo come un elemento chiave per l'ottimizzazione dei processi produttivi, con applicazioni che spaziano dall'automazione industriale alla gestione avanzata della supply chain, fino al miglioramento della collaborazione uomo-macchina. La capacità di questi modelli di apprendere da grandi quantità di dati e generare soluzioni innovative sta contribuendo a rendere il settore manifatturiero più efficiente, resiliente e sostenibile.

Un aspetto particolarmente interessante che emerge dalla revisione della letteratura, riportata nella Tabella 5.3, è la differenza nella distribuzione delle tecnologie generative impiegate in questa macroarea rispetto ad altre analizzate. Mentre in settori come la progettazione di nuovi prodotti e la generazione di dati sintetici le reti generative avversarie (GAN) giocano un ruolo centrale, nel miglioramento dei processi produttivi il focus principale è sui Large Language Models (LLM). Questa predominanza riflette il crescente utilizzo di modelli generativi per supportare il decision-making, l'automazione della gestione operativa e l'analisi avanzata dei dati industriali. L'adozione dei LLM in questo contesto è motivata dalla loro capacità di gestire flussi informativi complessi, ottimizzare la pianificazione produttiva e migliorare l'efficienza delle operazioni industriali.

Uno dei principali ambiti di applicazione riguarda l'automazione e l'ottimizzazione operativa, dove l'uso di modelli linguistici avanzati consente di automatizzare analisi complesse e migliorare la gestione dei dati industriali. L'impiego di LLM nella costruzione di *causal graphs* riduce il coinvolgimento umano nei processi decisionali, aumentando la rapidità e la precisione dell'analisi dei flussi produttivi (Meier et al., 2024). Inoltre, l'introduzione di agenti intelligenti in grado di pianificare autonomamente la produzione sta semplificando attività critiche come la stima dei tempi e la selezione delle risorse (Holland e Chaudhari, 2024). L'integrazione di modelli di linguaggio generativi con tecnologie di visione artificiale consente, inoltre, di monitorare con maggiore precisione i processi industriali, migliorando la qualità e riducendo le inefficienze operative (Fu et al., 2024). Parallelamente, l'automazione della programmazione dei robot per l'assemblaggio adattivo migliora l'efficienza della produzione, riducendo errori e tempi di riconfigurazione nelle linee industriali (Macaluso et al., 2024).

Oltre all'ottimizzazione interna, le tecnologie generative stanno ridefinendo la gestione della supply chain e della produzione sostenibile. L'integrazione dell'intelligenza artificiale generativa nei processi di gestione logistica sta favorendo un aumento dell'efficienza e una riduzione dei costi, grazie alla capacità di ottimizzare i flussi di approvvigionamento e prevedere le variazioni della domanda (Khlie et al., 2024). In parallelo, l'interazione tra modelli generativi e gemelli digitali sta emergendo come un elemento chiave per l'ottimizzazione della simulazione e della pianificazione dei processi produttivi. L'integrazione tra queste due tecnologie consente infatti di sviluppare sistemi cyber-fisici avanzati, capaci di apprendere in tempo reale dalle condizioni operative e di adattare dinamicamente le strategie produttive per migliorarne l'efficienza (Q. Xu et al., 2024). Questa combinazione tecnologica non solo migliora la

produttività, ma sta anche trasformando la gestione delle risorse, favorendo una riduzione dei consumi energetici e accelerando la transizione verso un modello di produzione più sostenibile (Assad et al., 2024). In questo contesto, l'adozione di strategie di supply chain verde e di modelli di economia circolare risulta facilitata dall'uso di strumenti generativi, che supportano l'integrazione di soluzioni sostenibili all'interno delle reti di produzione (L. Li et al., 2024). Parallelamente, l'ambidestria innovativa, ovvero la capacità di combinare esplorazione e sfruttamento delle risorse, sta emergendo come un fattore determinante per migliorare le prestazioni delle supply chain digitali, contribuendo a rafforzare la competitività del settore manifatturiero (Al-Khatib et al., 2024)

Un altro ambito di crescente interesse è la collaborazione uomo-macchina, dove l'intelligenza artificiale generativa sta supportando l'integrazione tra operatori e sistemi automatizzati. Nei contesti produttivi, l'introduzione di framework generativi sta migliorando l'efficienza dei processi di assemblaggio manuale, offrendo assistenza personalizzata e supporto alla formazione degli operatori (Potthoff et al., 2024). La combinazione di GAN e VAE si sta rivelando efficace per l'ottimizzazione del layout del reparto produttivo manifatturiero, permettendo una gestione più dinamica degli spazi e una maggiore efficienza nei flussi di lavoro (Cohen e Aperstein, 2024). Inoltre, l'uso di assistenti intelligenti basati su LLM nel lean manufacturing sta contribuendo a migliorare la gestione della produzione, guidando gli operatori nell'analisi e nell'ottimizzazione delle attività industriali (Magnus e Venschott, 2024).

L'adozione di soluzioni innovative per il monitoraggio e il controllo della produzione rappresenta un ulteriore passo avanti nella trasformazione del settore manifatturiero.

Nel complesso, l'IA generativa si sta affermando come una tecnologia di riferimento per il miglioramento dei processi produttivi, con un impatto significativo sull'efficienza operativa e sulla sostenibilità. Tuttavia, restano aperte sfide legate all'integrazione nei sistemi esistenti e alla validazione delle soluzioni adottate, aspetti che richiederanno ulteriori sviluppi per garantire un'implementazione efficace e scalabile nel settore manifatturiero.

Tabella 5.3. Sintesi delle ricerche sull'IA generativa applicata al miglioramento dei processi produttivi

<b>Autori</b>	<b>Tecnologie principali</b>	<b>Tipo di contributo</b>	<b>Contributo</b>
Meier et al., 2024	Large Language Models (LLM)	Modello sperimentale	Il paper dimostra come l'uso di LLM possa automatizzare la costruzione di causal graphs, riducendo il coinvolgimento umano e migliorando l'efficienza nell'analisi dei processi di produzione elettronica.
Al-khatib et al., 2024	Generico GenAI	Modello Sperimentale	Dimostra come la AI generativa, mediata dall'ambidestria innovativa (esplorativa ed esaustiva), migliori le prestazioni delle supply chain digitali, rafforzando la competitività delle aziende manifatturiere.

Rath et al., 2024	Generico GenAI	Modello sperimentale	Il paper esplora i fattori determinanti per l'implementazione e l'adozione continua della GenAI, utilizzando framework teorici per comprendere il contesto tecnologico, organizzativo e ambientale e superare le barriere psicologiche e funzionali.
L. Li et al., 2024	Large Language Models (LLM)	Modello sperimentale	Il paper analizza come la GenAI migliora la collaborazione nella supply chain verde (GSCC) e l'implementazione dell'economia circolare (CEI), dimostrando il loro ruolo mediatore nel migliorare la performance sostenibile delle supply chain.
J. Yang et al., 2024	Generico GenAI	Framework concettuale	Il framework DeFACT integra tecnologie come blockchain e modelli generativi per creare un'ecologia collaborativa "6S" (sicura, sostenibile, intelligente, ecc.), migliorando la produzione personalizzata e la sicurezza dei dati.
Yunqing Li e Starly, 2024	Large Language Models (LLM)	Framework concettuale	Il sistema integra un knowledge graph per il settore manifatturiero con ChatGPT, offrendo risposte più precise per query complesse sui servizi di produzione. Fornisce raccomandazioni personalizzate tramite analisi grafiche avanzate e apprendimento contestuale.
Sai et al., 2024	Generico GenAI	Review teorica	Fornisce una panoramica delle applicazioni della GenAI per trasformare i processi industriali in Industry 5.0, evidenziando vantaggi come efficienza operativa, riduzione dei downtime e personalizzazione.
Assad et al., 2024	Large Language Models (LLM)	Caso studio	Il paper presenta un approccio innovativo che integra la GenAI con i Gemelli Digitali Cognitivi (CDTs). Attraverso un caso studio, dimostra come questa integrazione migliori il monitoraggio in tempo reale e la sostenibilità del sistema produttivo, con un focus particolare sull'ottimizzazione del consumo energetico.
Rittikulsittichai e Siriborvornratanakul, 2024	Large Language Models (LLM)	Modello sperimentale	Il paper presenta un prototipo di chatbot AI che combina RAG con LLM per fornire assistenza tecnica nel processo di placcatura del rame nei PCB.
Magnus e Venschott, 2024	Large Language Models (LLM)	Modello sperimentale	Il paper valuta le capacità di GPT-4 come assistente per il lean manufacturing, dimostrando come possa guidare gli utenti attraverso l'analisi e l'ottimizzazione dei processi produttivi.

Mulongo, 2024	GAN	Review teorica	L'articolo è una review teorica sull'uso dell'intelligenza artificiale generativa per ottimizzare i flussi di lavoro nella produzione, analizzandone applicazioni, vantaggi e sfide.
Potthoff et al., 2024	Large Language Models (LLM)	Framework concettuale	Il paper presenta un framework per integrare la GenAI in sistemi di assemblaggio manuale, migliorando l'efficienza tramite assistenza personalizzata, training per nuovi dipendenti e suggerimenti adattivi.
Khlie et al., 2024	Generico GenAI	Review teorica	Il paper esplora come la GenAI possa trasformare la gestione della supply chain migliorando l'efficienza, riducendo i costi e ottimizzando i processi decisionali.
Holland e Chaudhari, 2024	Large Language Models (LLM)	Modello sperimentale	Il paper presenta un agente basato su LLM in grado di risolvere autonomamente problemi di pianificazione dei processi di produzione, come stima dei tempi e selezione delle risorse.
Skórnóg e Kmiecik, 2023	Large Language Models (LLM)	Caso studio	Lo studio dimostra che ChatGPT fornisce previsioni più accurate rispetto ad ARIMA, soprattutto per prodotti con lunghi tempi di approvvigionamento.
Xia et al., 2024	Large Language Models (LLM)	Modello sperimentale	Il paper propone un approccio innovativo che combina fine-tuning e validazione iterativa per adattare gli LLM alle esigenze del settore manifatturiero.
Fu et al., 2024	Large Language Models (LLM)	Modello sperimentale	Propone un sistema che integra modelli di linguaggio e di visione per monitorare, analizzare e ottimizzare i processi di fusione dell'acciaio.
Alawieh et al., 2021	GAN	Modello sperimentale	Il paper presenta un framework GAN-SRAF per migliorare la finestra di processo litografico e la qualità di fabbricazione dei circuiti integrati.
Cao et al., 2024	Large Language Models (LLM)	Caso studio	L'articolo esplora l'uso di ChatGPT per ottimizzare il riciclo e la riparazione delle lenti difettose nel processo di stampaggio del vetro, migliorando l'efficienza economica, ambientale e la qualità del prodotto.
Macaluso et al., 2024	Large Language Models (LLM)	Modello sperimentale	Il paper propone un sistema che usa ChatGPT per automatizzare la programmazione dei robot nell'assemblaggio adattivo, migliorando l'efficienza dei processi produttivi.

Cohen e Aperstein, 2024	Combinazione GAN e VAE	Framework concettuale	L'articolo propone un framework generativo per l'ottimizzazione del layout del shopfloor manifatturiero, integrando GAN e VAE in un processo a tre stadi per migliorare efficienza e collaborazione uomo-macchina
H. Wang e Yan-Fu Li, 2023	Large Language Models (LLM)	Framework concettuale	L'articolo introduce LLM-DSKB, un framework che combina grandi modelli linguistici con basi di conoscenza specifiche di dominio per migliorare l'operatività e la manutenzione di apparecchiature industriali.
Sun et al., 2020	GAN	Modello sperimentale	L'articolo presenta un sistema basato su GAN per valutare l'efficienza lavorativa nel manifatturiero, confrontando video dei lavoratori con un video di riferimento per analizzare la durata e l'accuratezza delle azioni.
Gholami 2024	Large Language Models (LLM)	Framework concettuale	L'articolo propone un approccio metodologico innovativo che combina LLM e fuzzy logic per migliorare il processo decisionale in contesti complessi.
Hoffmann et al., 2022	GAN	Framework concettuale	L'articolo presenta ProGAN, un framework che usa GAN per applicare il ciclo MAPE-K nei processi manifatturieri, monitorando i processi in tempo reale, analizzando le deviazioni e pianificando adattamenti per migliorare la resilienza e la reazione ai cambiamenti nei processi produttivi.
Kim et al., 2021	GAN	Modello sperimentale	L'articolo propone un controllore R2R basato su LSGAN che elimina la necessità di modelli di metrologia virtuale, migliorando significativamente il controllo del processo CMP rispetto ai modelli tradizionali.
Görge et al., 2024	Large Language Models (LLM)	Caso studio	Il paper esplora il ruolo di ChatGPT nella modellazione aziendale, dimostrando come possa supportare attività di analisi e progettazione, sebbene con limiti nell'accuratezza e nella comprensione del contesto.
Q. Xu et al., 2024	Combinazione LLM e Digital Twin	Framework concettuale	Propone un framework innovativo (GIPP) che combina IA generativa e gemelli digitali per creare un sistema di pianificazione dei processi altamente adattabile, capace di generare, verificare e ottimizzare automaticamente piani di produzione.

### 5.3.1 Casi studio rappresentativi

Nell'analisi e approfondimento dei differenti documenti, emergono alcuni casi studio rilevanti da approfondire e a cui prestare attenzione. Un esempio significativo evoluzione è rappresentato dallo studio di Alawieh et al. (2021), che ha introdotto il modello GAN-SRAF per il miglioramento della litografia industriale nel settore dei semiconduttori. L'impiego delle GAN per la generazione di Subresolution Assist Features (SRAF) ha permesso di ottimizzare i processi fotolitografici, riducendo la variabilità nella produzione di microchip. Il modello ha dimostrato di essere altamente efficiente, con una riduzione del tempo di elaborazione di 14,6 volte rispetto ai precedenti metodi di apprendimento automatico e di 144 volte rispetto agli approcci modellistici tradizionali. Questo risultato evidenzia come le tecniche generative possano essere utilizzate per migliorare la qualità della produzione, riducendo i costi computazionali e ottimizzando la precisione nei processi industriali avanzati. Nel settore dei semiconduttori, l'efficacia delle GAN è stata ulteriormente confermata dallo studio di Kim et al. (2021), che ha sviluppato un sistema di controllo Run-to-Run (R2R) basato su Least Squares Generative Adversarial Networks (LSGAN) per il processo di planarizzazione chimico-meccanica (CMP). L'integrazione di LSGAN ha consentito di gestire in modo efficace le variazioni di processo dovute a deriva e shift dei parametri operativi, garantendo una qualità costante del prodotto senza la necessità di modelli metrologici virtuali. I risultati hanno dimostrato che il modello proposto è in grado di prevedere e correggere automaticamente le deviazioni del processo, riducendo i tempi di elaborazione e migliorando la precisione del controllo rispetto ai metodi tradizionali.

Parallelamente, l'adozione dei Large Language Models (LLM) nei processi produttivi rappresenta un nuovo paradigma per l'automazione della manifattura intelligente. Xia et al. (2024) hanno sviluppato un sistema di fine-tuning basato su apprendimento iterativo assistito da errori, adattando un modello linguistico avanzato per migliorare la precisione della generazione di codice per il controllo delle macchine industriali. L'integrazione di questa tecnologia ha portato a un incremento del 4,1% nell'accuratezza delle risposte alle query di produzione, dimostrando il potenziale degli LLM nel colmare il divario tra conoscenza generica e applicazioni specifiche del settore manifatturiero. Un ulteriore sviluppo nel campo dell'IA generativa applicata alla pianificazione dei processi produttivi è stato introdotto da Holland e Chaudhari (2024), che hanno sviluppato un agente di pianificazione basato su modelli di linguaggio per la produzione di strutture in materiali compositi. Utilizzando LangChain e GPT-4, il sistema è stato in grado di eseguire stime accurate sui tempi di ciclo, ottimizzare l'allocazione delle risorse e migliorare il sequenziamento delle operazioni. Lo studio ha evidenziato che l'adozione di LLM per la gestione della pianificazione può ridurre i tempi di configurazione e migliorare la sincronizzazione tra progettazione e produzione, contribuendo a un'efficienza operativa superiore.

Gli studi analizzati dimostrano che l'intelligenza artificiale generativa sta trasformando il settore manifatturiero, portando a significativi miglioramenti in termini di ottimizzazione dei processi, qualità dei prodotti e riduzione delle inefficienze. Le GAN si confermano strumenti efficaci per la generazione di configurazioni ottimizzate nei processi avanzati di produzione, mentre gli LLM aprono nuove prospettive nella gestione della conoscenza industriale e nell'automazione della programmazione delle macchine. Il futuro della produzione intelligente potrebbe essere caratterizzato dalla combinazione tra IA generativa, simulazioni fisiche e sistemi cyber-fisici, con l'obiettivo di rendere i processi produttivi sempre più autonomi, resilienti e adattivi alle esigenze di un'industria in continua evoluzione.

## 5.4 *Simulazione avanzata di processi industriali*

La simulazione di processi industriali è diventata un elemento essenziale per l'industria manifatturiera moderna, permettendo alle aziende di ottimizzare i propri processi, ridurre i costi e migliorare la qualità della produzione. Grazie ai progressi dell'intelligenza artificiale generativa, oggi è possibile creare modelli predittivi sempre più accurati, capaci di rappresentare in modo realistico le dinamiche dei sistemi di produzione e supportare decisioni strategiche in tempo reale.

Negli ultimi anni, l'integrazione dell'intelligenza artificiale nella simulazione industriale ha portato a un significativo miglioramento nella capacità di generare dati sintetici affidabili, analizzare grandi quantità di informazioni e prevedere scenari futuri con maggiore precisione. In particolare, l'impiego di modelli generativi avanzati ha rivoluzionato il modo in cui vengono costruiti e testati gli ambienti di simulazione, consentendo di superare le limitazioni dei dati reali e di esplorare soluzioni innovative per il miglioramento dell'efficienza produttiva. Questo crescente interesse si riflette nell'ampia gamma di approcci utilizzati, che spaziano dalla generazione di dataset sintetici per il training di sistemi di apprendimento automatico fino all'ottimizzazione dei processi produttivi mediante modelli predittivi avanzati. Le metodologie basate su reti neurali, modelli probabilistici e tecniche di apprendimento rinforzato stanno trovando applicazioni sempre più diffuse nella manifattura, nella logistica e nell'ingegneria industriale, contribuendo a migliorare la resilienza e la sostenibilità dei sistemi produttivi.

La Tabella 5.4 fornisce una panoramica completa dei principali studi che hanno affrontato la simulazione di scenari industriali, evidenziando le diverse tecniche adottate, i contesti applicativi e i risultati ottenuti. Questa raccolta di lavori scientifici permette di delineare le tendenze emergenti nel settore e di comprendere l'impatto delle tecnologie di intelligenza artificiale sulla modellazione e l'ottimizzazione dei processi industriali.

Uno dei filoni di ricerca più consolidati riguarda l'impiego di reti generative avversarie (GAN) per la creazione di dati sintetici, utilizzati per migliorare la qualità delle simulazioni e superare le limitazioni dei dataset reali. In alcuni studi, le GAN sono state applicate con successo, nella fabbricazione additiva, per generare immagini termiche e a raggi X condizionate su parametri di produzione, consentendo una simulazione più precisa dell'impatto dei parametri di processo sulla qualità del prodotto (Ouidadi e Guo, 2024). L'adozione di tali modelli consente di ottenere dataset altamente realistici, migliorando la capacità dei sistemi di apprendimento automatico di riconoscere pattern complessi e predire l'evoluzione di specifiche condizioni di processo. In questo contesto, un esempio è l'uso combinato di GAN e VAE per modellare la capacità di trasformazione della forma nei processi di lavorazione meccanica. (X. Yan e Melkote, 2022).

Parallelamente, si sta affermando un secondo filone di ricerca orientato alla simulazione predittiva e all'ottimizzazione dei processi produttivi, con un impiego sempre più diffuso di modelli generativi di diffusione e reti neurali ibride. L'attenzione è rivolta alla capacità di questi modelli di prevedere l'evoluzione dei processi industriali, consentendo di intervenire proattivamente per ottimizzare le condizioni operative. In ambito manifatturiero, tecniche basate su GAN hanno permesso di sviluppare strumenti per la previsione delle mappe di stabilità nei processi di fresatura, offrendo una soluzione efficace per minimizzare i fenomeni di vibrazione indesiderata e migliorare l'efficienza delle operazioni di taglio (Rezaei et al., 2024). Un'altra direzione rilevante in questo ambito riguarda l'applicazione di reti neurali avanzate nella simulazione dei fenomeni termodinamici industriali. Ad esempio, l'utilizzo di modelli LSTM combinati con GAN ha permesso di ottenere simulazioni più accurate dell'ebollizione convettiva, con una precisione superiore al 96%, contribuendo all'ottimizzazione dei sistemi di gestione del calore nei processi produttivi (Asha et al., 2024).

Un'ulteriore evoluzione della ricerca riguarda l'integrazione delle GAN con il *reinforcement learning*, un approccio che permette l'adattamento dinamico dei modelli di simulazione alle variazioni delle condizioni operative senza la necessità di un riaddestramento completo. Ad esempio, Paul et al. (2022) hanno dimostrato come le GAN possano essere utilizzate per generare politiche decisionali in ambienti robotici industriali, consentendo ai robot di adattarsi a nuovi carichi senza dover ripetere il training da zero.

Nel complesso, i recenti progressi nella simulazione avanzata dei processi industriali evidenziano un crescente utilizzo di modelli generativi per migliorare la previsione e l'ottimizzazione delle operazioni industriali. L'integrazione delle GAN con tecniche di apprendimento automatico e simulazione fisica sta potenziando la capacità di generare dati sintetici affidabili, ridurre la dipendenza da test sperimentali e affinare la modellazione di scenari produttivi complessi. Questi sviluppi favoriscono un approccio più scalabile e adattivo, con applicazioni che spaziano dalla previsione delle condizioni operative alla progettazione avanzata di prodotti e processi.

Tabella 5.4. Sintesi delle ricerche sull'IA generativa applicata alla simulazione avanzata dei processi industriali

<b>Autori</b>	<b>Tecnologie principali</b>	<b>Tipo di contributo</b>	<b>Contributo</b>
Asha et al., 2024	GAN	Modello sperimentale	Presenta una soluzione completa basata su reti neurali per modellare i processi di ebollizione convettiva, raggiungendo un'accuratezza del 96%, migliorando velocità, robustezza e applicabilità in contesti industriali.
Ouidadi e Guo, 2024	GAN	Modello sperimentale	Il modello MPS-GAN permette di generare immagini rappresentative dello stato qualitativo dei prodotti fabbricati, basandosi su parametri di input.
X. Yan e Melkote, 2022	Combinazione GAN e VAE	Modello sperimentale	L'articolo sviluppa un modello generativo 3D (VAE-GAN) per simulare come i processi di lavorazione (come tornitura e fresatura) possono trasformare le forme, supportando la progettazione e la selezione del processo produttivo.
Jiyoung Moon et al., 2024	GAN	Modello sperimentale	Il paper dimostra l'efficacia di un modello GAN per prevedere segnali di processo realistici condizionati sullo spessore del metallo.
Rezaei et al., 2024	GAN	Modello sperimentale	L'articolo introduce l'Encoder GAN (EGAN), un framework che combina modelli fisici e apprendimento automatico per predire mappe di stabilità nel processo di fresatura utilizzando pochi test sperimentali.

Paul et al., 2022	GAN	Modello sperimentale	Il paper introduce un framework innovativo che integra GAN e RL per generare Q-tables adattive che permettono ai robot industriali di adattarsi a carichi variabili senza riaddestramento.
-------------------	-----	----------------------	--

#### 5.4.1 Casi studio rappresentativi

L'adozione di tecniche avanzate di apprendimento automatico, come le Generative Adversarial Networks (GAN) e i modelli basati su reti neurali variazionali (VAE), sta rivoluzionando il modo in cui vengono affrontate le problematiche legate alla previsione delle trasformazioni geometriche dei materiali, alla stabilità delle operazioni di fresatura e all'analisi delle proprietà dei materiali. Uno degli sviluppi più significativi in questo ambito è rappresentato dallo studio condotto da Yan e Melkote (2022), che hanno sviluppato un modello basato su una combinazione di 3D Variational Autoencoders e Generative Adversarial Networks (3D-VAE-GAN) per la simulazione della trasformazione geometrica nei processi di lavorazione meccanica. Questo sistema consente di prevedere con elevata accuratezza la capacità di un determinato processo di produzione di generare forme specifiche, offrendo ai progettisti uno strumento avanzato per selezionare il metodo ottimale per ciascun componente. L'analisi condotta attraverso questo modello si basa su una rappresentazione probabilistica delle trasformazioni di forma, permettendo di generare configurazioni realistiche che possono essere direttamente utilizzate nella pianificazione dei processi produttivi. Un altro contributo significativo in questo settore è stato fornito da Rezaei et al. (2024), che hanno introdotto un nuovo approccio basato su Encoder GAN (EGAN) per la previsione della stabilità della fresatura in presenza di dati sperimentali limitati. Il modello combina un encoder, un generatore e un discriminatore per apprendere le complesse relazioni tra i parametri di fresatura e la stabilità del processo, consentendo di generare mappe di stabilità accurate con un numero minimo di test sperimentali, generalmente tra cinque e dieci. I risultati ottenuti dimostrano che questa metodologia può ridurre significativamente i costi e i tempi di calibrazione dei parametri di fresatura, rendendola particolarmente adatta per ambienti di produzione dinamici in cui la disponibilità di dati è ridotta e la necessità di adattamento rapido è elevata.

Gli studi analizzati evidenziano il ruolo crescente dell'intelligenza artificiale generativa nella simulazione industriale, migliorando la previsione delle trasformazioni geometriche e la stabilità dei processi produttivi. Rimangono aperte sfide legate all'implementazione di queste tecniche nei flussi produttivi reali, in particolare per quanto riguarda la scalabilità e l'affidabilità in contesti industriali complessi. L'evoluzione futura si concentrerà sull'integrazione di modelli generativi con dati sperimentali laddove necessario, migliorando la precisione e l'adattabilità delle simulazioni per una manifattura più efficiente e flessibile.

### 5.5 *Controllo qualità*

Il controllo qualità è una funzione fondamentale nei processi manifatturieri, volta a garantire che i prodotti soddisfino gli standard richiesti in termini di precisione, affidabilità e sicurezza. Con l'aumento della complessità produttiva e la necessità di sistemi sempre più efficienti, le tecniche tradizionali di ispezione e monitoraggio stanno evolvendo rapidamente grazie all'adozione di soluzioni basate sull'intelligenza artificiale generativa (GenAI). La tecnologia generativa si distingue per la sua capacità di creare dati sintetici, apprendere pattern complessi e identificare anomalie con maggiore precisione, rendendola particolarmente adatta per

migliorare le pratiche di controllo qualità. Grazie all'uso di modelli avanzati di *deep learning*, le aziende possono implementare sistemi di ispezione più autonomi e adattivi, riducendo la dipendenza da ispezioni manuali e aumentando l'accuratezza dei controlli. L'evoluzione delle tecnologie di controllo qualità basate sull'AI generativa si inserisce in un più ampio processo di trasformazione digitale del settore manifatturiero, contribuendo a rendere i processi produttivi più efficienti, flessibili e affidabili. L'adozione su larga scala di questi strumenti rappresenta una delle sfide chiave per l'industria del futuro, con il potenziale di ridefinire gli standard di qualità e di competitività a livello globale.

La Tabella 5.5 raccoglie i principali studi analizzati, evidenziando le tecnologie impiegate e il loro contributo al miglioramento della qualità nei processi manifatturieri.

Nel contesto del controllo qualità nei processi manifatturieri, l'intelligenza artificiale generativa sta emergendo come una tecnologia chiave per migliorare l'ispezione automatizzata, il rilevamento delle anomalie e l'ottimizzazione dei sistemi di monitoraggio. Tra gli approcci più diffusi, le Generative Adversarial Networks (GAN) si confermano come uno degli strumenti più adottati per il rilevamento di difetti, grazie alla loro capacità di apprendere la distribuzione dei dati normali e di identificare deviazioni anomale rispetto a tali modelli. Studi recenti hanno dimostrato come le GAN possano migliorare l'individuazione di difetti in ambienti industriali complessi, permettendo una rilevazione più precisa e automatizzata di anomalie nei processi produttivi. In particolare, il loro impiego nel settore dei semiconduttori e nei sistemi di ispezione non distruttiva ha mostrato risultati promettenti, evidenziando una maggiore accuratezza rispetto ai metodi tradizionali (Hashimoto et al., 2021; J. Singh et al., 2022).

Oltre alle applicazioni basate su immagini, un altro filone di ricerca emergente è rappresentato dall'integrazione di modelli di linguaggio avanzati (LLM) con sistemi di controllo qualità. L'utilizzo di modelli come CausalKGPT e sistemi basati su Retrieval-Augmented Generation (RAG) sta trasformando il modo in cui le informazioni vengono analizzate e interpretate nei processi industriali, permettendo una gestione più efficace delle non conformità e una migliore diagnosi delle cause dei difetti. L'integrazione di questi modelli con *knowledge graphs* specifici del settore sta portando a un'evoluzione dei sistemi di supporto decisionale, con applicazioni che spaziano dalla diagnostica aerospaziale alla produzione di materiali avanzati (B. Zhou et al., 2024; Heredia Álvarez e González Barreda, 2025).

Infine, un trend emergente di particolare rilevanza riguarda l'integrazione di modelli generativi avanzati, come le reti VAE-GAN, per il miglioramento delle strategie di manutenzione predittiva nei sistemi industriali. Questi approcci consentono di generare indicatori di salute altamente fedeli, fondamentali per la previsione delle tendenze di guasto nei macchinari critici. L'adozione di tali metodologie migliora l'affidabilità delle previsioni e riduce i tempi di inattività, contribuendo a una gestione più efficiente delle risorse produttive. In particolare, nel settore dell'elettronica di consumo, l'uso di reti neurali profonde e tecniche di decomposizione tensoriale sta dimostrando un impatto significativo nell'ottimizzazione della manutenzione predittiva, favorendo pratiche di produzione più sostenibili e resilienti (Zhu et al., 2024).

L'insieme di queste tendenze evidenzia come l'intelligenza artificiale generativa stia progressivamente trasformando il controllo qualità nel manifatturiero, con soluzioni sempre più avanzate per l'ispezione automatizzata e l'analisi delle anomalie. L'evoluzione delle GAN, l'integrazione con altre architetture di *deep learning*, la generazione di dati sintetici e l'adozione di modelli linguistici avanzati suggeriscono un percorso di innovazione che punta a una crescente automazione e precisione dei processi di controllo, con un impatto significativo sull'efficienza produttiva e sulla qualità dei manufatti.

Tabella 5.5. Sintesi delle ricerche sull'IA generativa applicata al controllo qualità

<b>Autori</b>	<b>Tecnologie principali</b>	<b>Tipo di contributo</b>	<b>Contributo</b>
R. Xu e W. Yan, 2020	GAN	Modello sperimentale	Mostra che i GAN possono essere efficaci per rilevare anomalie quando i dati di errore sono inclusi nel training, migliorando significativamente le prestazioni nel rilevamento dei guasti.
Heredia Álvaro e González Barreda, 2025	Combinazione LLM e Retrieval-Augmented Generation (RAG)	Modello sperimentale	Il paper dimostra come l'integrazione di LLM con fonti di conoscenza specifiche possa ottimizzare il controllo qualità, identificando le cause dei difetti e generando soluzioni utili, migliorando significativamente la gestione delle non conformità.
Paroha, 2024	GAN	Modello sperimentale	Il paper dimostra come l'integrazione di GAN e modelli di AI generativa possa migliorare il monitoraggio delle pompe sommerse, generando scenari di guasto sintetici e ottimizzando la manutenzione preventiva per incrementare affidabilità ed efficienza operativa.
Zhu et al., 2024	Combinazione GAN e VAE	Modello sperimentale	Il paper propone un approccio innovativo che utilizza VAE-GAN per generare indicatori di salute dei compressori, previsti con LSTM per una manutenzione predittiva più precisa.
Xiao et al., 2025	GAN	Modello sperimentale	Il paper introduce IGAN come soluzione innovativa per il rilevamento di anomalie non supervisionato, superando i metodi tradizionali in termini di accuratezza e tempo di inferenza.
Kong e Ni, 2022	GAN	Modello sperimentale	Il paper introduce un approccio per migliorare il rilevamento dei pattern sconosciuti nei WBM attraverso la generazione di dati sintetici con GAN.
Hou et al., 2020	GAN	Modello sperimentale	Introduce il modello MDAN, che migliora la rilevazione delle anomalie riducendo i tempi di calcolo rispetto ai metodi GAN tradizionali.
Tulbure et al., 2024	Large Language Models (LLM)	Modello sperimentale	Il paper presenta un sistema che integra YOLOR e ChatGPT-turbo per rilevare difetti su prodotti come piatti in ceramica.
J. Singh et al., 2022	GAN	Modello sperimentale	Il documento introduce un framework innovativo che utilizza DNNs per mappare orientamenti di grani in materiali cristallini e individuare difetti nei processi produttivi.

Thirwani et al., 2024	GAN	Modello sperimentale	L'articolo propone un modello GAN per migliorare le immagini acquisite da ispezioni ottiche, consentendo una rilevazione più precisa dei difetti nei pannelli fotovoltaici.
Ziabari et al., 2022	GAN	Modello sperimentale	Il framework Simurgh viene utilizzato per ispezionare componenti metallici stampati in 3D, identificando difetti come crepe e pori con maggiore precisione, riducendo il tempo di scansione.
B. Zhou, et al., 2024	Large Language Models (LLM)	Modello sperimentale	L'articolo presenta CausalKGPT, un modello che integra grafi di conoscenza causale e LLM per analizzare i difetti di qualità nella produzione aerospaziale, mostrando migliori prestazioni rispetto a modelli commerciali come ChatGPT e GPT-4.
Hashimoto et al., 2021	GAN	Modello sperimentale	L'articolo sviluppa un modello GAN con meccanismo di attenzione per rilevare anomalie nei dati dei sensori, migliorando l'accuratezza rispetto ai sistemi esistenti e riducendo i falsi positivi.
Q. Zhou, et al., 2024	GAN	Modello sperimentale	Il framework semi-supervised combina dati reali e sintetici per affrontare la scarsità e lo squilibrio dei dataset, raggiungendo un'accuratezza del 92.30% e riducendo il tasso di false negatives al 2.63%.
R. Li e Kang, 2023	GAN	Review teorica	L'articolo sintetizza le applicazioni delle tecnologie di deep learning, tra cui GAN, CNNs e RNNs, per il rilevamento e la classificazione dei difetti nei wafer.

### 5.5.1 Casi studio rappresentativi

L'intelligenza artificiale generativa sta rivoluzionando il controllo qualità nel settore manifatturiero, consentendo di analizzare in modo più approfondito e predittivo i difetti di produzione. Recenti sviluppi hanno dimostrato come l'integrazione di modelli avanzati, tra cui Large Language Models (LLM), Generative Adversarial Networks (GAN) e tecniche di Retrieval-Augmented Generation (RAG), possa migliorare significativamente la capacità di individuare anomalie, diagnosticare le cause dei difetti e ottimizzare le strategie di manutenzione. Questi approcci innovativi si stanno rivelando particolarmente efficaci in settori ad alta complessità, come l'aerospaziale, la microelettronica e l'elettronica di consumo, dove la qualità del prodotto è un fattore critico per la competitività industriale.

Un contributo innovativo è stato fornito da Bin Zhou et al. (2024), che hanno sviluppato CausalKGPT, un modello di large language model (LLM) potenziato con conoscenza causale, progettato per analizzare i difetti di qualità nell'industria aerospaziale. Questo approccio sfrutta un causal knowledge graph (CQKG) per modellare le relazioni tra i difetti e le variabili dei processi produttivi, eliminando associazioni spurie e migliorando l'accuratezza dell'analisi delle cause dei problemi di qualità. I test sperimentali hanno dimostrato che il CausalKGPT supera GPT-4 nell'identificazione delle cause dei difetti, fornendo raccomandazioni più affidabili per la risoluzione dei problemi nel settore aerospaziale.

Nel settore della microelettronica, Hashimoto et al. (2021) hanno sviluppato un sistema basato su GAN con meccanismo di attenzione per il rilevamento di anomalie nei dati dei sensori dei macchinari di produzione di semiconduttori. Questo approccio consente di identificare anomalie non rilevabili visivamente, migliorando la capacità di prevenzione dei difetti nei wafer. I risultati sperimentali hanno mostrato un incremento dell'accuratezza del 12,3% rispetto ai metodi tradizionali, dimostrando il potenziale delle GAN nel migliorare l'affidabilità dei sistemi di controllo qualità.

Un ulteriore progresso è stato introdotto da Heredia Álvaro e González Barreda (2024), che hanno sviluppato un sistema di Retrieval-Augmented Generation (RAG) per il controllo qualità nella produzione ceramica. Questo metodo combina Large Language Models (LLM) con knowledge-based systems per analizzare dati tecnici e individuare rapidamente le cause dei difetti di produzione. Il sistema è in grado di recuperare informazioni da database tecnici e suggerire strategie di mitigazione, migliorando la gestione delle non conformità e riducendo il tempo di risposta nei processi di controllo qualità. L'integrazione di questo sistema ha aumentato la capacità di rilevazione delle cause dei difetti, fornendo raccomandazioni più precise rispetto ai metodi tradizionali.

Infine, Zhu et al. (2024) hanno proposto un approccio innovativo per il controllo qualità nel settore dell'elettronica di consumo, combinando tecniche di Generative AI con modelli di Long Short-Term Memory (LSTM) per il monitoraggio della salute dei compressori centrifughi, componenti chiave nei sistemi di raffreddamento industriali. La metodologia sfrutta una combinazione di decomposizione tensoriale per l'imputazione dei dati mancanti, un modello VAE-GAN per la generazione di indicatori di salute (HI) e reti LSTM per la previsione delle tendenze di guasto. I risultati sperimentali hanno dimostrato che l'utilizzo di VAE-GAN consente di generare dati di alta qualità per il training del modello, migliorando significativamente la capacità di rilevazione precoce di anomalie e la robustezza dei sistemi di controllo qualità. Questo approccio si è dimostrato particolarmente efficace nel ridurre i tempi di inattività imprevisti e nell'ottimizzare le strategie di manutenzione predittiva.

Gli studi analizzati evidenziano come l'intelligenza artificiale generativa possa fornire un contributo sostanziale al miglioramento del controllo qualità, superando le limitazioni dei metodi tradizionali grazie all'uso di modelli avanzati capaci di generare dati sintetici realistici, analizzare informazioni tecniche complesse e prevedere difetti con maggiore accuratezza. L'integrazione di tecniche come LLM potenziati con conoscenza causale, GAN per la generazione di dati e VAE-GAN combinati con LSTM per la manutenzione predittiva, dimostra un impatto significativo nella riduzione delle non conformità e dei tempi di inattività. Guardando al futuro, la sinergia tra le GenAI e i sistemi di apprendimento incrementale rappresenta una direzione promettente per il miglioramento continuo dei processi produttivi, garantendo maggiore efficienza, riduzione degli sprechi e un livello qualitativo sempre più elevato nei prodotti finali.

## 5.6 *Produzione additiva*

La produzione additiva ha rappresentato una svolta nell'industria manifatturiera, permettendo la realizzazione di geometrie complesse, la riduzione degli sprechi di materiale e un livello di personalizzazione mai raggiunto con i metodi tradizionali. Tuttavia, l'efficienza e la qualità della stampa 3D dipendono ancora da numerosi fattori, tra cui l'ottimizzazione dei parametri di produzione, la gestione delle risorse e il controllo della qualità dei manufatti.

Nell'ambito della presente revisione della letteratura, l'applicazione dell'IA generativa al campo della produzione additiva è emersa come un tema trattato in modo relativamente limitato suggerendo che, pur essendo un ambito di crescente interesse, non è ancora stato ampiamente approfondito nella letteratura scientifica attuale. Tuttavia, questi studi, presentati nella Tabella 5.6, evidenziano il potenziale della GenAI nel superare alcune delle attuali limitazioni della produzione additiva. Grazie alla sua capacità di generare modelli ottimizzati, prevedere difetti e migliorare i processi produttivi, l'IA generativa sta influenzando sia la fase di progettazione che quella di produzione. L'uso dell'AI generativa nella produzione additiva non solo migliora l'affidabilità e la qualità dei manufatti, ma apre anche nuove prospettive per la personalizzazione su larga scala, l'ottimizzazione dei processi produttivi e l'evoluzione verso modelli di produzione più sostenibili e flessibili. Questi progressi stanno delineando un futuro in cui la stampa 3D e l'intelligenza artificiale non sono solo complementari, ma strettamente integrate in un ecosistema manifatturiero sempre più autonomo ed efficiente.

Un primo trend rilevante nell'analisi della letteratura riguarda la convergenza tra produzione additiva e modelli generativi, dando origine a sistemi di Hybrid Additive Manufacturing (HAM), in cui la generazione di dati digitali basata su AI si integra con la fabbricazione fisica. Questo approccio si sta affermando nel contesto dell'Industria 5.0, dove la combinazione di strumenti generativi con la stampa 3D consente di ottimizzare le geometrie dei prodotti, ridurre le imperfezioni e migliorare la qualità finale dei manufatti. Recenti studi hanno dimostrato che la GenAI può essere utilizzata per progettare strutture additivamente fabbricate ottimizzate, generando modelli più efficienti in termini di prestazioni meccaniche e riducendo il materiale di supporto necessario (Terziyan e Kaikova, 2024). L'adozione di questi sistemi sta inoltre facilitando una maggiore personalizzazione della produzione, permettendo di adattare le caratteristiche dei prodotti alle esigenze specifiche dei consumatori o delle condizioni d'uso.

Parallelamente, un altro sviluppo significativo riguarda l'impiego di modelli linguistici avanzati (LLM) per la generazione e l'ottimizzazione del G-code, il linguaggio che controlla il funzionamento delle stampanti 3D. L'efficienza della produzione additiva dipende in larga misura dalla configurazione dei parametri di stampa, e la GenAI sta dimostrando un potenziale significativo nel migliorare questo processo. L'utilizzo di modelli basati su machine learning e Natural Language Processing (NLP) permette di analizzare i parametri di stampa, suggerire ottimizzazioni e correggere difetti prima che si verifichino (Badini et al., 2023).

Queste tendenze suggeriscono un'evoluzione della produzione additiva verso un modello più intelligente, automatizzato e adattivo, in cui la GenAI non si limita a supportare la fase di progettazione, ma diventa un elemento centrale anche nella gestione e nel controllo della produzione. La crescente interazione tra modelli generativi, stampa 3D e sistemi di ottimizzazione basati su AI sta trasformando il settore, rendendo la produzione additiva sempre più efficiente, flessibile e sostenibile.

Tabella 5.6. Sintesi delle ricerche sull'IA generativa applicata alla produzione additiva

<b>Autori</b>	<b>Tecnologie principali</b>	<b>Tipo di contributo</b>	<b>Contributo</b>
Terziyan e Kaikova, 2024	Generico GenAI	Framework concettuale	Introduce il concetto di Hybrid Additive Manufacturing (HAM), che estende la produzione additiva tradizionale (3D printing) combinandola con strumenti di IA generativa

			per creare prodotti intelligenti in sistemi cyber-fisico-sociali dell'Industria 5.0.
Westphal, Seitz, 2024	Generico GenAI	Review teorica	Presenta una panoramica dettagliata delle applicazioni dell'IA generativa nella produzione additiva, evidenziando come possa migliorare creatività, efficienza e velocità nella progettazione e produzione.
Badini et al., 2023	Large Language Models (LLM)	Modello sperimentale	Dimostra come ChatGPT possa generare ed ottimizzare GCode per specifici materiali e stampanti, riducendo il tempo di prova da tre settimane a un'ora.
Surovi et al., 2024	Generico GenAI	Review teorica	Il paper fornisce un'analisi dettagliata delle performance di diversi strumenti GenAI nelle applicazioni di manifattura additiva, utilizzando 35 metriche organizzate in tre categorie: agnostiche, legate al dominio e specifiche per problemi.
Ramlatchan e Yaohang Li, 2022	GAN	Modello sperimentale	Il paper introduce l'uso di CGAN per generare immagini sintetiche che rappresentano il processo SLM, permettendo di esplorare combinazioni di parametri del laser non sperimentalmente testate.

### 5.6.1 Casi studio rappresentativi

I recenti sviluppi nell'integrazione dell'IA generativa e tecnologie di produzione additiva hanno dimostrato il potenziale della generazione sintetica di dati per migliorare la qualità della stampa, prevedere difetti e ottimizzare i processi produttivi. L'uso di modelli generativi per la simulazione del comportamento dei materiali durante la stampa 3D rappresenta un punto di svolta per l'industria, come dimostrano diversi studi recenti. Un esempio significativo è fornito dal lavoro di Ramlatchan e Yaohang Li (2022), che hanno sviluppato un framework basato su Conditional Generative Adversarial Networks (CGAN) per la sintesi di immagini nel processo di Selective Laser Melting (SLM). Il loro approccio ha permesso di generare immagini sintetiche di microstrutture del materiale fuso, simulando le variazioni nei parametri di processo con una precisione senza precedenti. L'uso delle CGAN ha migliorato significativamente la capacità del modello di prevedere il comportamento del materiale in diverse condizioni operative, riducendo la necessità di test sperimentali costosi e ampliando la comprensione delle dinamiche del processo di fusione selettiva mediante laser.

Un altro studio rilevante è stato condotto da Badini et al. (2023), i quali hanno esplorato le capacità di ChatGPT nel migliorare la risoluzione dei problemi nella produzione additiva. Il loro lavoro ha dimostrato come i modelli di linguaggio di grandi dimensioni possano ottimizzare il processo di generazione del G-code per la stampa 3D, migliorando la qualità del prodotto finale e riducendo i tempi di produzione e lo spreco di materiale. In particolare, ChatGPT è stato utilizzato per identificare e correggere problemi comuni nella stampa Fused Filament Fabrication (FFF), come il distacco del pezzo dal piano di stampa, la deformazione e il fenomeno dello stringing. I risultati hanno evidenziato che l'integrazione di un modello generativo nella

regolazione automatizzata dei parametri di stampa ha portato a una riduzione significativa degli errori, aumentando la ripetibilità e l'affidabilità del processo.

Parallelamente, Terziyan e Kaikova (2024) hanno introdotto il concetto di Hybrid Additive Manufacturing (HAM), un paradigma che fonde la produzione additiva tradizionale con l'intelligenza artificiale generativa per creare entità ibride intelligenti nel contesto dei sistemi cyber-fisico-sociali dell'Industria 5.0. L'approccio proposto combina la produzione fisica con la generazione di componenti digitali, utilizzando l'intelligenza artificiale per migliorare la progettazione, l'adattabilità e l'interazione sociale dei prodotti stampati. L'adozione di HAM ha il potenziale di trasformare la produzione additiva, consentendo la creazione di prodotti altamente personalizzati e adattivi, capaci di apprendere e interagire con l'ambiente circostante. L'integrazione tra stampa 3D e modelli generativi apre nuove prospettive per l'automazione avanzata, permettendo la creazione di componenti che combinano proprietà fisiche ottimizzate con capacità computazionali avanzate.

Questi studi dimostrano che l'intelligenza artificiale generativa sta ridefinendo il ruolo della produzione additiva, offrendo soluzioni innovative per la progettazione, la simulazione dei processi e il controllo della qualità. L'uso delle GAN per la generazione di dati sintetici e l'ottimizzazione dei parametri di stampa si è rivelato particolarmente efficace nel settore della fusione selettiva mediante laser, migliorando la comprensione delle microstrutture del materiale e ottimizzando le condizioni di processo. Allo stesso modo, l'impiego di modelli di linguaggio avanzati per la generazione automatizzata del G-code rappresenta un'innovazione significativa, semplificando il processo di configurazione e riducendo i margini di errore. Il futuro della produzione additiva sarà probabilmente caratterizzato da un'interazione sempre più stretta tra intelligenza artificiale generativa e tecnologie di stampa 3D, aprendo la strada a un nuovo paradigma produttivo basato sulla personalizzazione, sull'ottimizzazione in tempo reale e sull'integrazione tra mondo fisico e digitale.

## 5.7 *Analisi teorica e framework sull'GenAI*

Un'area significativa della ricerca sull'intelligenza artificiale generativa applicata al settore manifatturiero riguarda studi che non si concentrano su specifici ambiti di applicazione, ma piuttosto si propongono di fornire una panoramica complessiva delle sue potenzialità, implicazioni e sfide. Diversi lavori hanno esplorato l'GenAI attraverso review teoriche e framework concettuali, analizzando il suo impatto sui processi produttivi, sulle strategie di innovazione e sull'integrazione con altre tecnologie avanzate. La crescente attenzione verso questa tecnologia è motivata dalla necessità di comprendere come essa possa essere implementata efficacemente all'interno dei sistemi produttivi, delineando sia le opportunità sia i limiti che ne derivano (Jide-Jegede e Omotesho, 2023).

Un aspetto rilevante di questa letteratura è l'elaborazione di framework di riferimento per classificare le applicazioni della GenAI nel contesto manifatturiero. Alcuni studi hanno cercato di definire in modo strutturato le aree in cui l'GenAI può apportare i maggiori benefici, identificando applicazioni chiave come l'ottimizzazione dei processi produttivi, la progettazione generativa, il miglioramento della manutenzione predittiva e la gestione della supply chain (Filz e Thiedeb, 2024). Altri lavori si sono invece concentrati sulle considerazioni teoriche e strategiche legate all'adozione dell'GenAI, evidenziando le principali sfide tecnologiche ed organizzative che ne influenzano la diffusione (Ejdys et al., 2023). Questi studi sottolineano la necessità di sviluppare modelli di governance e approcci etici per garantire un'integrazione efficace e responsabile di questa tecnologia nei contesti industriali.

Parallelamente, studi più recenti hanno esplorato il ruolo della GenAI all'interno dell'industrial metaverse, evidenziando come le tecnologie immersive e i modelli generativi possano trasformare la gestione delle operazioni produttive attraverso simulazioni avanzate e ambienti virtuali interattivi (Lăzăroiu et al., 2024b).

L'analisi della letteratura svolta in questa ricerca ha raccolto e classificato i principali contributi teorici sul tema, organizzandoli nella Tabella 5.7. Questa sintesi permette di evidenziare come gli studi accademici stiano cercando di costruire una base metodologica solida per guidare l'integrazione dell'IA generativa nel manifatturiero, fornendo una visione d'insieme sulle opportunità, i limiti e le strategie per un'adozione efficace. L'evoluzione di questa ricerca suggerisce che il successo dell'intelligenza artificiale generativa nell'industria dipenderà non solo dall'innovazione tecnologica, ma anche dalla capacità di sviluppare modelli di gestione e governance adeguati alle trasformazioni in corso.

Tabella 5.7. Principali studi teorici e framework sull'IA generativa nel settore manifatturiero

<b>Autori</b>	<b>Tecnologie principali</b>	<b>Tipo di contributo</b>	<b>Contributo</b>
Jide-Jegede e Omotesho, 2024	Large Language Models (LLM)	Review teorica	Esplora l'impatto dell'IA generativa nel rivoluzionare il settore manifatturiero, migliorando la personalizzazione, l'efficienza e l'innovazione nei processi di progettazione e produzione.
Doanh et al., 2023	Generico GenAI	Review teorica	Il paper fornisce una visione complessiva e teorica dell'impatto della GenAI sul settore manifatturiero, individuando le principali tendenze, le sfide e le opportunità per l'innovazione dei processi produttivi.
Kar et al., 2023	Large Language Models (LLM)	Review teorica	Il paper fornisce un'analisi esaustiva delle applicazioni e dei limiti della GenAI nei settori industriali.
Filz e Thiede, 2024	GAN	Framework concettuale	Propone un framework di riferimento per categorizzare le applicazioni di GenAI nel contesto industriale, evidenziando come i modelli probabilistici, il machine learning e la simulazione possano migliorare la pianificazione, l'ottimizzazione e il monitoraggio dei processi produttivi.
Lăzăroiu et al., 2024a	Generico GenAI	Review teorica	L'articolo fornisce una review teorica sull'applicazione dell'intelligenza artificiale generativa per ottimizzare i processi produttivi, inclusi design, simulazione, prototipazione e controllo qualità.
Lăzăroiu et al., 2024b	Generico GenAI	Review teorica	Il paper offre una revisione completa delle applicazioni della GenAI e dei sistemi IoRT nell'industrial metaverse.

Ghobakhloo et al. 2024	Generico GenAI	Framework concettuale	Il paper identifica dieci funzioni principali della GenAI e mostra come queste funzioni possano essere implementate in sequenza per massimizzare l'efficacia, riducendo al contempo gli impatti ambientali e promuovendo la sostenibilità sociale ed economica.
------------------------	----------------	-----------------------	---

## 6. Discussione delle opportunità, sfide e applicazioni nella GenAI per il manifatturiero

A partire dall'analisi condotta nei capitoli precedenti ed in particolare del capitolo 5 che ha fornito una panoramica sistematica delle principali aree di impatto rilevate dalla letteratura, questo capitolo si propone di discutere in maniera critica il ruolo dell'intelligenza artificiale generativa nel settore manifatturiero, valutandone le implicazioni strategiche, le sfide di implementazione e le prospettive future. L'attenzione sarà rivolta alle opportunità offerte dall'integrazione di queste tecnologie nei processi produttivi, evidenziando i benefici in termini di efficienza, innovazione e ottimizzazione della supply chain. Tuttavia, il potenziale della GenAI si accompagna a significative difficoltà tecniche e organizzative, che richiedono un'analisi delle barriere ancora presenti, dalla gestione dei dati alla sostenibilità economica e all'integrazione con le infrastrutture esistenti.

Nella seconda parte del capitolo, saranno esaminate alcune applicazioni concrete della GenAI nel settore manifatturiero attraverso casi di studio che ne dimostrano l'impatto in diversi ambiti, dalla progettazione alla manutenzione predittiva. Infine, il capitolo si chiuderà con una riflessione sulle prospettive di ricerca future, individuando le aree in cui ulteriori sviluppi potrebbero favorire un'adozione più efficace e sostenibile di queste tecnologie nel contesto industriale.

### 6.1 *Analisi delle opportunità offerte dall'IA generativa nel manufacturing*

L'introduzione di modelli generativi nel settore manifatturiero si configura sempre più come un'opportunità in grado di riconfigurare processi, prodotti e strategie di business, grazie a un insieme di funzionalità che spaziano dall'automazione alla sostenibilità. Le imprese che scelgono di integrare l'intelligenza artificiale generativa possono trarre vantaggio dall'elasticità nei processi produttivi, dall'ottimizzazione delle scelte decisionali e dall'innovazione continua di prodotti e componenti. Dall'analisi della letteratura emergono numerose applicazioni in grado di trasformare il modo in cui le aziende progettano, gestiscono e ottimizzano la produzione, introducendo livelli di automazione avanzata e capacità predittive sempre più sofisticate. In questa sezione, verranno esaminate le principali opportunità abilitate dalla GenAI nel manufacturing, con particolare attenzione al suo impatto sulla supply chain e sulla simulazione dei processi, sulla generazione di dati sintetici e sul controllo qualità, sulla progettazione di nuovi prodotti e sulla produzione additiva. L'obiettivo è fornire una panoramica delle potenzialità di questa tecnologia e del valore aggiunto che può apportare alle imprese, delineando le aree in cui il suo contributo risulta più significativo e i vantaggi concreti che ne derivano in termini di produttività e competitività.

Dall'analisi della letteratura, emerge come l'IA generativa stia contribuendo in modo significativo all'evoluzione dei processi produttivi, introducendo nuovi livelli di automazione, efficienza e adattabilità. Uno degli aspetti più rilevanti è la capacità della GenAI di analizzare e ottimizzare le operazioni industriali attraverso la modellazione avanzata e il supporto alle decisioni. L'utilizzo di modelli generativi e Large Language Models (LLM) consente di gestire in maniera più efficace flussi di dati complessi, migliorando la pianificazione della produzione e l'allocazione delle risorse. Grazie alla loro capacità di apprendere dai processi esistenti e generare soluzioni innovative, questi strumenti stanno trasformando la gestione della supply

chain e la programmazione delle attività produttive, riducendo i tempi di risposta alle variazioni della domanda e ottimizzando l'uso delle risorse disponibili. Parallelamente, la combinazione tra modelli generativi e sistemi di visione artificiale sta migliorando il monitoraggio in tempo reale delle linee produttive, permettendo di individuare inefficienze e colli di bottiglia con maggiore precisione. L'integrazione di queste tecnologie con la simulazione avanzata dei processi industriali rappresenta un ulteriore elemento di trasformazione per il settore. La capacità della GenAI di generare scenari predittivi e testare virtualmente le condizioni operative può avere un forte impatto potenziale nel modo in cui le aziende progettano e ottimizzano le proprie strategie produttive. In particolare, l'impiego di reti generative avversarie ha aperto nuove possibilità nella costruzione di ambienti di simulazione realistici, capaci di replicare le dinamiche di produzione con un livello di dettaglio senza precedenti. Questo approccio consente non solo di anticipare problemi e inefficienze, ma anche di testare configurazioni alternative prima di implementarle nella realtà, riducendo il rischio di errori e i costi di sperimentazione. L'integrazione tra simulazioni basate su GenAI e gemelli digitali sta inoltre potenziando la capacità di adattamento delle fabbriche intelligenti, permettendo ai sistemi produttivi di rispondere dinamicamente ai cambiamenti nelle condizioni operative e ottimizzare in tempo reale la configurazione delle linee di produzione (Q. Xu et al., 2024). Questa sinergia tra miglioramento dei processi produttivi e simulazione avanzata sta favorendo anche lo sviluppo di sistemi di produzione più flessibili e sostenibili. La possibilità di simulare e testare diverse strategie operative prima della loro applicazione pratica sta accelerando la transizione verso un modello di manifattura, capace di rispondere rapidamente alle richieste del mercato e di ridurre sprechi e inefficienze. Guardando al futuro, il crescente utilizzo della GenAI nei processi produttivi e nelle simulazioni industriali suggerisce un'evoluzione verso sistemi sempre più autonomi e capaci di auto-ottimizzarsi in funzione delle condizioni operative.

Un ulteriore aspetto rilevante da sottolineare è l'aumento di flessibilità che la GenAI offre alle organizzazioni. L'uso di modelli generativi e di linguaggi di grandi dimensioni (LLM) consente, ad esempio, di automatizzare la creazione di report o risposte a query non strutturate, potenziando la rapidità con cui le aziende possono adattarsi a variazioni della domanda o a mutamenti nelle linee produttive (Kar et al., 2023). In parallelo, Gli LLM stanno anche rivoluzionando il modo in cui le informazioni vengono sintetizzate e utilizzate per supportare gli operatori attraverso interfacce conversazionali, semplificando la collaborazione tra uomo e macchina. Un aspetto particolarmente interessante di questa evoluzione è il loro impiego nella generazione automatica di codice industriale, che ottimizza la scrittura di script per macchinari e processi di automazione, riducendo errori manuali e accelerando la programmazione (Xia et al., 2024). In prospettiva, questa elasticità si manifesta non solo nella fase di produzione, ma anche nella gestione delle risorse e nella manutenzione predittiva, dove la GenAI facilita la previsione tempestiva di guasti, rendendo più efficiente la pianificazione degli interventi e riducendo i tempi di fermo macchina (Liang et al., 2020; Doanh et al., 2023). Dall'analisi della letteratura emerge che la manutenzione predittiva è uno dei campi in cui la GenAI sta dimostrando il maggiore impatto. Tuttavia, è interessante notare come la sua efficacia dipenda fortemente dalla disponibilità e dalla qualità dei dati raccolti dai sensori industriali.

In questo contesto, un ulteriore elemento che amplifica le opportunità offerte dall'intelligenza artificiale generativa nel settore manifatturiero, menzionato con frequenza nelle ricerche, è la capacità di generare dati sintetici per l'addestramento di modelli avanzati, con ricadute dirette sul miglioramento dei processi di controllo qualità. La disponibilità di dataset ampi e rappresentativi costituisce infatti una delle principali sfide per l'implementazione dell'AI industriale, poiché la raccolta di dati reali è spesso onerosa, soggetta a vincoli di privacy o limitata dalla scarsa frequenza di anomalie significative. In questo contesto, dallo studio della

letteratura, si è visto come l'impiego di reti generative avversarie (GAN) e modelli di diffusione consente di superare queste barriere, creando dataset artificiali capaci di simulare condizioni operative reali con un elevato grado di fedeltà. Questa capacità di generazione sintetica apre scenari inediti sia per l'addestramento di modelli predittivi, che possono essere resi più robusti e generalizzabili, sia per il controllo qualità, che può beneficiare di algoritmi di ispezione più accurati ed efficaci nel rilevamento di difetti.

La stretta connessione tra questi due ambiti emerge chiaramente nell'ottimizzazione dei sistemi di ispezione automatizzata. La possibilità di generare immagini e segnali sintetici consente di superare la scarsità di dati disponibili per il training dei modelli di classificazione, migliorando la capacità delle reti neurali di riconoscere anomalie sottili e potenzialmente critiche per la qualità del prodotto finale (Cho et al., 2023). L'integrazione di queste tecnologie nei sistemi di monitoraggio industriale non solo permette di aumentare la precisione delle ispezioni, ma contribuisce anche alla transizione verso un approccio più predittivo, in cui la qualità non viene più valutata solo a posteriori, ma continuamente ottimizzata grazie all'analisi in tempo reale dei dati generati. In questo contesto, la generazione di dati sintetici rappresenta un valore strategico per l'addestramento di modelli di manutenzione predittiva, rendendo possibile la simulazione di scenari di degrado e guasto con maggiore accuratezza, riducendo i costi di fermo macchina e ottimizzando la gestione degli interventi. L'adozione dell'IA generativa nel controllo qualità si traduce così in un miglioramento complessivo dell'efficienza produttiva. La capacità di individuare difetti con maggiore precisione e tempestività riduce gli sprechi, minimizza le rilavorazioni e favorisce una maggiore sostenibilità dei processi produttivi. Inoltre, l'integrazione con modelli linguistici avanzati e *knowledge graphs* sta aprendo nuove prospettive per la gestione delle non conformità e l'ottimizzazione delle strategie di ispezione, grazie alla possibilità di correlare automaticamente anomalie e cause operative, migliorando il processo decisionale in tempo reale (Heredia Álvarez e González Barreda, 2025). Guardando al futuro, la combinazione tra generazione di dati sintetici e controllo qualità basato su GenAI non solo permette di superare le attuali limitazioni nella raccolta e nell'elaborazione dei dati, ma pone le basi per una nuova fase di automazione avanzata nei processi manifatturieri. La capacità di simulare, apprendere e adattarsi dinamicamente alle variazioni produttive rappresenta un passo significativo verso un modello industriale più resiliente, efficiente e competitivo.

Nella progettazione industriale, l'IA generativa ha aperto nuove prospettive, permettendo di superare i limiti degli approcci tradizionali e accelerando il ciclo di sviluppo. L'utilizzo di modelli generativi consente di esplorare un ampio spettro di configurazioni, ottimizzando la geometria dei componenti in base ai requisiti funzionali e produttivi. La combinazione con i *digital twin* sta contribuendo a una progettazione più integrata e predittiva, riducendo il numero di iterazioni fisiche necessarie per la validazione del prodotto (Kasar, e Kumar, 2024). In parallelo, l'impiego di reti generative per la creazione di strutture ottimizzate ha dimostrato un impatto significativo in termini di riduzione del peso e miglioramento delle prestazioni meccaniche, con applicazioni che spaziano dall'industria aerospaziale a quella automobilistica. Inoltre, l'IA generativa si sta affermando come uno strumento chiave per la personalizzazione di massa, abilitando modelli produttivi più flessibili e sostenibili. Questo processo di innovazione trova un'estensione naturale nella produzione additiva, che, grazie alla sua capacità di realizzare geometrie complesse con un utilizzo ottimizzato delle risorse, si configura come il complemento ideale della progettazione basata su IA generativa. La convergenza tra queste due tecnologie si traduce in una maggiore efficienza del ciclo produttivo, in cui le geometrie ottimizzate generate dall'IA possono essere direttamente stampate in 3D con un livello di precisione e affidabilità sempre più elevato. L'integrazione di modelli generativi con i processi additivi consente non solo di migliorare le prestazioni strutturali dei prodotti, ma anche di ridurre

i tempi di sviluppo e il materiale di scarto, contribuendo così a una produzione più sostenibile. Un aspetto particolarmente rilevante è rappresentato dall'adozione di tecniche avanzate di ottimizzazione del G-code, che permettono di affinare i parametri di stampa in tempo reale, migliorando la qualità e la ripetibilità dei manufatti (Badini et al., 2023). Questa sinergia tra progettazione generativa e produzione additiva sta portando alla nascita di un nuovo paradigma manifatturiero, in cui i confini tra ideazione e realizzazione si fanno sempre più sfumati. L'uso combinato di algoritmi generativi, *digital twin* e stampa 3D sta delineando un ecosistema produttivo più adattivo e automatizzato, in grado di rispondere con maggiore rapidità alle esigenze del mercato e di supportare modelli di produzione personalizzati e on-demand. L'IA generativa non si limita più a un ruolo di supporto alla progettazione o all'ottimizzazione dei processi, ma diventa un elemento di integrazione che connette in modo fluido tutte le fasi della catena del valore manifatturiera.

La sostenibilità rappresenta un altro ambito in cui l'IA generativa sta offrendo contributi significativi. Integrata con strategie di economia circolare, la GenAI favorisce l'adozione di materiali ecologici e ottimizza il riuso e il recupero, grazie alla capacità di analizzare grandi quantità di dati e simulare virtualmente il ciclo di vita dei prodotti. Studi su casi aziendali (Ghobakhloo et al., 2024) evidenziano, infatti, un miglioramento nella gestione delle risorse, con una riduzione degli scarti e dei costi energetici. Un esempio concreto è lo Smart Product Platforming, che sfrutta la GenAI per personalizzare i prodotti in base alle esigenze dei clienti, ottimizzando al contempo l'uso di materiali riciclati e processi produttivi a basso impatto ambientale (Akhtar et al., 2024). Questo approccio non solo incrementa l'efficienza produttiva, ma rappresenta anche un passo concreto verso una manifattura più sostenibile. L'integrazione di modelli generativi in questi sistemi favorisce la riduzione degli sprechi e un miglioramento complessivo dell'efficienza nell'intero ciclo di vita del prodotto. L'analisi della letteratura fa emergere quindi un panorama dove l'adozione dell'IA generativa per la sostenibilità è ancora in una fase iniziale, ma i risultati preliminari suggeriscono un potenziale significativo. Tuttavia, affinché questi benefici possano tradursi in un impatto industriale su larga scala, sarà necessario integrare questi strumenti con strategie di produzione più ampie, come il Life Cycle Assessment (LCA) e le tecnologie di tracciabilità digitale dei materiali.

In sostanza, l'IA generativa offre la possibilità di un salto qualitativo per l'intero settore manifatturiero, con un impatto che tocca l'ottimizzazione e la simulazione dei flussi di lavoro, la progettazione di nuovi prodotti, la generazione di dati sintetici, il controllo qualità e l'integrazione con altre tecnologie all'avanguardia. La capacità di queste tecnologie di migliorare l'efficienza produttiva, aumentare la resilienza organizzativa e potenziare la sostenibilità dei processi produttivi rappresenta un'opportunità senza precedenti.

Tuttavia, affinché questi benefici possano tradursi in un vantaggio competitivo concreto e sostenibile nel lungo periodo, è necessario interrogarsi sulle sfide ancora aperte. L'efficacia dell'IA generativa non dipende solo dalla potenza dei modelli, ma anche dalla qualità dei dati, dall'integrazione con le infrastrutture esistenti e dalla capacità delle imprese di ripensare i propri processi in un'ottica realmente data-driven. Inoltre, l'adozione su larga scala di queste tecnologie solleva questioni etiche e normative che non possono essere trascurate, in particolare per quanto riguarda la trasparenza delle decisioni automatizzate e la responsabilità in caso di errori. Se da un lato il potenziale trasformativo della GenAI nel manufacturing è evidente, dall'altro la sua implementazione richiede un cambio di paradigma che va oltre la semplice adozione tecnologica, coinvolgendo aspetti strategici, culturali e organizzativi. In questo senso, il successo della transizione dipenderà non solo dagli sviluppi scientifici e tecnici, ma anche dalla capacità

dell'industria di gestire con consapevolezza questa rivoluzione, evitando di limitarsi a una digitalizzazione superficiale e puntando invece a un reale ripensamento dei modelli produttivi.

Proprio in questa direzione emergono le principali sfide tecniche e organizzative che potrebbero ostacolare l'adozione efficace della GenAI nel settore manifatturiero. La necessità di grandi quantità di dati, le difficoltà di integrazione con le infrastrutture esistenti, i costi computazionali e le resistenze organizzative rappresentano nodi critici che richiedono un'analisi approfondita. È quindi essenziale analizzare nel dettaglio queste sfide per comprendere fino a che punto l'IA generativa possa realmente inserirsi nei processi produttivi tradizionali. La sezione successiva si propone di esplorare questi aspetti, evidenziando le principali barriere che le aziende devono affrontare nel percorso verso una manifattura più intelligente e automatizzata.

## 6.2 *Discussione delle principali sfide tecniche e organizzative*

Nel contesto dell'IA generativa applicata ai processi manifatturieri, nel contesto della letteratura analizzata, l'entusiasmo suscitato dalle potenzialità di questa tecnologia si accompagna a una serie di sfide, tanto sul fronte strettamente tecnico quanto sul piano organizzativo.

Una delle criticità più ricorrenti emerse in letteratura riguarda la necessità di grandi volumi di dati di alta qualità a scopo di addestramento: la dipendenza da dataset estesi e ben strutturati, essenziali per abilitare modelli come GAN o LLM, può limitare le performance della tecnologia laddove i dati risultino scarsi o di bassa qualità (Kar et al., 2023; Ghobakhloo et al., 2024). Nei casi in cui i dati siano disponibili, inoltre, si pone il rischio di bias incorporati nei modelli, in quanto le distorsioni presenti nel set di addestramento possono riflettersi nelle decisioni o nelle sintesi fornite dall'IA (Doanh et al., 2023). Ciò solleva questioni etiche, poiché l'uso di dati non rappresentativi potrebbe portare a decisioni discriminatorie o ingiuste, rendendo necessaria una regolamentazione più rigorosa per garantire equità e trasparenza nei processi industriali. In particolare, questa criticità è particolarmente rilevante nelle aziende manifatturiere che operano in settori regolamentati, dove l'adozione di IA generativa senza adeguati controlli può compromettere la conformità normativa e la fiducia del mercato. Tale scenario induce molte imprese a valutare con grande cautela qualsiasi soluzione di GenAI, in modo da evitare sanzioni o danni reputazionali legati a un uso inappropriato dei dati.

Dal punto di vista economico, l'adozione della GenAI rappresenta una sfida significativa per molte aziende, soprattutto a causa dei costi iniziali elevati e dell'incertezza sui ritorni dell'investimento. Sebbene nel lungo periodo la GAI possa generare benefici economici, le spese per la formazione del personale e l'implementazione di infrastrutture di calcolo adeguate possono scoraggiare le imprese, in particolare le PMI, che dispongono di risorse limitate (Kar et al., 2023; Doanh et al., 2023). Un recente studio del MIT evidenzia che mentre il 77% delle aziende con oltre 10 miliardi di dollari di fatturato sta implementando casi d'uso dell'IA, solo il 4% delle imprese con un fatturato compreso tra 100 e 499 milioni ha iniziato a implementare casi d'uso in produzione (MIT Technology Review Insights, 2024). A ciò si aggiungono gli elevati costi computazionali legati all'addestramento e all'esecuzione di modelli avanzati, che richiedono hardware costoso e consumano ingenti quantità di energia (Filz e Thiede, 2024; Liang et al., 2020). Il costo del mantenimento e dell'aggiornamento dei modelli IA è considerato un ostacolo rilevante dal 38% dei produttori, rendendo ancora più complessa la scalabilità delle soluzioni IA all'interno delle aziende manifatturiere (MIT Technology Review Insights, 2024). L'assenza di best practice consolidate per quantificare con certezza i benefici economici della GenAI contribuisce ulteriormente a frenare la sua adozione, generando incertezza e rallentando

la trasformazione digitale. Tuttavia, soluzioni come il *cloud computing* e l'*edge AI* potrebbero attenuare queste problematiche, permettendo alle aziende di distribuire il carico computazionale su infrastrutture scalabili e di ridurre i costi iniziali, trasformando l'onere finanziario in un servizio on demand. In questo contesto, mentre le grandi imprese possono sfruttare economie di scala per accelerare la transizione verso l'uso della GAI, le PMI potrebbero beneficiare di strategie mirate per accedere alle potenzialità dell'intelligenza artificiale senza affrontare investimenti proibitivi.

A complicare il quadro, si aggiungono i problemi di integrazione con i sistemi industriali preesistenti, in particolare in aziende manifatturiere di stampo tradizionale, dove infrastrutture legacy possono porre ostacoli all'integrazione agevole di tecnologie di IA generativa (Lazaroiu et al., 2024b). Nel suo studio, il MIT afferma che circa il 45% delle aziende segnala che il *technical debt*, dovuto in gran parte all'obsolescenza delle infrastrutture IT e alla mancanza di interoperabilità tra i sistemi OT e IT, rappresenta una barriera significativa alla scalabilità dell'IA (MIT Technology Review Insights, 2024). Nel caso di sistemi come i *digital twin* o le piattaforme di robotica avanzata, i requisiti di compatibilità e sicurezza fanno lievitare la complessità tecnica dell'implementazione (Yang et al., 2024). Inoltre, emergono nuove sfide legate all'interazione tra GenAI e tecnologie emergenti, come il metaverso industriale e i sistemi cyber-fisici, dove la gestione sicura dei dati e la conformità a regolamenti ancora in evoluzione diventano elementi critici per l'adozione su larga scala. Questo ostacolo si traduce in un rallentamento nell'adozione della tecnologia, poiché le imprese devono affrontare costi e tempi di adattamento elevati prima di poter trarre valore concreto dall'implementazione dell'IA generativa. A queste difficoltà si aggiunge inoltre la necessità di competenze specialistiche in ambiti quali data science o ingegneria del software, non sempre presenti nelle realtà manifatturiere. Secondo un recente studio di Amazon Web Services (AWS), il 75% delle aziende che considerano prioritario l'inserimento di talenti con competenze in AI riscontra difficoltà nel reperire candidati qualificati. Inoltre, quasi l'80% dei lavoratori non è a conoscenza dei programmi di formazione AI disponibili per sviluppare tali competenze (Amazon Web Services e Access Partnership, 2023). Questo evidenzia una lacuna significativa nella preparazione della forza lavoro all'adozione di nuove tecnologie e sottolinea la necessità di strategie mirate per colmare il divario di competenze. Tuttavia, la difficoltà nell'individuare o formare figure professionali adeguate rimane un ostacolo significativo da affrontare ma che necessita di proposte e soluzioni differenti in base al caso specifico. Per esempio, le aziende più strutturate potrebbero adottare programmi di *reskilling* per il personale esistente, mentre le PMI potrebbero beneficiare di consorzi industriali che facilitano l'accesso a competenze condivise, dando così luogo a una trasformazione digitale più inclusiva e sostenibile.

Sul piano organizzativo, la resistenza al cambiamento rappresenta una criticità trasversale, amplificata dall'integrazione di sistemi di automazione evoluta e di strumenti "black box", ossia tecnologie o algoritmi, come alcuni modelli di intelligenza artificiale, il cui funzionamento interno non è immediatamente comprensibile o accessibile agli utenti. Il 43% dei dirigenti intervistati da MIT Technology Review Insights (2024) indica che le difficoltà di adattamento organizzativo rappresentano uno degli ostacoli più rilevanti all'implementazione dell'IA. L'opacità dei sistemi generativi può suscitare diffidenza, sia per il timore di una riduzione del personale sia per la percezione di scarsa trasparenza nei processi decisionali, specialmente in settori come il manifatturiero, dove la tracciabilità delle decisioni è fondamentale, ostacolando ulteriormente il processo di integrazione (Doanh et al., 2023; Jide-Jegede e Omotesho, 2024). La questione della interpretabilità diventa quindi un aspetto cruciale: l'impossibilità di spiegare chiaramente il funzionamento di modelli generativi come GAN o LLM può minare la fiducia dei tecnici e rallentare l'adozione su larga scala (Ghobakhloo et al., 2024). Inoltre, la mancanza

di standardizzazione e di pratiche comuni per l'audit dei modelli aggrava ulteriormente questo problema. Per mitigare tali criticità, un approccio promettente consiste nell'adozione di sistemi di explainable AI (XAI), che permettano di rendere più comprensibili i processi decisionali delle IA generative, affiancati da framework di governance dei modelli che definiscano criteri chiari per la validazione, la certificazione e l'audit. La trasparenza potrebbe inoltre essere migliorata attraverso programmi di coinvolgimento attivo dei lavoratori, volti a ridurre la percezione di rischio e favorire un'integrazione più armoniosa della tecnologia nei processi produttivi.

Un ultimo nodo cruciale, messo in luce da molteplici ricerche, riguarda la sicurezza e la privacy dei dati. Secondo il 38% dei produttori intervistati nello studio del MIT Technology Review Insights (2024), la protezione dei dati è una sfida chiave, in un contesto in cui le aziende devono affrontare problemi di sicurezza e conformità. La condivisione di informazioni sensibili tra sistemi IA e piattaforme di calcolo esterne può esporre l'azienda al rischio di fughe di informazioni o manipolazioni fraudolente (Kar et al., 2023; Filz e Thiede, 2024). Nel caso della manutenzione predittiva, ad esempio, i dati di funzionamento delle macchine potrebbero essere di grande interesse competitivo e imporre agli sviluppatori di IA generativa di adottare misure robuste di cifratura e controllo degli accessi. A questo si aggiungono anche i temi di regolamentazione e compliance: poiché la normativa riguardante l'uso dell'IA in contesti industriali è ancora in evoluzione, mancano standard consolidati che garantiscano un'implementazione sicura e trasparente, lasciando alle aziende incertezze su come allinearsi a futuri requisiti legali (Doanh et al., 2023; Jide-Jegede e Omotesho, 2024). Un ulteriore sviluppo potrebbe derivare dalla creazione di certificazioni e framework di compliance specifici per l'uso dell'IA generativa nel settore manifatturiero, garantendo standard chiari per la protezione dei dati e l'interoperabilità delle soluzioni.

In conclusione, l'adozione dell'IA generativa nel settore manifatturiero, sebbene promettente, è accompagnata da significative sfide tecniche e organizzative che ne ostacolano la diffusione su larga scala. La necessità di dati di alta qualità, i costi elevati, le difficoltà di integrazione con sistemi preesistenti e la carenza di competenze specialistiche rappresentano ostacoli concreti che le aziende devono affrontare con strategie mirate. Inoltre, la resistenza al cambiamento, la mancanza di trasparenza nei modelli generativi e le preoccupazioni legate alla sicurezza e alla conformità normativa impongono un approccio cauto e ben strutturato. Tuttavia, attraverso soluzioni come il *cloud computing*, l'*edge AI*, l'adozione di framework di explainable AI (XAI) e politiche di formazione avanzate, le imprese possono mitigare molte di queste barriere, avviando un percorso di trasformazione digitale più inclusivo e sostenibile. La chiave per un'implementazione efficace risiede dunque in un equilibrio tra innovazione e gestione consapevole dei rischi, garantendo così un'integrazione dell'IA generativa che sia vantaggiosa sia dal punto di vista produttivo che etico.

### 6.3 *Implicazioni della GenAI per l'industria: applicazioni e casi studio*

L'analisi delle opportunità e delle sfide connesse all'adozione dell'IA generativa nel settore manifatturiero evidenzia un quadro complesso e sfaccettato. Se da un lato, le potenzialità di questa tecnologia stanno già trasformando i processi produttivi, dall'altro persistono ostacoli significativi che ne limitano l'adozione su larga scala.

In questo scenario di duplice natura della GenAI, risulta fondamentale analizzare come aziende leader del settore abbiano implementato con successo l'IA generativa nei loro processi. Per esplorare meglio queste dinamiche, nelle sezioni successive vengono esaminati alcuni casi studio aziendali che rappresentano esempi concreti di come la GenAI stia influenzando il settore

manifatturiero e logistico. Tali esempi evidenziano come l'IA generativa stia ridefinendo le strategie operative nel settore industriale, contribuendo a migliorare l'efficienza, la flessibilità e la resilienza dei processi produttivi e logistici. Queste innovazioni aprono nuove prospettive per il settore, accelerando la trasformazione digitale e ponendo le basi per un'industria più interconnessa e intelligente.

### 6.3.1 Il caso Amazon, Microsoft e Airbus: IA generativa per la gestione della supply chain e l'automazione dei processi aziendali

La letteratura ha evidenziato come l'IA generativa possa ottimizzare la gestione della supply chain, migliorando la previsione della domanda, l'allocazione delle risorse e la resilienza dei processi produttivi (Meier et al., 2024; L. Li et al., 2024). In particolare, il framework DeFACT proposto da Yang et al. (2024) integra modelli generativi e blockchain per creare un'ecologia collaborativa nella supply chain, garantendo maggiore sicurezza e personalizzazione della produzione. Un caso esemplare di implementazione pratica è l'utilizzo dell'IA generativa da parte di Amazon attraverso Amazon Bedrock e AWS Supply Chain, che permettono di automatizzare e ottimizzare il procurement, la gestione delle scorte e la pianificazione della domanda. Grazie a modelli avanzati di machine learning e NLP, questi strumenti unificano e centralizzano i dati provenienti da diverse fonti, migliorando la tracciabilità dei processi decisionali e semplificando la gestione della supply chain con insight predittivi. L'automazione del procurement consente di generare, approvare e gestire ordini di acquisto con un elevato grado di precisione, riducendo errori manuali e tempi di elaborazione. L'integrazione con sistemi di estrazione automatizzata di dati, da documenti, come Amazon Textract, permette inoltre di confrontare fatture, ordini e ricevute di consegna in modo rapido ed efficiente, garantendo il rispetto dei contratti e una gestione più fluida dei pagamenti. Inoltre, l'uso della knowledge management attraverso tecniche di Retrieval-Augmented Generation (RAG) con Amazon Bedrock Agents consente un accesso contestualizzato alle informazioni aziendali, supportando le decisioni strategiche con dati aggiornati. L'analisi predittiva applicata alla supply chain migliora la gestione dell'inventario, riducendo il rischio di scorte in eccesso o insufficienti, ottimizzando la pianificazione della produzione e migliorando la gestione della domanda. L'impiego di modelli generativi accelera l'adattamento ai cambiamenti del mercato, consentendo alle aziende di rispondere più rapidamente a variazioni della domanda o a imprevisti nella supply chain. Grazie alle capacità di integrazione di Amazon Bedrock con altri servizi AWS, è possibile facilitare la collaborazione tra team interni e fornitori, migliorando la comunicazione e automatizzando i processi decisionali. Le funzionalità di previsione della domanda e di ottimizzazione dell'approvvigionamento aiutano a ridurre i costi operativi e migliorare l'efficienza delle operazioni logistiche. L'adozione di sistemi avanzati di monitoraggio e gestione delle informazioni consente inoltre una maggiore trasparenza lungo tutta la catena del valore, garantendo una migliore gestione dei rischi e una maggiore conformità alle normative aziendali e di settore. L'integrazione di questi strumenti ha permesso ad Amazon di trasformare la gestione della supply chain, riducendo inefficienze, migliorando la capacità di adattamento e ottimizzando le operazioni su larga scala. Questi sviluppi rappresentano un modello per le aziende che vogliono adottare soluzioni AI avanzate per ottimizzare la propria logistica e migliorare la gestione delle operazioni di procurement e distribuzione (Kurian e Petrashka, 2024).

Oltre all'uso di Amazon Bedrock e AWS Supply Chain per l'ottimizzazione della gestione delle scorte e della pianificazione della domanda, un ulteriore esempio dell'applicazione della GenAI nei processi aziendali è rappresentato da Microsoft Dynamics 365 Copilot. Questo

strumento, integrato nei sistemi ERP (Enterprise Resource Planning) e CRM (Customer Relationship Management), sfrutta l'intelligenza artificiale generativa per automatizzare attività aziendali ripetitive, migliorare la gestione dei dati e supportare la presa di decisioni strategiche. Nell'ambito della supply chain e del procurement, Dynamics 365 Copilot, attraverso il Microsoft Supply Chain Center, consente di identificare potenziali interruzioni nella catena di approvvigionamento, sfruttando insight predittivi basati su dati esterni come condizioni meteorologiche, problemi finanziari o geografici. Inoltre, aiuta i pianificatori della supply chain a mitigare i rischi, generando automaticamente notifiche e comunicazioni per i partner coinvolti con l'intento di garantire la continuità operativa. Grazie alla sua capacità di integrare informazioni provenienti da diverse fonti, Copilot migliora la visibilità operativa e facilita l'automazione di processi aziendali, riducendo il tempo speso in attività manuali e ottimizzando la gestione delle informazioni strategiche (Lamanna, 2023).

Parallelamente, anche in altri settori emergono esempi significativi di come l'IA generativa possa trasformare i processi aziendali. Airbus (2024), ad esempio, spiega come l'impiego dell'intelligenza artificiale è iniziato già nel 2016 con OneAtlas, che ha permesso di elaborare immagini satellitari ad alta risoluzione e fornire informazioni utili a settori come l'agricoltura, le assicurazioni e l'energia. Nel 2017, la piattaforma digitale Skywise ha migliorato la manutenzione predittiva e ridotto i rischi di guasto degli aeromobili in servizio. Inizialmente l'uso dell'IA era limitato a ingegneri specializzati e data scientist, ma con l'avvento dell'IA generativa il suo potenziale si è ampliato in modo esponenziale, rendendo la tecnologia accessibile a molte più persone all'interno dell'azienda.

Per sfruttare al meglio queste opportunità, Airbus ha avviato nel 2023 un gruppo di lavoro interno dedicato, con l'obiettivo di integrare grandi modelli di linguaggio e modelli di base nei processi aziendali, delineando al contempo politiche e meccanismi di salvaguardia che garantiscano un uso responsabile e coerente con i valori fondamentali della società. In meno di un anno, sono stati identificati oltre 600 casi d'uso per l'IA generativa che spaziano dall'ottimizzazione dei processi interni al miglioramento delle relazioni con i clienti, fino all'automazione di task ripetitivi. In ambito supply chain e procurement, per esempio, vengono esplorate soluzioni per l'analisi di contratti, l'automazione di processi di acquisto e il supporto alla gestione delle scorte, in modo analogo a quanto fatto da Amazon. Altri progetti riguardano la manutenzione, la sicurezza informatica e la gestione del rischio. L'abilità dell'IA di supportare il lavoro umano su documentazione tecnica complessa risulta particolarmente promettente: un esperimento mira a supportare i team di post-vendita nella fornitura di risposte più rapide ai clienti, mentre un altro, testato su larga scala, utilizza un assistente AI per interpretare e consultare rapidamente le Standard Operating Instructions (le istruzioni operative necessarie per assemblare gli aeromobili). Come evidenziato da Fabrice Valentin, responsabile AI e Advanced Analytics di Airbus, l'accesso semplificato a dati tecnici permette di recuperare in pochi istanti informazioni essenziali, come la tipologia di chiave dinamometrica da usare in una determinata operazione, laddove in passato era necessario sfogliare manualmente numerose pagine di documentazione. Tuttavia, come evidenziato è improbabile che la GenAI possa progettare nuovi prodotti Airbus da zero: il suo valore principale risiede nel supporto alle attività umane, in particolare nella gestione di documentazione tecnica complessa e nei processi aziendali. Sebbene i risultati iniziali siano incoraggianti, un'implementazione su larga scala richiederà più tempo, in parte a causa delle rigide normative del settore aerospaziale e della volontà di garantire che le soluzioni di IA generativa siano sicure, etiche, sostenibili e allineate ai valori aziendali, come sottolineato da Catherine Jestin, Executive Vice President Digital di Airbus (Airbus, 2024).

### 6.3.2 Il caso Bosch e Siemens: IA generativa per generazione di dati sintetici e la manutenzione industriale.

La letteratura più recente evidenzia come le tecniche basate su Generative Adversarial Networks (GAN) e *data augmentation* possano migliorare in modo significativo la rilevazione e la classificazione dei difetti in sistemi industriali, specialmente quando si dispone di dataset sbilanciati o non sufficientemente rappresentativi (Pinetz et al., 2019; Da Silva et al., 2021).

Un esempio concreto di questa evoluzione è rappresentato dall'uso dell'IA da parte di Bosch nel controllo qualità della produzione di statori per motori elettrici nello stabilimento di Hildesheim, in Germania. Qui, la GenAI viene impiegata per generare immagini sintetiche di difetti noti e potenziali, consentendo di addestrare i modelli di ispezione automatizzata anche in assenza di un dataset sufficientemente rappresentativo. Il problema principale nell'implementazione dei sistemi di ispezione visiva basati su AI è infatti la necessità di grandi quantità di immagini di difetti, che in un processo produttivo altamente efficiente come quello di Bosch risultano naturalmente scarse. La GenAI permette di superare questo ostacolo attraverso il domain transfer, ovvero l'adattamento di immagini di prodotti simili per creare nuovi dati sintetici utili all'addestramento dell'AI. In questo modo, il sistema di visione artificiale può riconoscere anche difetti che potrebbero non essersi ancora verificati nella produzione reale. Durante la produzione degli statori, i fili vengono saldati per garantire il corretto flusso di corrente nel motore elettrico e possono presentare sei tipi di difetti differenti, tra cui fori microscopici, depositi di materiale indesiderati e saldature deboli. Per ottimizzare la rilevazione di questi difetti, Bosch ha generato circa 15.000 immagini sintetiche a partire da un numero limitato di immagini reali, accelerando l'addestramento e migliorando l'accuratezza del sistema di ispezione automatizzata. Il primo impianto pilota di Hildesheim, attivato a fine 2023, ha dimostrato che l'AI, una volta addestrata, può individuare errori con una precisione quasi del 100%, contro il 70-90% della verifica umana, consentendo una riduzione della durata del progetto di sei mesi rispetto ai metodi tradizionali e un incremento annuo della produttività quantificabile in centinaia di migliaia di euro (Bosch, 2023).

Parallelamente, Siemens ha introdotto una nuova funzionalità basata sulla Generative AI all'interno del suo sistema Senseye Predictive Maintenance, segnando un ulteriore passo verso l'evoluzione della manutenzione industriale. L'integrazione della GenAI con il machine learning consente di trasformare la manutenzione predittiva in manutenzione prescrittiva, ottimizzando i processi decisionali attraverso un'interfaccia conversazionale che rende l'accesso alle informazioni più immediato e intuitivo. Questa evoluzione consente agli operatori di interagire direttamente con il sistema, accelerando le diagnosi e facilitando l'individuazione delle azioni correttive più efficaci. Senseye Predictive Maintenance è in grado di elaborare dati provenienti da diverse fonti, analizzando informazioni non strutturate e contestualizzandole all'interno di strategie di manutenzione più avanzate. Il sistema permette inoltre di scalare la conoscenza interna delle aziende, utilizzando la GenAI per recuperare, aggregare e rendere accessibili esperienze e protocolli operativi pregressi. In questo modo, le imprese possono ottimizzare le proprie operazioni senza dover necessariamente disporre di personale altamente specializzato, contrastando così la crescente carenza di competenze nel settore. Il tutto avviene in un ambiente cloud privato, garantendo la massima sicurezza e riservatezza delle informazioni sensibili. L'adozione di Senseye Predictive Maintenance da parte di aziende come BlueScope, produttore australiano di acciaio, ha dimostrato il potenziale della tecnologia nel migliorare la gestione delle anomalie e nel facilitare la condivisione della conoscenza tra team distribuiti a livello globale, rafforzando al tempo stesso le strategie di trasformazione digitale (Siemens, 2024).

### 6.3.3 Il caso Siemens per l'automazione intelligente della programmazione industriale

La ricerca ha evidenziato che l'adozione di modelli linguistici avanzati, opportunamente adattati attraverso fine-tuning iterativo, può migliorare significativamente la precisione della generazione automatica di codice per il controllo delle macchine industriali. Questa evoluzione tecnologica non solo agevola l'automazione della programmazione, ma contribuisce anche alla standardizzazione dei sistemi di produzione, riducendo la variabilità e migliorando l'efficienza operativa (Xia et al., 2024).

In questo contesto, Siemens ha inoltre sviluppato l'Industrial Copilot, un assistente basato sull'intelligenza artificiale generativa, progettato per supportare gli ingegneri nell'automazione della scrittura del codice per i controllori logici programmabili (PLC). Questa tecnologia consente di trasformare input in linguaggio naturale in codice funzionale, semplificando drasticamente la programmazione delle macchine industriali e riducendo il margine di errore. Grazie alla collaborazione con Schaeffler, il sistema è stato integrato direttamente in contesti produttivi reali, dimostrando la sua capacità di velocizzare lo sviluppo del codice, minimizzare gli errori e facilitare la transizione verso fabbriche sempre più automatizzate e digitalizzate.

L'Industrial Copilot è connesso al framework Totally Integrated Automation (TIA) Portal di Siemens tramite l'API TIA Portal Openness, consentendo una perfetta integrazione con gli ambienti di sviluppo già esistenti. Ciò risponde a una delle criticità più rilevanti riscontrate in letteratura, ovvero la difficoltà di integrare soluzioni di IA generativa in infrastrutture legacy già operative. Gli ingegneri possono generare codice per PLC senza dover scrivere manualmente ogni riga, ma semplicemente descrivendo in linguaggio naturale le funzionalità desiderate. Questo approccio non solo riduce i tempi di sviluppo, ma democratizza l'accesso alla programmazione industriale, permettendo anche a tecnici con minore esperienza di contribuire attivamente alla configurazione dei sistemi.

Oltre alla scrittura del codice, l'Industrial Copilot è in grado di rilevare errori e suggerire correzioni, sfruttando l'accesso immediato a documentazione tecnica, linee guida e manuali operativi. Grazie a queste capacità, gli operatori possono identificare rapidamente le cause di eventuali malfunzionamenti e ottenere istruzioni dettagliate per risolverli, riducendo così i tempi di fermo macchina e aumentando la continuità operativa. Questa caratteristica è particolarmente rilevante in un settore in cui anche pochi minuti di inattività possono tradursi in perdite economiche significative (Siemens, 2023)

Inoltre, la possibilità di fornire assistenza immediata e suggerimenti contestualizzati contribuisce a rendere più trasparente il funzionamento dell'IA nel processo industriale. Sebbene il tema dell'interpretabilità dei modelli generativi rimanga un aspetto rilevante, l'integrazione dell'Industrial Copilot con il TIA Portal favorisce una maggiore tracciabilità delle modifiche al codice, semplificandone la gestione e facilitando eventuali audit. Questo approccio consente di migliorare il controllo sui processi di automazione e può supportare le aziende nel mantenere la conformità a standard industriali in evoluzione.

L'adozione dell'Industrial Copilot risponde anche alla crescente carenza di ingegneri specializzati nel settore dell'automazione industriale, evidenziata da molti studi in letteratura. Automatizzando le attività più ripetitive e laboriose, la tecnologia libera risorse per compiti ad alto valore aggiunto e consente ai lavoratori meno esperti di acquisire competenze avanzate in tempi più rapidi. Questo contribuisce a ridurre la resistenza al cambiamento, poiché le barriere di ingresso alla programmazione industriale si abbassano e il personale può gradualmente familiarizzare con l'IA generativa in un contesto guidato e strutturato. Secondo Siemens, questa tecnologia rappresenta l'inizio di una nuova era nell'automazione industriale, in cui la

comunicazione tra uomo e macchina diventa più intuitiva ed efficiente, rendendo l'IA un pilastro fondamentale della trasformazione digitale nel settore manifatturiero (Siemens, 2023).

#### 6.3.4 Il caso Toyota: IA generativa per l'ottimizzazione del design e lo sviluppo accelerato dei veicoli

La letteratura più recente mostra come l'IA generativa, integrata con metodologie di progettazione avanzate, possa contribuire a una riduzione dei tempi e dei costi di sviluppo prodotto (Kasar e Kumar, 2024). In particolare, l'impiego di approcci ispirati alle reti generative avversarie (GAN) e ad algoritmi di ottimizzazione consente di esplorare ampi spazi di design, bilanciando criteri estetici e vincoli tecnici (Broo, 2023). Un esempio concreto di questa integrazione è rappresentato dal nuovo strumento sviluppato dal Toyota Research Institute (TRI), il quale permette di incorporare vincoli ingegneristici (come la resistenza aerodinamica o le dimensioni del telaio) sin dalla fase iniziale di progettazione. Grazie a un algoritmo che combina principi della teoria dell'ottimizzazione e capacità generative testo-immagine, il designer può formulare prompt orientati a una determinata estetica (“elegante”, “simile a un SUV”, “moderno”) e, allo stesso tempo, ottenere design già ottimizzati su parametri chiave come la riduzione della resistenza o l'ergonomia. L'approccio di Toyota ha quindi il potenziale di ridurre il numero di iterazioni necessarie tra le fasi di ideazione creativa e validazione tecnica, favorendo lo sviluppo rapido di veicoli elettrificati con migliore efficienza aerodinamica e prestazioni ottimali (Toyota, 2024). Questa soluzione pone le basi per un nuovo paradigma di progettazione, in cui l'IA generativa non è soltanto uno strumento ispirazionale, ma diventa parte integrante della progettazione ingegneristica.

## 7. Conclusione

### 7.1 *Proposte per future linee di ricerca*

L'analisi condotta in questa tesi ha evidenziato il ruolo crescente dell'intelligenza artificiale generativa nel settore manifatturiero, con impatti significativi sulla progettazione, l'ottimizzazione dei processi, la simulazione avanzata, la generazione di dati sintetici per l'addestramento di modelli predittivi e il controllo qualità. Tuttavia, nonostante i progressi, restano numerose sfide che richiedono un approfondimento sistematico per garantire una maggiore efficacia e scalabilità di queste tecnologie nel contesto industriale.

Un ambito di ricerca di primaria importanza riguarda il miglioramento dell'affidabilità e della robustezza dei modelli generativi applicati alla produzione, con particolare attenzione alla generazione di dati sintetici, progetti ottimizzati e scenari produttivi simulati. Affinché queste soluzioni possano essere adottate in contesti industriali e produttivi reali, è fondamentale garantire la loro validità e coerenza, evitando che le decisioni derivate da modelli generativi siano inficiate da errori o distorsioni. Un aspetto particolarmente critico è rappresentato dalla mitigazione delle cosiddette "allucinazioni", ossia la generazione di output apparentemente plausibili ma privi di fondamento tecnico o fisico, fenomeno che può compromettere l'affidabilità delle soluzioni proposte. Per affrontare questa problematica, la ricerca futura dovrebbe concentrarsi sull'integrazione di tecniche avanzate di verifica e validazione dei risultati generati, combinando approcci basati su modelli generativi con metodologie più rigorose, come simulazioni fondate sulla fisica computazionale o l'utilizzo di dati sperimentali reali. La sinergia tra questi approcci consentirebbe di rafforzare il controllo sulla qualità degli output generati, riducendo l'incidenza di errori e garantendo che i modelli siano in grado di produrre soluzioni non solo innovative, ma anche affidabili e coerenti con i vincoli fisici e tecnici del dominio applicativo. L'integrazione di queste strategie di validazione, oltre a migliorare la robustezza dei modelli, rappresenta un passaggio essenziale per favorire l'adozione su larga scala delle tecnologie generative nell'ambito produttivo, consentendo di sfruttarne appieno il potenziale senza esporre i processi decisionali a rischi inaccettabili derivanti da risultati non verificati o incoerenti con la realtà fisica e operativa del sistema produttivo.

Un secondo ambito di grande interesse riguarda la questione dell'interpretabilità dei modelli generativi. Sebbene la GenAI abbia dimostrato un enorme potenziale nella generazione di contenuti e nella simulazione di scenari produttivi, la natura "black box" di molti algoritmi ne ostacola l'adozione in contesti regolamentati. In questa direzione, un'area di ricerca promettente che alcuni studi stanno iniziando ad esplorare e che potrebbe essere approfondita in futuro è rappresentata dall'integrazione di tecniche di Explainable AI (XAI) nei framework generativi, ovvero strumenti e metodologie che rendono più comprensibile e trasparente il funzionamento dei modelli di IA, così da aumentare la trasparenza delle decisioni prese dai modelli e migliorarne l'accettabilità da parte degli operatori industriali (Schneider, J., 2024).

Sulla stessa scia, l'armonizzazione con framework etici e regolatori appare un ulteriore ambito di studio, dal momento che la creazione di linee guida condivise e buone pratiche consentirebbe di definire standard di sicurezza, tutela dei dati e responsabilità nella gestione di eventuali bias. La ricerca futura dovrebbe concentrarsi sulla standardizzazione delle pratiche per l'adozione della GenAI nel settore manifatturiero. Questo aspetto diventa particolarmente rilevante per

affrontare problematiche legate alla proprietà intellettuale, alla trasparenza dei modelli e alla gestione della cybersecurity nei processi di generazione automatizzata.

Un ulteriore asse di ricerca di particolare rilevanza riguarda lo sviluppo di modelli di intelligenza artificiale generativa più sostenibili e meno onerosi dal punto di vista energetico, con l'obiettivo di migliorarne l'accessibilità e favorirne un'adozione più diffusa. L'addestramento di modelli generativi avanzati richiede un'ingente quantità di risorse computazionali, determinando costi energetici elevati che ne limitano l'impiego alle sole grandi aziende dotate di infrastrutture adeguate. Questa criticità pone la necessità di sviluppare nuove strategie volte a ottimizzare l'efficienza dei modelli, riducendo il consumo di calcolo senza comprometterne le prestazioni. Tra le soluzioni più promettenti, la ricerca futura dovrebbe approfondire l'applicazione di tecniche di quantizzazione e pruning, che consentono di comprimere i modelli riducendone la complessità computazionale (Kuzmin et al., 2024), nonché l'adozione di strategie di apprendimento federato, che permettono di distribuire il processo di addestramento su più nodi decentralizzati, limitando la necessità di trasferire grandi volumi di dati e riducendo l'impatto energetico complessivo (Li et al., 2020). Parallelamente, l'integrazione di tecnologie di calcolo distribuito e *edge computing* potrebbe costituire un ulteriore elemento chiave per la sostenibilità della generazione artificiale, permettendo l'elaborazione locale dei dati e minimizzando la dipendenza da infrastrutture centralizzate ad alta intensità energetica. Queste soluzioni, se implementate in maniera efficace, potrebbero non solo migliorare l'efficienza complessiva dei modelli generativi, ma anche favorirne una diffusione più capillare, rendendo accessibili le tecnologie di intelligenza artificiale generativa anche alle piccole e medie imprese. In questo modo, si ridurrebbe il divario tecnologico tra le diverse realtà industriali, consentendo una democratizzazione dell'innovazione e un utilizzo più equilibrato delle risorse computazionali a livello globale.

Un ambito di ricerca di particolare interesse riguarda l'integrazione tra intelligenza artificiale generativa e robotica collaborativa, con l'obiettivo di migliorare l'adattabilità e l'efficienza operativa dei sistemi robotici negli ambienti produttivi. L'uso combinato di modelli generativi e cobots può contribuire in modo significativo all'ottimizzazione delle dinamiche di interazione tra macchine e operatori umani, consentendo ai robot di adattare i propri movimenti e strategie operative in tempo reale sulla base delle condizioni di lavoro e del comportamento degli operatori. Questa capacità di adattamento risulta essenziale per incrementare la reattività dei cobots ai cambiamenti di contesto, riducendo i tempi di risposta e migliorando la fluidità delle operazioni produttive. Per raggiungere questi obiettivi, la ricerca futura dovrebbe concentrarsi sullo sviluppo di architetture avanzate in grado di garantire una comunicazione efficace e bidirezionale tra i modelli di intelligenza artificiale generativa e i sistemi robotici, integrando algoritmi capaci di interpretare e prevedere le azioni umane per ottimizzare la collaborazione tra uomo e macchina. Un'evoluzione in questa direzione consentirebbe di aumentare significativamente la flessibilità dei processi produttivi, facilitando l'adattamento a scenari industriali dinamici e migliorando al contempo la sicurezza degli operatori. L'integrazione tra intelligenza artificiale generativa e robotica collaborativa potrebbe rappresentare, dunque, un passo fondamentale verso la realizzazione di fabbriche intelligenti più efficienti, sicure e in grado di rispondere con maggiore rapidità alle esigenze di produzione, riducendo al minimo le interruzioni operative e ottimizzando l'interazione tra sistemi automatizzati e personale umano.

Infine, sul piano tecnologico, la prospettiva di abbinare l'IA generativa a sistemi di realtà estesa e metaverso industriale continua a stimolare la ricerca e potrebbe essere un'ambito di approfondimento molto incentivante per i prossimi anni: l'ipotesi di unire modelli generativi, sensoristica IoT, robotica avanzata e *digital twin* all'interno di ecosistemi immersivi potrebbe

dare vita a nuove modalità di simulazione e addestramento operativo, aprendo opportunità di studio tanto nell'ambito del design sostenibile quanto nella formazione professionale.

In conclusione, le prospettive di ricerca future nell'ambito dell'intelligenza artificiale generativa per il settore manifatturiero sono estremamente promettenti e articolate. L'affidabilità, l'interpretabilità, la sostenibilità e l'integrazione con altre tecnologie emergenti rappresentano le principali sfide da affrontare per consentire un'adozione efficace e diffusa di queste soluzioni. Il superamento di tali ostacoli richiederà un approccio multidisciplinare e una stretta collaborazione tra il mondo accademico, l'industria e le istituzioni regolatorie, al fine di garantire che le tecnologie generative non solo ottimizzino i processi produttivi, ma siano anche sicure, trasparenti ed eticamente sostenibili. Lo sviluppo di metodologie avanzate di verifica, l'armonizzazione con framework normativi e la riduzione dell'impatto computazionale saranno fattori determinanti per rendere l'intelligenza artificiale generativa una leva strategica per l'innovazione industriale nei prossimi anni.

## 7.2 Considerazioni finali e implicazioni della ricerca

L'analisi condotta in questa tesi ha delineato il ruolo strategico dell'intelligenza artificiale generativa nel settore manifatturiero, mettendone in evidenza le potenzialità, le applicazioni concrete e le principali sfide da affrontare. Attraverso una revisione sistematica della letteratura, è stato possibile individuare i principali ambiti di utilizzo di questa tecnologia nella ricerca e nella manifattura, che spaziano dalla progettazione avanzata alla simulazione di processi industriali, dall'ottimizzazione delle operazioni industriali alla generazione di dati sintetici per il miglioramento dell'apprendimento automatico. La convergenza tra GenAI e tecnologie innovative come i *digital twin*, la manifattura additiva e il controllo qualità dimostra il profondo impatto dell'intelligenza artificiale sulla trasformazione digitale dell'industria, favorendo un'evoluzione sempre più orientata all'automazione, all'efficienza e alla sostenibilità.

Uno degli aspetti più rilevanti emersi dall'analisi riguarda il potenziale della GenAI nell'ottimizzazione dei processi produttivi. L'integrazione con modelli predittivi e strumenti di simulazione consente non solo di migliorare la pianificazione industriale e ridurre sprechi ed inefficienze, ma anche di incrementare la personalizzazione della produzione. L'adozione di tecniche generative applicate ai *digital twin* rappresenta un elemento di particolare interesse, poiché consente di creare ambienti virtuali altamente realistici, all'interno dei quali è possibile simulare scenari operativi, testare configurazioni ottimali e anticipare possibili problematiche prima che queste si manifestino nei contesti reali. Questa capacità di modellazione avanzata non solo migliora le prestazioni e l'affidabilità delle linee produttive, ma si rivela cruciale per il processo decisionale strategico e la gestione proattiva degli impianti.

Parallelamente, l'impiego della GenAI nella progettazione industriale sta evolvendo il modo in cui vengono sviluppati nuovi prodotti. Le Generative Adversarial Networks (GAN) e i modelli di diffusione permettono di esplorare configurazioni progettuali innovative, ottimizzando l'efficienza strutturale e riducendo il time-to-market. La possibilità di generare prototipi virtuali attraverso simulazioni avanzate contribuisce a minimizzare il numero di iterazioni sperimentali necessarie, accelerando così i cicli di innovazione e abbattendo i costi legati alla fase di prototipazione fisica. L'impiego di queste tecnologie si estende anche alla manifattura additiva, dove la generazione automatizzata di configurazioni geometriche e parametri di stampa ottimizzati consente di ottenere componenti con caratteristiche meccaniche migliorate e un ridotto consumo di materiali.

Un forte ambito di ricerca è rappresentato dalla generazione di dati sintetici, una soluzione che si sta rivelando particolarmente utile per affrontare la sfida della scarsità di dataset bilanciati e di alta qualità per l'addestramento di modelli di machine learning. La capacità delle reti generative di produrre dati realistici e variabili migliora significativamente le prestazioni dei modelli predittivi, garantendo una maggiore affidabilità nelle applicazioni di monitoraggio e controllo qualità. In questo contesto, l'integrazione della GenAI con tecniche di visione artificiale ha dimostrato di poter migliorare sensibilmente la capacità di rilevamento automatico di difetti nei prodotti, riducendo la necessità di ispezioni manuali e aumentando la precisione dei sistemi di controllo automatizzato.

Le applicazioni aziendali della GenAI nel settore manifatturiero sono state approfondite attraverso diversi casi studio che ne evidenziano i benefici concreti. L'implementazione da parte di Amazon dell'IA generativa per la gestione della supply chain ha permesso di ottimizzare i processi di approvvigionamento e migliorare la previsione della domanda, riducendo sprechi e inefficienze logistiche. Microsoft, attraverso il suo Dynamics 365 Copilot, ha sfruttato la GenAI per automatizzare attività aziendali ripetitive e supportare decisioni strategiche basate sull'analisi predittiva.

Nel settore aerospaziale, Airbus ha integrato modelli generativi per la manutenzione predittiva e il supporto alle operazioni post-vendita, migliorando la gestione della documentazione tecnica e velocizzando le risposte ai clienti. Bosch ha applicato la GenAI per la generazione di dati sintetici nel controllo qualità, addestrando modelli di visione artificiale con immagini sintetiche per identificare difetti nei componenti elettronici con maggiore precisione. Siemens ha implementato la GenAI nel suo sistema Senseye Predictive Maintenance, trasformando la manutenzione predittiva in una manutenzione prescrittiva e migliorando l'accesso alle informazioni attraverso interfacce conversazionali intuitive.

Un altro caso rilevante riguarda Toyota, che ha sviluppato un sistema di progettazione basato su GenAI per ottimizzare il design dei veicoli. Questo approccio ha permesso di ridurre il numero di iterazioni necessarie tra le fasi di ideazione e validazione tecnica, accelerando lo sviluppo di nuovi modelli automobilistici con prestazioni aerodinamiche migliorate. Siemens ha inoltre introdotto l'Industrial Copilot, un assistente basato su GenAI che supporta gli ingegneri nella programmazione industriale automatizzata, riducendo errori e semplificando il processo di sviluppo di codice per i controllori logici programmabili (PLC).

Nonostante le numerose opportunità, l'implementazione della GenAI nel manufacturing solleva anche una serie di sfide critiche che ne limitano l'adozione su larga scala. Un aspetto centrale riguarda la necessità di garantire la trasparenza e l'affidabilità dei modelli generativi, soprattutto in contesti in cui la qualità e la sicurezza dei prodotti rappresentano priorità imprescindibili. Il fenomeno delle allucinazioni nei modelli generativi e la difficoltà nel garantire la riproducibilità dei risultati richiedono l'adozione di strategie di validazione rigorose e protocolli di testing avanzati. La scalabilità e l'interoperabilità con le infrastrutture industriali esistenti rappresentano un ulteriore ostacolo, rendendo necessaria una maggiore standardizzazione delle tecnologie e dei protocolli di integrazione.

Un altro aspetto di crescente rilevanza riguarda l'impatto ambientale dell'IA generativa. L'addestramento di modelli di grande scala comporta un elevato consumo energetico, sollevando interrogativi sulla sostenibilità dell'adozione su larga scala di queste tecnologie. A ricerca futura dovrà concentrarsi su metodologie per rendere l'IA generativa più efficiente dal punto di vista computazionale, riducendo l'impatto ambientale senza compromettere le prestazioni.

Le implicazioni pratiche della presente ricerca suggeriscono che il successo nell'adozione della GenAI dipenderà dalla capacità delle aziende manifatturiere di bilanciare innovazione tecnologica e gestione responsabile dei relativi impatti. È fondamentale, infatti, investire nella formazione e nell'upskilling delle risorse umane, affinché le competenze necessarie per la gestione e lo sviluppo di sistemi basati su GenAI siano diffuse e costantemente aggiornate. Solo attraverso una stretta collaborazione tra mondo accademico e industria sarà possibile tradurre i progressi teorici in soluzioni concrete, che rispondano efficacemente alle esigenze dei processi produttivi e, al contempo, rispettino principi di trasparenza, sicurezza ed etica.

In conclusione, questa tesi ha offerto un contributo significativo alla comprensione delle opportunità e delle criticità legate all'adozione della GenAI nel settore manifatturiero, fornendo una base solida su cui si potranno sviluppare ulteriori studi e applicazioni, e suggerendo un percorso di trasformazione digitale in cui la sinergia tra tecnologia, organizzazione e sostenibilità rappresenta la chiave per il successo futuro dell'industria manifatturiera. Il futuro dell'intelligenza artificiale generativa in questo settore sarà, quindi, determinato dalla capacità di integrare queste tecnologie in modo sostenibile, etico e trasparente. La ricerca dovrà proseguire nell'esplorare soluzioni per migliorare la robustezza e l'affidabilità dei modelli, sviluppare normative e linee guida specifiche e garantire una perfetta interoperabilità con le infrastrutture esistenti. Solo attraverso un approccio equilibrato tra innovazione e sostenibilità sarà possibile sfruttare appieno il potenziale della GenAI, contribuendo alla creazione di un ecosistema produttivo più efficiente, adattabile e resiliente.



## 8. Bibliografia

Accenture. (2024). *Technology Vision 2024: Human by design*. Accenture. <https://www.accenture.com/br-pt/insights/technology/technology-trends-2024>

Airbus. (2024, May 6). *How Airbus uses generative artificial intelligence to reinvent itself*. <https://www.airbus.com/en/newsroom/stories/2024-05-how-airbus-uses-generative-artificial-intelligence-to-reinvent-itself>

Akhtar ZB. Artificial intelligence (AI) within manufacturing: An investigative exploration for opportunities, challenges, future directions. *Metaverse*. 2024; 5(2): 2731. <https://doi.org/10.54517/m.v5i2.2731>

Akhtar, P., Ghouri, A. M., Ashraf, A., Lim, J. J., Khan, N. R., & Ma, S. (2024). Smart product platforming powered by AI and generative AI: Personalization for the circular economy. *International Journal of Production Economics*, 273, 109283. <https://doi.org/10.1016/j.ijpe.2024.109283>

Al-Khatib, A. W., Al-Shboul, M. A., & Khattab, M. (2024). How can generative artificial intelligence improve digital supply chain performance in manufacturing firms? Analyzing the mediating role of innovation ambidexterity using hybrid analysis through CB-SEM and PLS-SEM. *Technology in Society*, 78, 102676. <https://doi.org/10.1016/j.techsoc.2024.102676>

Alawieh, M. B., Lin, Y., Zhang, Z., Li, M., Huang, Q., & Pan, D. Z. (2021). GAN-SRAF: Subresolution assist feature generation using generative adversarial networks. *IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems*, 40(2), 373–385. <https://doi.org/10.1109/TCAD.2020.2995338>

Amazon Web Services, & Access Partnership. (2023). *Accelerating AI skills: Preparing the workforce for jobs of the future*. Amazon <https://assets.aboutamazon.com/e1/a0/17842ee148e8af9d55d10d75a213/aws-accelerating-ai-skills-us-en.pdf>

Asha, V., Anjimon, S., Singla, A., Khan, I., Alsharifi, H. A. F., & Maranan, R. (2024). Sophisticated neural network architectures for the holistic simulation and performance enhancement of convective boiling processes in industrial applications. In *2024 OPJU International Technology Conference (OTCON) on Smart Computing for Innovation and Advancement in Industry 4.0* (pp. 1–6). <https://doi.org/10.1109/OTCON60325.2024.10687891>

Assad, F., Patsavellas, J., & Salonitis, K. (2024). Enhancing sustainability in manufacturing through cognitive digital twins powered by generative artificial intelligence. *Procedia CIRP*, 130, 677–682. <https://doi.org/10.1016/j.procir.2024.10.147>

Azizah, S. F. N., Cahyono, H. D., Sihwi, S. W., & Widiarto, W. (2023). Performance analysis of transformer-based models (BERT, ALBERT, and RoBERTa) in fake news detection. *Proceedings of the 2023 International Conference on Information and Communications Technology (ICOIACT)*, 425-430. <https://doi.org/10.1109/ICOIACT59844.2023.10455849>

Badini, S., Regondi, S., Frontoni, E., & Pugliese, R. (2023). Assessing the capabilities of ChatGPT to improve additive manufacturing troubleshooting. *Advanced Industrial and Engineering Polymer Research*, 6(3), 278–287. <https://doi.org/10.1016/j.aiepr.2023.03.003>

Baungarten-Leon, E. I., Ortega-Cisneros, S., Abdelmoneum, M., Vidana Vidana Morales, R. Y., & Pinedo-Diaz, G. (2024). The genesis of AIbyAI integrated circuit: Where AI creates AI. *Electronics*. <https://api.semanticscholar.org/CorpusID:269476875>

Bosch. (2023). *Generative AI in manufacturing: Out of the old, emerges the new*. <https://www.bosch.com/stories/ai-image-recognition-production/>

Brad, S., Bartoş, VD., Brad, E., Trifan, CV. (2025). Neuro-Symbolic AI-Driven Inventive Design of a Benzoic Acid Extraction Installation from Styrax Resin. In: Cavallucci, D., Brad, S., Livotov, P. (eds) *World Conference of AI-Powered Innovation and Inventive Design*. TFC 2024. IFIP Advances in Information and Communication Technology, vol 735. Springer, Cham. [https://doi.org/10.1007/978-3-031-75919-2\\_5](https://doi.org/10.1007/978-3-031-75919-2_5)

Broo, D. G. (2023). How generative AI helped me imagine a better robot: It didn't give me schematics, but it did boost my creativity. *IEEE Spectrum*, 60, 44–50. <https://api.semanticscholar.org/CorpusID:265055974>

Brown, T. B., Mann, B., Ryder, N., Subbiah, M., Kaplan, J., Dhariwal, P., Neelakantan, A., Shyam, P., Sastry, G., Askell, A., Agarwal, S., Herbert-Voss, A., Krueger, G., Henighan, T., Child, R., Ramesh, A., Ziegler, D. M., Wu, J., Winter, C., ... & Amodei, D. (2020). Language models are few-shot learners. *Advances in Neural Information Processing Systems*. <https://doi.org/10.48550/arXiv.2005.14165>

Brühl, V. (2023). Generative Artificial Intelligence (GAI): Foundations, Use Cases and Economic Potential. *CFS Working Paper Series*. <https://doi.org/10.2139/ssrn.4515593>

Bruno, A., Mazzeo, P. L., Chetouani, A., Tliba, M., & Kerkouri, M. A. (2023). Insights into classifying and mitigating LLMs' hallucinations. *arXiv*. <https://arxiv.org/abs/2311.08117>

Cao, S., Lim, W. H., Zhu, Y. J., & others. (2024). Revolutionizing glass molding process: ChatGPT's role in repairing and recycling lenses. *International Journal of Advanced Manufacturing Technology*, 135(3), 3827–3845. <https://doi.org/10.1007/s00170-024-14702-5>

Cao, Y., Li, S., Liu, Y., Yan, Z., Dai, Y., Yu, P.S., & Sun, L. (2023). A Comprehensive Survey of AI-Generated Content (AIGC): A History of Generative AI from GAN to ChatGPT. *ArXiv*. <https://arxiv.org/abs/2303.04226>

Challapalli, A., Konlan, J., Patel, D., & Li, G. (2021). Discovery of Cellular Unit Cells With High Natural Frequency and Energy Absorption Capabilities by an Inverse Machine Learning Framework. *Frontiers of Mechanical Engineering*. <https://api.semanticscholar.org/CorpusID:244779821>

Chen, S.-N., & Chen, S.-H. (2024). Application of generative adversarial networks for virtual silicon data generation and design-technology co-optimization: A study on WAT and CP. *IEEE Access*, 12, 6532–6545. <https://doi.org/10.1109/ACCESS.2024.3351802>

Chen, Y., Yang, C., Feng, Y. (2020). Reinforcement Learning on Robot with Variational Auto-Encoder. In: Wang, R., Chen, Z., Zhang, W., Zhu, Q. (eds) Proceedings of the 11th International Conference on Modelling, Identification and Control (ICMIC2019). Lecture Notes in Electrical Engineering, vol 582. Springer, Singapore. [https://doi.org/10.1007/978-981-15-0474-7\\_63](https://doi.org/10.1007/978-981-15-0474-7_63)

Cho, E., Jeon, B., & Park, I. K. (2023). Synthesizing industrial defect images under data imbalance. *IEEE Access*, 11, 111335–111346. <https://doi.org/10.1109/ACCESS.2023.3322927>

Cohen, Y., & Aperstein, Y. (2024). Generative shopfloor layout design: Challenges and proposed modelling approach. *IFAC-PapersOnLine*, 58(19), 748–753. <https://doi.org/10.1016/j.ifacol.2024.09.213>

Corchado, J. M., López F., S., Núñez V., J. M., Garcia S., R., & Chamoso, P. (2023). Generative Artificial Intelligence: Fundamentals. *ADCAIJ: Advances in Distributed Computing and Artificial Intelligence Journal*, 12(1), e31704. <https://doi.org/10.14201/adcaij.31704>

Da Silva, L. A., dos Santos, E. M., Araújo, L., de Sousa Freire, N., Vasconcelos, M., Giusti, R., Ferreira, D. A. O., Jesus, A. S., Pimentel, A., Cruz, C. F. S., Belém, R. J. S., Costa, A. S., & da Silva, O. A. (2021). Spatio-temporal deep learning-based methods for defect detection: An industrial application study case. *Applied Sciences*. <https://api.semanticscholar.org/CorpusID:244374289>

Decardi-Nelson, B., Alshehri, A. S., Ajagekar, A., & You, F. (2024). Generative AI and process systems engineering: The next frontier. *Computers & Chemical Engineering*, 187, 108723. <https://doi.org/10.1016/j.compchemeng.2024.108723>

Deeluea, S., Jeenanunta, C., & Tunpun, A. (2022). Fault prediction model for motor and generative adversarial networks for acceleration signal generation. In *2022 17th International Joint Symposium on Artificial Intelligence and Natural Language Processing (iSAI-NLP)* (pp. 1–5). <https://doi.org/10.1109/iSAI-NLP56921.2022.9960281>

Deloitte. (2024). *State of Generative AI in the Enterprise: Now decides next (Q2 Report)*. Deloitte. <https://www2.deloitte.com/us/en/pages/consulting/articles/state-of-generative-ai-in-enterprise.html>

Devlin, J., Chang, M.-W., Lee, K., & Toutanova, K. (2019). BERT: Pre-training of deep bidirectional transformers for language understanding. *arXiv Preprint*. <https://arxiv.org/abs/1810.04805>

Dey, B., De Ridder, V., Blanco, V., Halder, S., & Waeyenberge, B. (2024). Addressing class imbalance and data limitations in advanced node semiconductor defect inspection: A generative approach for SEM images. *arXiv Preprint*. <https://doi.org/10.48550/arXiv.2407.10348>

Doanh, D., Ejdy, J., Dufek, Z., Ginevičius, R., Korzynski, P., Mazurek, G., Paliszkiwicz, J., Wach, K., & Ziemba, E. (2023). Generative AI in the manufacturing process: Theoretical considerations. *Engineering Management in Production and Services*, 15(3), 76–89. <https://doi.org/10.2478/emj-2023-0029>

Du, Z., Gao, L., & Li, X. (2023). A new contrastive GAN with data augmentation for surface defect recognition under limited data. *IEEE Transactions on Instrumentation and Measurement*, 72, 1–13. <https://doi.org/10.1109/TIM.2022.3232649>

Dwivedi, Y. K., Pandey, N., Currie, W., & Micu, A. (2024). Leveraging ChatGPT and other generative artificial intelligence (AI)-based applications in the hospitality and tourism industry: Practices, challenges and research agenda. *International Journal of Contemporary Hospitality Management*, 36(1), 1–12. <https://doi.org/10.1108/IJCHM-05-2023-0686>

Faltings, U., Bettinger, T., Barth, S., & Schäfer, M. (2022). Impact on Inference Model Performance for ML Tasks Using Real-Life Training Data and Synthetic Training Data from GANs. *Information*, 13(1), 9. <https://doi.org/10.3390/info13010009>

Farseev, A., Yang, Q., Filchenkov, A., Lepikhin, K., Chu-Farseeva, Y.-Y., & Loo, D.-B. (2021). SoMin.ai: Personality-driven content generation platform. In *Proceedings of the 14th ACM*

International Conference on Web Search and Data Mining (WSDM '21) (pp. 890–893). ACM. <https://doi.org/10.1145/3437963.3441714>

Feuerriegel, S., Hartmann, J., Janiesch, C., & Zschech, P. (2023). Generative AI. *Business & Information Systems Engineering*, 66(1), 111–126. <https://doi.org/10.1007/s12599-023-00834-7>

Filz, M.-A., & Thiede, S. (2024). Generative AI in manufacturing systems: Reference framework and use cases. *Procedia CIRP*, 130, 238–243. <https://doi.org/10.1016/j.procir.2024.10.082>

Finn, C., Christiano, P., Abbeel, P., & Levine, S. (2016). A connection between generative adversarial networks, inverse reinforcement learning, and energy-based models. *arXiv*. <https://arxiv.org/abs/1611.03852>

Fu, T., Liu, S., & Li, P. (2024). Intelligent smelting process, management system: Efficient and intelligent management strategy by incorporating large language model. *Frontiers of Engineering Management*, 11(3), 396–412. <https://doi.org/10.1007/s42524-024-4013-y>

García-Peñalvo, F. J., & Vázquez-Ingelmo, A. (2023). What Do We Mean by GenAI? A Systematic Mapping of The Evolution, Trends, and Techniques Involved in Generative AI. *International Journal of Interactive Mobile Technologies (IJIMAI)*. <https://doi.org/10.9781/ijimai.2023.07.006>.

Ghobakhloo, M., Fathi, M., Iranmanesh, M., Vilkas, M., Grybauskas, A., & Amran, A. (2024). Generative artificial intelligence in manufacturing: Opportunities for actualizing Industry 5.0 sustainability goals. *Journal of Manufacturing Technology Management*, 35(9), 94–121. <https://doi.org/10.1108/JMTM-12-2023-0530>

Gholami, H. (2024). Artificial intelligence techniques for sustainable reconfigurable manufacturing systems: An AI-powered decision-making application using large language models. *Big Data and Cognitive Computing*, 8(11), 152. <https://doi.org/10.3390/bdcc8110152>

Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.

Goodfellow, Ian & Pouget-Abadie, Jean & Mirza, Mehdi & Xu, Bing & Warde-Farley, David & Ozair, Sherjil & Courville, Aaron & Bengio, Y. (2014). Generative Adversarial Networks. *Advances in Neural Information Processing Systems*. 3. 10.1145/3422622. Disponible su <https://arxiv.org/abs/1406.2661>

Görge, L., Müller, E., Triller, M., Nast, B., & Sandkuhl, K. (2024). Large language models in enterprise modeling: Case study and experiences. In *Proceedings of the 12th International Conference on Model-Based Software and Systems Engineering - Volume 1: MODELSWARD* (pp. 74–85). SciTePress. <https://doi.org/10.5220/0012387000003645>

Grewal, D., Saturnino, C.B., Davenport, T. *et al.* How generative AI Is shaping the future of marketing. *J. of the Acad. Mark. Sci.* (2024). <https://doi.org/10.1007/s11747-024-01064-3>

Guo, Y., Liu, Y., Bakker, E.M., Guo, Y., & Lew, M.S. (2017). CNN-RNN: a large-scale hierarchical image classification framework. *Multimedia Tools and Applications*, 77, 10251 - 10271. <https://doi.org/10.1007/s11042-017-5443-x>

Hashimoto, M., Ide, Y., & Aritsugi, M. (2021). Anomaly detection for sensor data of semiconductor manufacturing equipment using a GAN. *Procedia Computer Science*, 192, 873–882. <https://doi.org/10.1016/j.procs.2021.08.090>

Hemleben, N., Ospina-Acero, D., Blank, D., VanFossen, A., Zahiri, F., & Kumar, M. (2023). DAGGER: Data augmentation generative framework for time-series data in data-driven smart manufacturing systems. *Annual Conference of the PHM Society*, 15(1). <https://doi.org/10.36001/phmconf.2023.v15i1.3483>

Heredia Álvaro, J. A., & González Barreda, J. (2025). An advanced retrieval-augmented generation system for manufacturing quality control. *Advanced Engineering Informatics*, 64, 103007. <https://doi.org/10.1016/j.aei.2024.103007>

Hertz, A., Voynov, A., Fruchter, S., & Cohen-Or, D. (2024). *Style aligned image generation via shared attention*. arXiv. <https://arxiv.org/abs/2312.02133>

Ho, Jonathan & Jain, Ajay & Abbeel, Pieter. (2020). Denoising Diffusion Probabilistic Models. *Advances in Neural Information Processing Systems*. Disponibile su <https://arxiv.org/abs/2006.11239>

Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>

Hoffmann, M., Malburg, L., Bergmann, R. (2022). ProGAN: Toward a Framework for Process Monitoring and Flexibility by Change via Generative Adversarial Networks. In: Marrella, A., Weber, B. (eds) *Business Process Management Workshops. BPM 2021*. Lecture Notes in Business Information Processing, vol 436. Springer, Cham. [https://doi.org/10.1007/978-3-030-94343-1\\_4](https://doi.org/10.1007/978-3-030-94343-1_4)

Holland, M., & Chaudhari, K. (2024). Large language model-based agent for process planning of fiber composite structures. *Manufacturing Letters*, 40, 100–103. <https://doi.org/10.1016/j.mfglet.2024.03.010>

Hou, Y., Chen, Z., Wu, M., Foo, C.-S., Li, X., & Shubair, R. M. (2020). Mahalanobis distance-based adversarial network for anomaly detection. In *ICASSP 2020 - 2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)* (pp. 3192–3196). <https://doi.org/10.1109/ICASSP40776.2020.9053206>

Howland, S., Kassab, L., Kappagantula, K., & others. (2023). Parameters, properties, and process: Conditional neural generation of realistic SEM imagery toward ML-assisted advanced manufacturing. *Integrating Materials and Manufacturing Innovation*, 12, 1–10. <https://doi.org/10.1007/s40192-022-00287-y>

Hsiao, H.-H., & Wang, K.-J. (2024). HotspotFusion: A generative AI approach to predicting CMP hotspot in semiconductor manufacturing. *IEEE Transactions on Semiconductor Manufacturing*, 1–1. <https://doi.org/10.1109/TSM.2024.3510376>

IBM. (2024). *AI in Action 2024: Identifying what separates AI leaders from learners*. IBM Corporation. <https://www.ibm.com/think/reports/ai-in-action>

Jide-Jegede, M., & Omotesho, T. (2024). Harnessing generative AI for manufacturing innovation: Applications and opportunities. In *2024 International Conference on Artificial Intelligence in Information and Communication (ICAIIIC)* (pp. 568–572). <https://doi.org/10.1109/ICAIIIC60209.2024.10463265>

Jurafsky, D., & Martin, J. H. (2008). *Speech and language processing: An introduction to natural language processing, computational linguistics, and speech recognition* (2nd ed.). Pearson Prentice Hall.

Kampker, A., Heimes, H., Dorn, B., Clever, H., Drescher, M., & Ludwigs, R. (2023). Synthesis of artificial coating images and parameter data sets in electrode manufacturing. *Proceedings of the Electrode Manufacturing Conference*. <https://doi.org/10.15488/13485>

Kar, A. K., Varsha, P. S., & Rajan, S. (2023). Unravelling the impact of generative artificial intelligence (GAI) in industrial applications: A review of scientific and grey literature. *Global Journal of Flexible Systems Management*, 24, 659–689. <https://doi.org/10.1007/s40171-023-00356-x>

Kasar, R., & Kumar, T. (2024). Digital Twin and Generative AI for Product Development. *Procedia CIRP*, 128, 905–910. <https://doi.org/10.1016/j.procir.2024.06.043>

Kench, S., Squires, I., Dahari, A., Planella, F. B., Roberts, S. A., & Cooper, S. J. (2024). Li-ion battery design through microstructural optimization using generative AI. *Matter*, 7(12), 4260–4269. <https://doi.org/10.1016/j.matt.2024.08.014>

Khlie, K., Benmamoun, Z., Jebbor, I., & Serrou, D. (2024). Generative AI for enhanced operations and supply chain management. *Journal of Infrastructure, Policy and Development*, 8, 6637. <https://doi.org/10.24294/jipd.v8i10.6637>

Kılınç, H. K., & Keçecioglu, O. F. (2023). Generative Artificial Intelligence: A Historical and Future Perspective. *Academic Platform Journal of Engineering and Smart Systems*, 11(3), 1–15. <https://doi.org/10.21541/apjess.1398155>

Kim, S., Jang, J., & Kim, C. O. (2021). A run-to-run controller for a chemical mechanical planarization process using least squares generative adversarial networks. *Journal of Intelligent Manufacturing*, 32, 2267–2280. <https://doi.org/10.1007/s10845-020-01639-1>

Kingma, D. P., & Welling, M. (2013). Auto-Encoding Variational Bayes. *arXiv preprint arXiv:1312.6114*. <https://arxiv.org/abs/1312.6114>

Kingma, Diederik & Ba, Jimmy. (2014). Adam: A Method for Stochastic Optimization. *International Conference on Learning Representations*. Disponibile su <https://arxiv.org/abs/1412.6980>

Kong, Y., & Ni, D. (2022). A one-shot learning approach for similarity retrieval of wafer bin maps with unknown failure pattern. *IEEE Transactions on Semiconductor Manufacturing*, 35(1), 40–49. <https://doi.org/10.1109/TSM.2021.3123290>

Kong, Z., Ping, W., Huang, J., Zhao, K., & Catanzaro, B. (2021). DiffWave: A versatile diffusion model for audio synthesis. In *International Conference on Learning Representations*. <https://openreview.net/forum?id=a-xFK8Ymz5J>

KPMG LLP. (2024). *GenAI Survey – 2024: Key insights*. KPMG LLP. <https://kpmg.com/us/en/media/news/gen-ai-survey-august-2024.html>

Kshetri, N., Dwivedi, Y. K., Davenport, T. H., & Panteli, N. (2024). Generative artificial intelligence in marketing: Applications, opportunities, challenges, and research agenda. *International Journal of Information Management*, 75, 102716. <https://doi.org/10.1016/j.ijinfomgt.2023.102716>

Kurian, S., & Petrashka, D. (2024, November 14). *Optimize your supply chain processes with generative AI on AWS*. AWS Blog. <https://aws.amazon.com/it/blogs/industries/optimize-your-supply-chain-processes-with-generative-ai-on-aws/>

Kuzmin, A., Nagel, M., van Baalen, M., Behboodi, A., & Blankevoort, T. (2024). Pruning vs quantization: Which is better? *arXiv Preprint*. <https://arxiv.org/abs/2307.02973>

La Salvia, M., Torti, E., Leon, R., Fabelo, H., Ortega, S., Martinez-Vega, B., Callico, G. M., & Leporati, F. (2022). Deep Convolutional Generative Adversarial Networks to Enhance Artificial Intelligence in Healthcare: A Skin Cancer Application. *Sensors*, 22(16), 6145. <https://doi.org/10.3390/s22166145>

Lamanna, C. (2023, March 6). *Introducing Microsoft Dynamics 365 Copilot, the world's first copilot in both CRM and ERP, that brings next-generation AI to every line of business*. Microsoft. <https://blogs.microsoft.com/blog/2023/03/06/introducing-microsoft-dynamics-365-copilot/>

Lazaroiu, G., Gedeon, T., Rogalska, E., Valášková, K., Nagy, M., Musa, H., Poliak, M., Horák, J., Crețoiu, R., Krulický, T., Ionescu, L., Popa, C., Hurloiu, L., Filip, N., Avram, L., & Braga, V. (2024a). Digital twin-based cyber-physical manufacturing systems, extended reality metaverse enterprise and production management algorithms, and Internet of Things financial and labor market technologies in generative artificial intelligence economics. *Oeconomia Copernicana*, 15, 837. <https://doi.org/10.24136/oc.3183>

Lazaroiu, G., Gedeon, T., Valaskova, K., Vrbka, J., Šuleř, P., Zvarikova, K., Kramarova, K., Rowland, Z., Stehel, V., Gajanova, L., Horák, J., Grupac, M., Caha, Z., Blazek, R., Kovalova, E., & Nagy, M. (2024b). Cognitive digital twin-based Internet of Robotic Things, multi-sensory extended reality and simulation modeling technologies, and generative artificial intelligence and cyber-physical manufacturing systems in the immersive industrial metaverse. *Equilibrium. Quarterly Journal of Economics and Economic Policy*, 19(3), 719–748. <https://doi.org/10.24136/eq.3131>

Le, X., Mei, J., Zhang, H., Zhou, B., & Xi, J. (2020). A learning-based approach for surface defect detection using small image datasets. *Neurocomputing*, 408, 112–120. <https://doi.org/10.1016/j.neucom.2019.09.107>

Li, L., Fan, Y., Tse, M., & Lin, K.-Y. (2020). A review of applications in federated learning. *Computers & Industrial Engineering*, 149, 106854. <https://doi.org/10.1016/j.cie.2020.106854>

Li, L., Zhu, W., Chen, L., & Liu, Y. (2024). Generative AI usage and sustainable supply chain performance: A practice-based view. *Transportation Research Part E: Logistics and Transportation Review*, 192, 103761. <https://doi.org/10.1016/j.tre.2024.103761>

Li, R., & Kang, Z. (2023). Deep learning for wafer map defect detection: A review. In *Proceedings of the 2023 PHM-Hangzhou Conference* (pp. 1–6). <https://doi.org/10.1109/PHM-Hangzhou58797.2023.10482800>

Li, W., Zhang, M., Li, W., Wang, Y., Zhang, X., Chen, B., & Ding, H. (2024). ASM-GAN: Arbitrary object shape styles manipulation in synthesized images for GANs. *IEEE Transactions on Instrumentation and Measurement*, 74, 1–15. <https://doi.org/10.1109/TIM.2024.3502835>

Li, X., Tao, F., Ye, W., Nassehi, A., & Sutherland, J. W. (2024). *Generative manufacturing systems using diffusion models and ChatGPT*. arXiv. <https://arxiv.org/abs/2405.00958>

Li, Y., & Starly, B. (2024). Building a knowledge graph to enrich ChatGPT responses in manufacturing service discovery. *Journal of Industrial Information Integration*, 40, 100612. <https://doi.org/10.1016/j.jii.2024.100612>

Liang, P., Deng, C., Wu, J., & Yang, Z. (2020). Intelligent fault diagnosis of rotating machinery via wavelet transform, generative adversarial nets and convolutional neural network. *Measurement*, 159, 107768. <https://doi.org/10.1016/j.measurement.2020.107768>

Lin, S., He, Z., & Sun, L. (2019). Defect Enhancement Generative Adversarial Network for Enlarging Data Set of Microcrack Defect. *IEEE Access*, 7, 148413-148423.

Liu, Y., Yang, Z., Yu, Z., Liu, Z., Liu, D., Lin, H., Li, M., Ma, S., Avdeev, M., & Shi, S. (2023). Generative artificial intelligence and its applications in materials science: Current situation and future perspectives. *Journal of Materiomics*, 9(4), 798-816. <https://doi.org/10.1016/j.jmat.2023.05.001>

Lu, H., Du, M., Qian, K., He, X., & Wang, K. (2022). GAN-based data augmentation strategy for sensor anomaly detection in industrial robots. *IEEE Sensors Journal*, 22(18), 17464–17474. <https://doi.org/10.1109/JSEN.2021.3069452>

Lu, J., Batra, D., Parikh, D., & Lee, S. (2019). ViLBERT: Pretraining task-agnostic visiolinguistic representations for vision-and-language tasks. In H. Wallach, H. Larochelle, A. Beygelzimer, F. d'Alché-Buc, E. Fox, & R. Garnett (Eds.), *Advances in Neural Information Processing Systems* (Vol. 32). Curran Associates, Inc. [https://proceedings.neurips.cc/paper\\_files/paper/2019/file/c74d97b01eae257e44aa9d5bade97baf-Paper.pdf](https://proceedings.neurips.cc/paper_files/paper/2019/file/c74d97b01eae257e44aa9d5bade97baf-Paper.pdf)

Lyu, P., Cheng, Y., Zhang, M., Yu, W., Xia, L., & Liu, C. (2024). GPSC-GAN: A data-enhanced model for intelligent fault diagnosis. *IEEE Transactions on Instrumentation and Measurement*, 73, 1–16. <https://doi.org/10.1109/TIM.2024.3457925>

Macaluso, A., Cote, N., & Chitta, S. (2024). Toward automated programming for robotic assembly using ChatGPT. In *Proceedings of the 2024 IEEE International Conference on Robotics and Automation (ICRA)* (pp. 17687–17693). <https://doi.org/10.1109/ICRA57147.2024.10610554>

Magnus, C. S., & Venschott, M. (2024). Towards a GPT-based lean manufacturing consultant for manufacturing optimization. *Procedia CIRP*, 130, 167–176. <https://doi.org/10.1016/j.procir.2024.10.072>

McKinsey & Company. (2023). *The state of AI in 2023: Generative AI's breakout year*. QuantumBlack AI by McKinsey. Disponibile su [https://www.mckinsey.com/capabilities/quantumblack/our-insights/the-state-of-ai-in-2023-generative-AIs-breakout-year?utm\\_source=chatgpt.com#/](https://www.mckinsey.com/capabilities/quantumblack/our-insights/the-state-of-ai-in-2023-generative-AIs-breakout-year?utm_source=chatgpt.com#/)

McKinsey & Company. (2024). *The state of AI in early 2024: Gen AI adoption spikes and starts to generate value*. Disponibile su <https://www.mckinsey.com/capabilities/quantumblack/our-insights/the-state-of-ai>

Meier, S., Töper, F., Gebele, J., Rachinger, B., Klarmann, S., & Franke, J. (2024). Knowledge mining using generative AI for causal discovery in electronics production. In *Proceedings of the 2024 47th International Spring Seminar on Electronics Technology (ISSE)* (pp. 1–10). <https://doi.org/10.1109/ISSE61612.2024.10604102>

Mescheder, L.M., Geiger, A., & Nowozin, S. (2018). Which Training Methods for GANs do actually Converge? *International Conference on Machine Learning*. Disponibile su <https://arxiv.org/abs/1801.04406>

MIT Technology Review Insights. (2024). Taking AI to the next level in manufacturing: Reducing data, talent, and organizational barriers to achieve scale. *MIT Technology Review Insights*. <https://www.technologyreview.com/2024/04/09/1090880/taking-ai-to-the-next-level-in-manufacturing/>

Moon, J., Gelbich, D., Becker, M., Niemietz, P., & Bergs, T. (2024). Predicting fine blanking process signals from sheet metal thickness. *Materials Research Proceedings*, 41, 1436–1445. <https://doi.org/10.21741/9781644903131-159>

Moon, J., Yang, M., Park, S., & Jeong, J. (2024). From scarcity to abundance: Expansion of manufacturing data through limited defect images. In *Proceedings of the 57th Hawaii International Conference on System Sciences*. <https://doi.org/10.24251/HICSS.2023.124>

Mulongo, N. (2024). Optimisation of manufacturing workflow through generative artificial intelligence. In *Proceedings of the 2024 International Symposium on Networks, Computers and Communications (ISNCC)* (pp. 1–6). <https://doi.org/10.1109/ISNCC62547.2024.10758970>

Ng, A., & Jordan, M.I. (2001). On Discriminative vs. Generative Classifiers: A comparison of logistic regression and naive Bayes. *Neural Information Processing Systems*.

Noh, H., You, T., Mun, J., & Han, B. (2017). Regularizing deep neural networks by noise: Its interpretation and optimization. *arXiv*. <https://arxiv.org/abs/1710.05179>

Novelli, C., Casolari, F., Hacker, P., Spedicato, G., & Floridi, L. (2024). Generative AI in EU law: Liability, privacy, intellectual property, and cybersecurity. *arXiv*. <https://arxiv.org/abs/2401.07348>

Ntavelis, E., Kastanis, I., Van Gool, L., & Timofte, R. (2020). Same same but different: Augmentation of tiny industrial datasets using generative adversarial networks. *2020 7th Swiss Conference on Data Science (SDS)*, 17–22. <https://doi.org/10.1109/SDS49233.2020.00011>

OpenAI. (2023a). *GPT-4 Technical Report*. (arXiv Preprint). Disponibile su <https://arxiv.org/abs/2303.08774>

OpenAI. (2023b). *DALL-E 3*. OpenAI. Retrieved December 18, 2024, from <https://openai.com/dall-e-3>

Ouidadi, H., & Guo, S. (2024). MPS-GAN: A multi-conditional generative adversarial network for simulating input parameters' impact on manufacturing processes. *Journal of Manufacturing Processes*, 131, 1030–1045. <https://doi.org/10.1016/j.jmapro.2024.09.067>

Paroha, A. D. (2024). Generative AI-based health monitoring and prediction of electrical submersible pumps. In *2024 15th International Conference on Computing Communication and Networking Technologies (ICCCNT)* (pp. 1–7). <https://doi.org/10.1109/ICCCNT61001.2024.10725256>

Paul, J., & Rialp Criado, A. (2020). The art of writing literature review: What do we know and what do we need to know? *International Business Review*, 29(4), 101717. <https://doi.org/10.1016/j.ibusrev.2020.101717>

Paul, N., Tasgaonkar, V., Walambe, R., & Kotecha, K.V. (2022). Integrating the Generative Adversarial Network for Decision Making in Reinforcement Learning for Industrial Robot Agents. *Robotics*, 11, 150. <https://doi.org/10.3390/robotics11060150>

Pinetz, T., Ruisz, J., & Soukup, D. (2019). Actual impact of GAN augmentation on CNN classification performance. In *Proceedings of the 8th International Conference on Pattern Recognition Applications and Methods (ICPRAM)* (pp. 15–23). <https://doi.org/10.5220/0007244600150023>

Potthoff, L., Naussedat, R., & Gunnemann, L. (2024). Exploring generative AI's role in manual assembly: Application potentials and use concepts. *Procedia CIRP*, 130, 194–199. <https://doi.org/10.1016/j.procir.2024.10.075>

Prasad, V., Kshirsagar, A., Koert, D., Stock-Homburg, R., Peters, J., & Chalvatzaki, G. (2024). MoVEInt: Mixture of Variational Experts for Learning Human–Robot Interactions From Demonstrations. *IEEE Robotics and Automation Letters*, 9(7), 6043–6050. <https://doi.org/10.1109/LRA.2024.3396074>

Radford, A., Kim, J.W., Hallacy, C., Ramesh, A., Goh, G., Agarwal, S., Sastry, G., Askell, A., Mishkin, P., Clark, J., Krueger, G., & Sutskever, I. (2021). Learning Transferable Visual Models From Natural Language Supervision. *International Conference on Machine Learning*. Disponibile su <https://arxiv.org/abs/2103.00020>

Radford, A., Metz, L., & Chintala, S. (2015). Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks. *CoRR*, *abs/1511.06434*. Disponibile su <https://arxiv.org/abs/1511.06434>

Radford, A., Wu, J., Child, R., Luan, D., Amodei, D. & Sutskever, I. (2019). Language Models are Unsupervised Multitask Learners. *OpenAI*. [https://cdn.openai.com/better-language-models/language\\_models\\_are\\_unsupervised\\_multitask\\_learners.pdf](https://cdn.openai.com/better-language-models/language_models_are_unsupervised_multitask_learners.pdf)

Ramesh, A., Dhariwal, P., Nichol, A., Chu, C., & Chen, M. (2022). Hierarchical text-conditional image generation with CLIP latents. *arXiv Preprint*. <https://arxiv.org/abs/2204.06125>

Ramesh, A., Pavlov, M., Goh, G., Gray, S., Voss, C., Radford, A., Chen, M., & Sutskever, I. (2021). Zero-shot text-to-image generation. In *Proceedings of the 38th International Conference on Machine Learning (Proceedings of Machine Learning Research, Vol. 139, pp. 8821–8831)*. <https://proceedings.mlr.press/v139/ramesh21a.html>

Ramlatchan, A., & Li, Y. (2022). Image synthesis using conditional GANs for selective laser melting additive manufacturing. In *Proceedings of the 2022 International Joint Conference on Neural Networks (IJCNN)* (pp. 1–8). <https://doi.org/10.1109/IJCNN55064.2022.9892033>

Rath, S. P., Tripathy, R., & Jain, N. K. (2024). Assessing the factors influencing the adoption of generative artificial intelligence (GenAI) in the manufacturing sector. In S. K. Sharma, Y. K. Dwivedi, B. Metri, B. Lal, & A. Elbanna (Eds.), *Transfer, diffusion and adoption of next-generation digital technologies. TDIT 2023* (IFIP Advances in Information and Communication Technology, Vol. 697). Springer, Cham. [https://doi.org/10.1007/978-3-031-50188-3\\_11](https://doi.org/10.1007/978-3-031-50188-3_11)

Ratner, A.J., Sa, C.D., Wu, S., Selsam, D., & Ré, C. (2016). Data Programming: Creating Large Training Sets, Quickly. *Advances in neural information processing systems*, *29*, 3567–3575 . Disponibile su <https://arxiv.org/abs/1605.07723>

Ray, P. P. (2023). ChatGPT: A comprehensive review on background, applications, key challenges, bias, ethics, limitations, and future scope. *Internet of Things and Cyber-Physical Systems*, *3*, 121–154. <https://doi.org/10.1016/j.iotcps.2023.04.003>

Reed, S., Akata, Z., Yan, X., Logeswaran, L., Schiele, B., & Lee, H. (2016). Generative adversarial text to image synthesis. *Proceedings of the 33rd International Conference on*

*Machine Learning, Proceedings of Machine Learning Research*, 48, 1060–1069. Disponibile su <https://arxiv.org/abs/1605.05396>

Rezaei, S., Cornelius, A., Karandikar, J., & et al. (2024). Using GANs to predict milling stability from limited data. *Journal of Intelligent Manufacturing*. <https://doi.org/10.1007/s10845-023-02291-1>

Rittikulsittichai, S., & Siriborvornratanakul, T. (2024). An intelligent chatbot assistant for comprehensive troubleshooting guidelines and knowledge repository in printed circuit board production. *IEEE Transactions on Artificial Intelligence, Advance online publication*, 1–10. <https://doi.org/10.1109/TAI.2024.3521873>

Rombach, R., Blattmann, A., Lorenz, D., Esser, P., & Ommer, B. (2022). High-resolution image synthesis with latent diffusion models. In *2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)* (pp. 10674–10685). IEEE Computer Society. <https://doi.org/10.1109/CVPR52688.2022.01042>

Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. In *Proceedings of the International Conference on Medical Image Computing and Computer-Assisted Intervention (MICCAI)* (pp. 234–241). Springer. [https://doi.org/10.1007/978-3-319-24574-4\\_28](https://doi.org/10.1007/978-3-319-24574-4_28)

Saharia, C., Chan, W., Saxena, S., Li, L., Whang, J., Denton, E., Seyed Ghasemipour, S. K., Karagol Ayan, B., Mahdavi, S. S., Gontijo Lopes, R., Salimans, T., Ho, J., Fleet, D. J., & Norouzi, M. (2022). Photorealistic text-to-image diffusion models with deep language understanding. *arXiv*. <https://arxiv.org/abs/2205.11487>

Sai, S., Sai, R., & Chamola, V. (2024). Generative AI for Industry 5.0: Analyzing the impact of ChatGPT, DALLE, and other models. *IEEE Open Journal of the Communications Society, Advance online publication*. <https://doi.org/10.1109/OJCOMS.2024.3400161>

Saiz, F. A., Alfaro, G., Barandiaran, I., & Graña, M. (2021). Generative adversarial networks to improve the robustness of visual defect segmentation by semantic networks in manufacturing components. *Applied Sciences*. <https://api.semanticscholar.org/CorpusID:237752794>

San Martín, A. (2024). What generative artificial intelligence means for terminological definitions. *arXiv Preprint*. <https://arxiv.org/abs/2402.16139>

Sarda, K., Yerudkar, A., & Vecchio, C. D. (2021). Missing data imputation for real time-series data in a steel industry using generative adversarial networks. In *IECON 2021 – 47th Annual Conference of the IEEE Industrial Electronics Society* (pp. 1–6). <https://doi.org/10.1109/IECON48115.2021.9589716>

Sasiaowapak, T., Boonsang, S., Chuwongin, S., Tongloy, T., & Lalitrojwong, P. (2023). Generative AI for industrial applications: Synthetic dataset. *2023 15th International Conference*

on *Information Technology and Electrical Engineering (ICITEE)*, 1–6. <https://api.semanticscholar.org/CorpusID:265341675>

Sayed, A., Alshathri, S. I., & Hemdan, E. E. (2024). Conditional generative adversarial networks with optimized machine learning for fault detection of triplex pump in industrial digital twin. *Processes*. <https://api.semanticscholar.org/CorpusID:273677676>

Schneider, J. (2024). Explainable generative AI (GenXAI): A survey, conceptualization, and research agenda. *Artificial Intelligence Review*, 57, 289. <https://doi.org/10.1007/s10462-024-10916-x>

Sengar, S. S., Hasan, A. B., Kumar, S., & Carroll, F. (2024). Generative artificial intelligence: a systematic review and applications. *Multimedia Tools and Applications*, 13807501. <https://doi.org/10.1007/s11042-024-20016-1>

Siemens AG. (2023). *AI for industry: Schaeffler and Siemens bring Industrial Copilot to shop floor*. [Press release] <https://press.siemens.com/global/en/pressrelease/ai-industry-schaeffler-and-siemens-bring-industrial-copilot-shopfloor>

Siemens AG. (2024, February 5). *Generative artificial intelligence takes Siemens' predictive maintenance solution to the next level* [Press release]. <https://press.siemens.com/global/en/pressrelease/generative-artificial-intelligence-takes-siemens-predictive-maintenance-solution-next>

Singh, J., Tant, K., Curtis, A. et al. Real-time super-resolution mapping of locally anisotropic grain orientations for ultrasonic non-destructive evaluation of crystalline material. *Neural Comput & Applic* 34, 4993–5010 (2022). <https://doi.org/10.1007/s00521-021-06670-8>

Singh, R., Garg, R., Patel, N. S., & Braun, M. W. (2020). Generative adversarial networks for synthetic defect generation in assembly and test manufacturing. *2020 31st Annual SEMI Advanced Semiconductor Manufacturing Conference (ASMC)*, 1–5. <https://api.semanticscholar.org/CorpusID:221568525>

Skórnóg, D., & Kmiecik, M. (2023). Supporting inventory management in the manufacturing company by ChatGPT. *Logforum*, 19, 535–554. <https://doi.org/10.17270/J.LOG.2023.917>

Snyder, H. (2019). Literature review as a research methodology: An overview and guidelines. *Journal of Business Research*, 104, 333–339. <https://doi.org/10.1016/j.jbusres.2019.07.039>

Sohn, K., Ruiz, N., Lee, K., Castro Chin, D., Blok, I., Chang, H., Barber, J., Jiang, L., Entis, G., Li, Y., Hao, Y., Essa, I., Rubinstein, M., & Krishnan, D. (2023). *StyleDrop: Text-to-image generation in any style*. arXiv. <https://arxiv.org/abs/2306.00983>

Statnikov, A., Wang, L. & Aliferis, C.F. A comprehensive comparison of random forests and support vector machines for microarray-based cancer classification. *BMC Bioinformatics* **9**, 319 (2008). <https://doi.org/10.1186/1471-2105-9-319>

Sun, H., Ning, G., Zhao, Z., Huang, Z., & He, Z. (2020). Automated work efficiency analysis for smart manufacturing using human pose tracking and temporal action localization. *Journal of Visual Communication and Image Representation*, **73**, 102948. <https://doi.org/10.1016/j.jvcir.2020.102948>

Surovi, N. A., Witherell, P., Mathew, V. S., & Kumara, S. (2024). Current state and benchmarking of generative artificial intelligence for additive manufacturing. In *Proceedings of the ASME 2024 International Design Engineering Technical Conferences and Computers and Information in Engineering Conference* (Vol. 2A, 44th Computers and Information in Engineering Conference, V02AT02A032). ASME. <https://doi.org/10.1115/DETC2024-144076>

Tang, H., Gao, S., Wang, L., Li, X., Li, B., & Pang, S. (2021). A Novel Intelligent Fault Diagnosis Method for Rolling Bearings Based on Wasserstein Generative Adversarial Network and Convolutional Neural Network under Unbalanced Dataset. *Sensors*, **21**(20), 6754. <https://doi.org/10.3390/s21206754>

Terziyan, V., & Kaikova, O. (2024). Hybrid additive manufacturing: A convergence of physical, digital, and social realms driven by generative AI. In H. Fujita, R. Cimler, A. Hernandez-Matamoros, & M. Ali (Eds.), *Advances and trends in artificial intelligence: Theory and applications. IEA/AIE 2024* (Lecture Notes in Computer Science, Vol. 14748). Springer. [https://doi.org/10.1007/978-981-97-4677-4\\_35](https://doi.org/10.1007/978-981-97-4677-4_35)

Terziyan, V., & Vitko, O. (2023). Causality-aware convolutional neural networks for advanced image classification and generation. *Procedia Computer Science*, **217**, 495–506. <https://doi.org/10.1016/j.procs.2022.12.245>

Thirwani, A., Nair, R., & Kulkarni, K. (2024). A generative adversarial network-based approach for accurate detection of bright spots in photovoltaic panels. *2024 11th International Conference on Signal Processing and Integrated Networks (SPIN)*, 349–354. <https://doi.org/10.1109/SPIN60856.2024.10511515>

Torres-Carrion, Pablo & González González, Carina & Aciar, Silvana & Rodriguez, Germana. (2018). *Methodology for Systematic Literature Review applied to Engineering and Education*. 10.1109/EDUCON.2018.8363388.

Toyota. (2023, August 22). *Toyota Research Institute develops new AI technique with potential to help speed up vehicle design* [Press release]. <https://media.toyota.co.uk/toyota-research-institute-develops-new-ai-technique-with-potential-to-help-speed-up-vehicle-design/>

Tse, B., Wright, T., Nsiye, E., Azinord, T., Medina, D., & Mondesire, S. (2024). Semiconductor manufacturing data synthesis through GANs. *2024 35th Annual SEMI Advanced Semiconductor Manufacturing Conference (ASMC)*, 1–6. <https://doi.org/10.1109/ASMC61125.2024.10545371>

Tseng, L.-S., Wu, C.-H., Chen, Y. H., & Tsai, C.-H. (2023). GAN-based data augmentation for metal surface defect detection using convolutional neural networks. In *2023 Sixth International Symposium on Computer, Consumer and Control (IS3C)* (pp. 80–83). <https://doi.org/10.1109/IS3C57901.2023.00029>

Tulbure, A. A., Szabo, I., Danciu, D.-P., Tulbure, A. A., & Dulf, E. H. (2024). Defect interpretations and worker training copilot using YOLOR and ChatGPT-turbo. In *Proceedings of the 2024 28th International Conference on System Theory, Control and Computing (ICSTCC)* (pp. 426–431). <https://doi.org/10.1109/ICSTCC62912.2024.10744745>

Vaswani, A., Shazeer, N. M., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, L., & Polosukhin, I. (2017). Attention is all you need. In *Advances in Neural Information Processing Systems (NeurIPS)*. Disponibile su <https://arxiv.org/abs/1706.03762>

Wang, F. (2024). LightHouse: A survey of AGI hallucination. *arXiv*. <https://arxiv.org/abs/2401.06792>

Wang, H., & Li, Y.-F. (2023). Large language model empowered by domain-specific knowledge base for industrial equipment operation and maintenance. In *Proceedings of the 2023 5th International Conference on System Reliability and Safety Engineering (SRSE)* (pp. 474–479). <https://doi.org/10.1109/SRSE59585.2023.10336112>

Wang, T., Lund, B. D., Marengo, A., Pagano, A., Mannuru, N. R., Teel, Z. A., & Pange, J. (2023). Exploring the Potential Impact of Artificial Intelligence (AI) on International Students in Higher Education: Generative AI, Chatbots, Analytics, and International Student Success. *Applied Sciences*, *13*(11), 6716. <https://doi.org/10.3390/app13116716>

Wang, X., Yu, K., Wu, S., Gu, J., Liu, Y., Dong, C., Loy, C.C., Qiao, Y., & Tang, X. (2018). ESRGAN: Enhanced Super-Resolution Generative Adversarial Networks. *ECCV Workshops*. [https://doi.org/10.1007/978-3-030-11021-5\\_5](https://doi.org/10.1007/978-3-030-11021-5_5)

Weidinger, L., Mellor, J., Rauh, M., Griffin, C., Uesato, J., Huang, P.-S., Cheng, M., Glaese, M., Balle, B., Kasirzadeh, A., Kenton, Z., Brown, S., Hawkins, W., Stepleton, T., Biles, C., Birhane, A., Haas, J., Rimell, L., Hendricks, L. A., ... Gabriel, I. (2021). Ethical and social risks of harm from language models. *arXiv*. <https://arxiv.org/abs/2112.04359>

Westphal, E., & Seitz, H. (2024). Generative Artificial Intelligence: Analyzing Its Future Applications in Additive Manufacturing. *Big Data Cogn.Comput.*, 8, 74. <https://doi.org/10.3390/bdcc8070074>

Westphal, E., & Seitz, H. (2024). Generative Artificial Intelligence: Analyzing Its Future Applications in Additive Manufacturing. *Big Data and Cognitive Computing*, 8(7), 74. <https://doi.org/10.3390/bdcc8070074>

Witkowski, A., & Wodecki, A. (2024). A Cross-Disciplinary Knowledge Management Framework for Generative Artificial Intelligence in Product Management: A Case Study From the Manufacturing Sector. In N. Obermayer & A. Bencsik (Eds.), *Proceedings of the 25th European Conference on Knowledge Management* (No. 1; Vol. 25, pp. 921–929). Academic Conferences International Limited Reading. <https://doi.org/10.34190/eckm.25.1.2605>

Xia, L., Li, C., Zhang, C., Liu, S., & Zheng, P. (2024). Leveraging error-assisted fine-tuning large language models for manufacturing excellence. *Robotics and Computer-Integrated Manufacturing*, 88, 102728. <https://doi.org/10.1016/j.rcim.2024.102728>

Xiao, F., Zhou, J., Han, K., Hu, H., & Fan, J. (2025). Unsupervised anomaly detection using inverse generative adversarial networks. *Information Sciences*, 689, 121435. <https://doi.org/10.1016/j.ins.2024.121435>

Xu, Q., Zhou, G., Zhang, C., & others. (2024). Generative AI and DT integrated intelligent process planning: A conceptual framework. *International Journal of Advanced Manufacturing Technology*, 133, 2461–2485. <https://doi.org/10.1007/s00170-024-13861-9>

Xu, R., & Yan, W. (2020). A comparison of GANs-based approaches for combustor system fault detection. In *2020 International Joint Conference on Neural Networks (IJCNN)* (pp. 1–8). <https://doi.org/10.1109/IJCNN48605.2020.9207487>

Yan, X., & Melkote, S. (2022). Generative modeling of the shape transformation capability of machining processes. *Manufacturing Letters*, 33(Supplement), 794–801. <https://doi.org/10.1016/j.mfglet.2022.07.098>

Yang, J., Wang, Y., Wang, X., Wang, X., Wang, X., & Wang, F.-Y. (2024). Generative AI empowering parallel manufacturing: Building a “6S” collaborative production ecology for Manufacturing 5.0. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 54(11), 6522–6536. <https://doi.org/10.1109/TSMC.2024.3349555>

Yang, Y., & Sun, M. (2024). Knowledge distillation cross-domain diffusion model: A generative AI approach for defect pattern segmentation. *IEEE Transactions on Semiconductor Manufacturing*, 37(4), 634–642. <https://doi.org/10.1109/TSM.2024.3472611>

Yu, H., Gong, W., Chen, J., & Ma, H. (2024). GET3DGS: Generate 3D Gaussians Based on Points Deformation Fields. *IEEE Transactions on Circuits and Systems for Video Technology*, 1–1. <https://doi.org/10.1109/TCSVT.2024.3511342>

Yu, J., & Liu, J. (2022). Multiple granularities generative adversarial network for recognition of wafer map defects. *IEEE Transactions on Industrial Informatics*, 18(3), 1674–1683. <https://doi.org/10.1109/TII.2021.3092372>

Yu, J., Oh, S. J., Baek, S., Kim, J., & Lee, T. (2022). Predicting the Effect of Processing Parameters on Caliber-Rolled Mg Alloys through Machine Learning. *Applied Sciences*, 12(20), 10646. <https://doi.org/10.3390/app122010646>

Yüksel, N., & Börklü, H. R. (2024). A Generative Deep Learning Approach for Improving the Mechanical Performance of Structural Components. *Applied Sciences*, 14(9), 3564. <https://doi.org/10.3390/app14093564>

Zhang, J., Yuan, X., Wang, K., Wang, Y., Yang, C., & Gui, W. (2024). AMING: Adaptive-learning mechanism-based missing-value imputation networks using GAN in industrial processes. In *Proceedings of the 2024 IEEE International Conference on Data Driven Control and Learning Systems (DDCLS)* (pp. 257–262). <https://doi.org/10.1109/DDCLS61622.2024.10606690>

Zhou, B., Li, X., Liu, T., Xu, K., Liu, W., & Bao, J. (2024). CausalKGPT: Industrial structure causal knowledge-enhanced large language model for cause analysis of quality problems in aerospace product manufacturing. *Advanced Engineering Informatics*, 59, 102333. <https://doi.org/10.1016/j.aei.2023.102333>

Zhou, Q., Chen, X., & Tang, J. (2024). GANs fostering data augmentation for automated surface inspection with adaptive learning bias. *International Journal of Advanced Manufacturing Technology*, 135, 5647–5667. <https://doi.org/10.1007/s00170-024-14842-8>

Zhu, H., Jia, L., Xue, X., & Kim, B.-G. (2024). Leveraging generative AI for essential predictive maintenance in industrial consumer electronics. *IEEE Transactions on Consumer Electronics*, Advance online publication. <https://doi.org/10.1109/TCE.2024.3510786>

Ziabari, A., Venkatakrisnan, S., Dubey, A., Lisovich, A., Brackman, P., Frederick, C., Bhattad, P., Bingham, P., Plotkowski, A., Dehoff, R., & Paquit, V. (2022). Simurgh: A framework for CAD-driven deep learning-based X-ray CT reconstruction. In *Proceedings of the 2022 IEEE International Conference on Image Processing (ICIP)* (pp. 3836–3867). <https://doi.org/10.1109/ICIP46576.2022.9898017>

