



**Politecnico  
di Torino**

**Politecnico di Torino**

Corso di Laurea Magistrale in Ingegneria Gestionale

A.a. 2023/2024

Sessione di Laurea aprile 2024

**Innovazioni nell'Industria Agroalimentare  
Secondaria: Applicazioni dell'Intelligenza Artificiale  
nei Processi di Trasformazione**

Relatori:

Prof.re Maurizio Galetto

Prof.ssa Elisa Verna

Candidato:

Maruffi Luca



# Indice

Abstract.....	7
Capitolo 1: Introduzione .....	9
1.1    Contesto dello studio .....	9
1.2    Esposizione del problema .....	11
1.3    Scopo dello studio.....	12
1.4    Metodologia di ricerca .....	12
Capitolo 2: Metodologia di ricerca .....	13
2.1    Progetto di ricerca .....	13
2.2    Raccolta dati.....	15
2.2.1 Strumenti di ricerca e fonti utilizzate.....	15
2.2.2 Qualificazione delle fonti e dei dati .....	16
Capitolo 3: Concetti chiave dell'Intelligenza Artificiale .....	19
3.1    Evoluzione storica dell'Intelligenza Artificiale .....	19
3.2    Sulla definizione e tassonomia dell'IA .....	20
3.3    Descrizione di tecniche ed algoritmi di IA .....	26
3.3.1 Machine Learning.....	26
3.3.2 Reti Neurali Artificiali .....	27
3.3.3 Deep Learning.....	27
3.3.4 Apprendimento Rinforzato .....	28
3.3.5 Apprendimento supervisionato .....	28
3.3.6 Apprendimento non supervisionato.....	29
3.3.7 Apprendimento semi-supervisionato.....	30
3.3.8 Naive Bayes .....	31
3.3.9 k-Nearest Neighbour .....	31
3.3.10 Decision Tree .....	32
3.3.11 Random Forest.....	32
3.3.12 Fuzzy Logic .....	33
3.3.13 Knowledge Based Systems .....	33
3.3.14 Case-Base Reasoning.....	33
3.3.16 Recurrent Neural Network.....	34

3.3.17 Modelli Sequence to Sequence .....	34
3.3.18 Reti Long Short-Term Memory.....	35
3.3.19 Gated Recurrent Units (GRU).....	35
3.3.20 Backpropagation .....	36
3.3.21 Convolutional Neural Network .....	36
3.3.22 AI Based Image Filtering.....	36
3.3.23 Image Segmentation.....	37
3.3.24 Object Detection .....	37
3.3.25 Clustering.....	38
3.3.26 Classification .....	39
3.3.27 Regressione Lineare .....	39
3.3.28 Regressione Logistica .....	40
3.3.29 Macchina a Vettori di Supporto.....	41
3.3.30 Analisi delle Componenti Principali .....	41
3.3.31 Visione Artificiale .....	42
3.3.32 Pattern Recognition .....	43
3.3.33 Knowledge Discovery.....	43
3.3.34 Elaborazione del Linguaggio Naturale .....	44
3.3.35 Tokenizzazione .....	45
3.3.36 Named Entity Recognition.....	45
3.3.37 Part-Of-Speech tagging.....	45
3.3.38 Word Embeddings .....	46
3.3.39 Bagging.....	46
3.3.40 Boosting .....	47
3.4 Tendenza all'integrazione di tecniche ed algoritmi .....	48
3.5 Principali applicazioni funzionali dell'IA negli ambiti produttivi .....	50
Capitolo 4: I processi di trasformazione alimentare .....	51
4.1 Definizione e tassonomia dei processi di trasformazione alimentare .....	51
4.2 Sistemi di classificazione.....	54
Capitolo 5: L'IA nella filiera della produzione alimentare.....	57
5.1 Funzione maggiormente diffuse dell'IA nella trasformazione alimentare.....	57
5.1.1 Applicazioni dell'intelligenza artificiale nel controllo qualità.....	59

5.1.2 Applicazione dell'intelligenza artificiale nel processo di trasformazione.....	60
5.1.3 Applicazione dell'intelligenza artificiale sul prodotto finito .....	61
5.1.4 Applicazione dell'intelligenza artificiale nel packaging .....	62
5.2 Applicazione dell'IA per funzione, tipologia di prodotto e fase .....	64
5.2.1 Tecniche ed algoritmi applicati sul controllo delle materie prime: .....	65
5.2.2 Tecniche ed algoritmi applicati nei processi di trasformazione.....	77
5.2.3 Tecniche ed algoritmi applicati sul prodotto finito.....	84
5.2.4 Tecniche ed algoritmi impiegati sui controlli nel packaging e stoccaggio .....	88
Capitolo 6: Sfide tecnologiche, industriali ed etiche.....	95
6.1 Motivi di cautela .....	95
6.2 Motivi di ottimismo .....	98
Capitolo 7: Conclusioni e sviluppi futuri.....	103
Ringraziamenti al progetto NODES .....	105
Ringraziamenti Personali .....	105
Bibliografia .....	107



# Abstract

La presente tesi indaga l'impiego dell'Intelligenza Artificiale (IA) nel settore agroalimentare secondario, focalizzandosi sulle sue applicazioni nei processi di trasformazione dei prodotti alimentari. Attraverso un'analisi bibliografica, viene analizzato lo stato dell'arte riguardo agli sviluppi apportati dall'Intelligenza Artificiale nel settore, mettendo in luce le implicazioni e le potenzialità di questa ondata innovativa per il futuro dell'Industria.

Nel primo capitolo vengono esposti il contesto dello studio anche in relazione al problema sottoposto. In secondo luogo viene introdotta la metodologia di ricerca utilizzata per il reperimento delle fonti per la ricerca bibliografica e la struttura dell'elaborato.

Nel secondo capitolo, invece, viene esposta nel dettaglio la metodologia di ricerca insieme ai domini specifici del campo e dell'intersezione dei sottoinsiemi d'interesse per la ricerca. A questo punto si giunge alla sezione dedicata alla qualificazione dei dati e le informazioni riguardanti i criteri scelti come discriminanti per l'inclusione.

Una volta esposto il processo che ha portato alla costruzione della revisione della letteratura, viene presentato un quadro generale sull'Intelligenza Artificiale e una tassonomia per dare un grado di dettaglio e compattezza maggiore alla struttura ed all'elaborato. Vengono proposti anche gli algoritmi e le tecniche maggiormente riscontrate in questo campo applicativo.

A seguito della parte descrittiva ci si addentra in ciò che riguarda la scomposizione delle fasi che intercorrono nell'Industria Agroalimentare Secondaria, partendo dal controllo qualità sulle materie prime fino ad arrivare al packaging ed allo stoccaggio dei prodotti food & beverage. Vengono riportati in tabelle riassuntive gli elementi di interesse rilevati in letteratura letteratura che vengono poi commentati.

Nella parte finale vengono presentate alcune questioni sollevate dalle varie sfide poste dall'applicazione dell'Intelligenza Artificiale nel settore agroalimentare e tratte le conclusioni derivanti dal percorso di tesi, i possibili sviluppi futuri ed aree d'interesse.



# Capitolo 1: Introduzione

## 1.1 Contesto dello studio

Lo studio si colloca all'intersezione tra gli ambiti della produzione alimentare e dell'Intelligenza Artificiale (IA), e più precisamente nei sotto-domini della trasformazione alimentare e della IA applicata.

L'industria alimentare svolge un ruolo fondamentale nella società moderna, fornendo sostentamento e nutrimento a una popolazione globale in continua crescita. La lavorazione, la produzione e la distribuzione efficiente dei prodotti alimentari sono essenziali per garantire la sicurezza alimentare e soddisfare le esigenze nutrizionali umane globali.

La trasformazione degli alimenti non è un concetto nuovo: è stata parte integrante della civiltà umana per secoli. Dalle prime tecniche di conservazione, come l'essiccazione e la salatura, ai metodi più moderni, come l'inscatolamento e la refrigerazione, l'obiettivo è sempre stato quello di prolungare la durata di conservazione degli alimenti, aumentarne la sicurezza e migliorarne il gusto e la qualità. Nel XXI secolo, tuttavia, il ritmo del progresso tecnologico si è accelerato.

L'intelligenza artificiale è il termine portemanteau con il quale si indica un complesso ambito interdisciplinare che studia e realizza sistemi che espongono comportamenti simili a quelli umani. L'IA così provvisoriamente definita è diventata un'area di importanza strategica delle tecnoscienze con il potenziale per essere un motore chiave dello sviluppo economico e della trasformazione sociale. Usiamo il termine "tecnoscienze" perché sembra il più appropriato per l'IA, prendendo a prestito il concetto espresso da Bruno Latour (Bruno Latour, 1987) per il quale le tecnoscienze si riferiscono a quelle scienze create dagli esseri umani in contesti socioeconomici e politici reali, caratterizzati da conflitti e alleanze tra gli esseri umani e anche tra gli esseri umani e i non umani (istituzioni, macchine e animali, tra gli altri).

In questo contesto generale, l'integrazione delle tecnologie di intelligenza artificiale (AI) nei processi di lavorazione degli alimenti è emersa come un approccio trasformativo e promettente.

Tra i fattori che hanno favorito l'adozione di strumenti di IA nell'industria alimentare hanno avuto sicuramente un ruolo preminente la crescente complessità dei processi e del sistema nel suo insieme, unita alla richiesta di aumentare l'efficienza dei processi, di avere flessibilità ed eterogeneità sempre maggiori con la conseguente accelerazione dell'innovazione e sviluppo dei prodotti, e nello stesso tempo mettere in atto standard di qualità e sicurezza sempre più elevati.

L'IA offre infatti un'ampia gamma di funzionalità particolarmente adatte ad affrontare queste sfide: per esempio l'apprendimento automatico, la visione artificiale, l'elaborazione del linguaggio naturale, l'automazione spinta fino ai sistemi ciber-fisici, l'analisi predittiva.

Negli ultimi anni l'adozione e l'integrazione delle tecnologie IA nei processi di trasformazione alimentare si è via via specializzata per rispondere alle esigenze sopra citate e le diverse declinazioni dell'IA si sono differenziate e sono state orientate verso i campi applicativi specifici per i quali sono più adatte.

L'uso dell'IA nella trasformazione alimentare risulta promettente, ed è perciò utile comprendere lo stato attuale dell'adozione in questo settore, identificare le sfide aperte ed esplorare le potenziali aree di sviluppo. Questo lavoro va in questa direzione, esaminando e caratterizzando le applicazioni dell'IA nei diversi passaggi della trasformazione alimentare, lo stato di maturità tecnologica, i benefici accertati, le aree di incertezza.

La comprensione del ruolo dell'IA nei processi di lavorazione alimentare non è un esercizio speculativo, ma è importante per tutti i principali stakeholder: produttori e attori di tutta la supply chain, consumatori, autorità di regolamentazione e ricercatori.

Nella ricerca ci si focalizza prevalentemente sugli elementi in letteratura che mostrano le applicazioni dell'IA nei processi di produzione includendo il controllo di qualità, la sicurezza, la lavorazione, il confezionamento e lo sviluppo del prodotto stesso.

Un aspetto rilevante è il riconoscimento dei limiti della tecnologia, tra cui quelli imposti dalla necessità di grandi moli di dati, di notevoli risorse di calcolo e di personale qualificato. Risulta altresì necessario un approfondimento di livello etico e legale sull'utilizzo delle tecniche in maniera intensiva e, spesso sostitutiva del lavoro umano, nonostante l'utilizzo porti innovazione e un contributo che potrebbe risultare utile nei processi decisionali.

Infine saranno indagate le applicazioni e prospettive future dell'IA nell'industria della trasformazione alimentare, per quanto possibile in un ambito in così rapido sviluppo. L'analisi dell'argomento è stata fatta attingendo alla letteratura pertinente e ai casi di studio documentati.

## 1.2 Esposizione del problema

L'industria della trasformazione alimentare si colloca come snodo essenziale e critico tra l'agricoltura, le altre attività primarie, e il commercio globale, in quanto deve soddisfare le esigenze e le preferenze nutrizionali di miliardi di persone. Proprio per la sua importanza e per l'intreccio di fattori in gioco, questo settore deve affrontare sfide 'vecchie' come il controllo della qualità, la sicurezza, l'efficienza produttiva, e nuove, come quelle derivanti dal cambiamento climatico, della insicurezza della supply chain, della cybersicurezza, ecc. L'integrazione dell'Intelligenza Artificiale (IA) è stata proposta come soluzione trasformativa, ma non tutte le questioni sono risolte.

Le numerose declinazioni dell'IA (approcci, tecnologie, algoritmi, materializzazioni, ecc.) stanno conoscendo un'evoluzione accelerata, che non lascia il tempo per includere meccanismi di *selezione naturale* nel passaggio dalla teoria alla pratica, dalla prova di concetto all'inserimento nel processo produttivo, con l'esito che l'impiego dell'IA nella lavorazione degli alimenti aumenta, ma restano e forse si ampliano le lacune nella comprensione degli aspetti più problematici, e più potenzialmente trasformativi, dell'integrazione dell'IA nei processi e nel sistema. Per questo serve un esame completo dello stato attuale dell'adozione dell'IA e delle sue applicazioni specifiche.

Il focus principale di questa tesi è la mappatura delle applicazioni esistenti e dei relativi *pro* e *contro*, in modo da ottenere una traccia dei percorsi che sono in atto e delle prospettive che si intravedono.

Per le ragioni esposte, nel corso dell'elaborato vengono evidenziati anche gli aspetti maggiormente problematici dell'applicazione dell'IA:

- nel controllo della qualità e sicurezza alimentare;
- per l'efficienza della produzione;
- per l'impatto ambientale.

### 1.3 Scopo dello studio

A partire dal contesto e dai problemi evidenziati, verrà sottoposto un quadro inerente alle soluzioni già adottate che possono essere replicate, di quelle che sono disponibili a certe condizioni e solamente in certi segmenti dei processi, e di quelle che si prospettano per il prossimo futuro.

Le domande di ricerca sono le seguenti:

- Qual è lo stato attuale dell'applicazione dell'IA nei processi di trasformazione alimentare? Quali sono gli utilizzi prevalenti?
- Quali tecniche e algoritmi sono utilizzati e con risultati?
- L'IA sta diventando pervasiva attraverso tutta la filiera agroalimentare, farm to fork (CE, 2019): il processo di trasformazione è al centro. Quali sono le implicazioni che si prospettano, anche di tipo etico?

### 1.4 Metodologia di ricerca

Il lavoro si basa sulla ricerca secondaria e revisione sistematica dei risultati di attività di ricerca originali ed è condotto utilizzando dati già esistenti, estratti e interpretati dai lavori pubblicati sull'argomento, poi analizzati, descritti, e valutati criticamente, per riassumere infine le interpretazioni in una conclusione basata sulle evidenze raccolte.

Le fasi sono state:

- definizione del contesto e formulazione del focus e delle domande di ricerca;
- definizione della strategia e poi attuazione della raccolta e distillazione delle informazioni;
- organizzazione dei dati costruendo le relazioni tra i diversi insiemi ottenuti;
- analisi e interpretazione delle evidenze;
- discussione dei risultati;
- conclusioni.

Alla fine di ogni fase è stato fatto un ciclo di riesame per verificare l'eventuale necessità di rivedere e aggiornare le tappe precedenti .

Sono stati utilizzati strumenti bibliografici come Mendeley<sup>1</sup> e Zotero<sup>2</sup> e di data mining (Recoll)<sup>3</sup>, oltre ai classici fogli di calcolo MS Excel per aggiornare la metodologia e l'iter di passaggi per la raccolta degli articoli ed ai database per la ricerca degli articoli (Scopus, Google Scholar ed altri).

## Capitolo 2: Metodologia di ricerca

### 2.1 Progetto di ricerca

Questa tesi è un lavoro di ricerca secondaria e revisione sistematica basata sui risultati di attività di ricerca originali e condotta utilizzando dati già esistenti, estratti e interpretati dagli studi pubblicati sull'argomento, poi analizzati, descritti, e valutati criticamente, per riassumere infine le interpretazioni autonome in una conclusione basata su evidenze.

La definizione iniziale del problema è stata il passaggio fondamentale per il successivo andamento del lavoro di ricerca e per giungere a conclusioni coerenti. Seguono la delimitazione precisa dell'ambito, i concetti e i criteri chiave, e la definizione della struttura iniziale del lavoro.

Nella pratica reale, le domande non si sono presentate come dati di fatto, ma si sono dovute costruire a partire dal materiale relativo a situazioni talvolta problematiche, difficili e incerte, come sono tipicamente le pubblicazioni di ricerca, che costituiscono l'input primario di questa tesi.

La fase iniziale è stata quindi di dare un senso a una situazione inizialmente sfumata: una volta chiarito il problema centrale e i quesiti di ricerca, abbiamo seguito un processo con cui dare un nome ai concetti a cui prestare attenzione e abbiamo delimitato e inquadrato il contesto in cui trattarli.

---

<sup>1</sup> <https://www.mendeley.com/>

<sup>2</sup> <https://www.zotero.org/>

<sup>3</sup> <https://www.lesbonscomptes.com/recoll/pages/index-recoll.html>

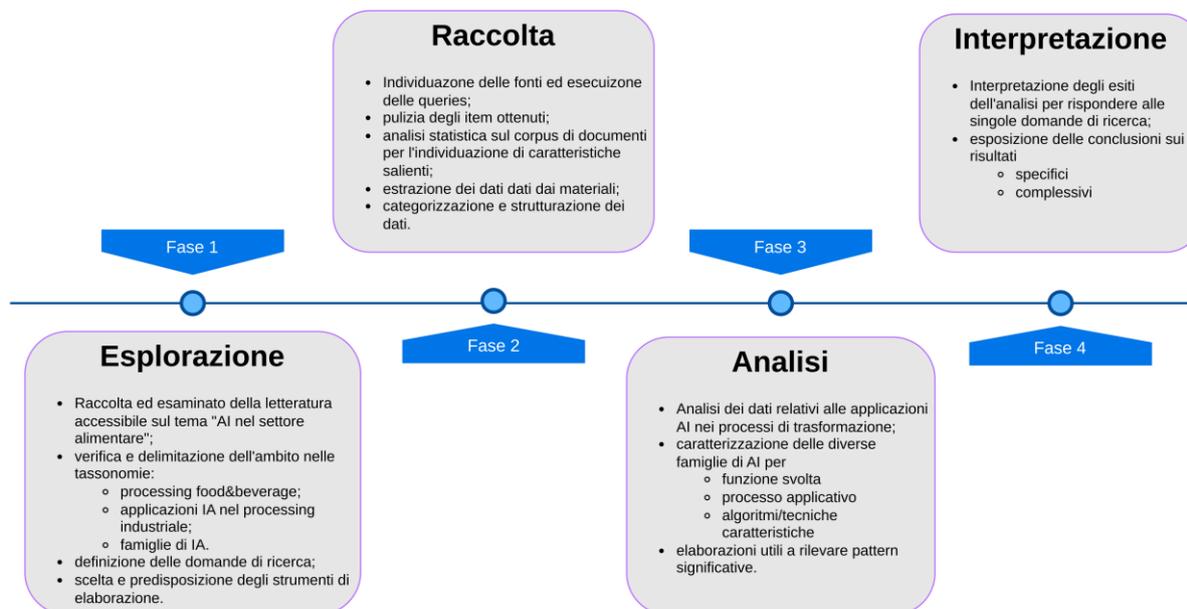


Figura 1: Fasi del progetto di ricerca

I concetti messi al centro sono:

- l'IA e le sue declinazioni;
- il settore industriale della produzione alimentare collocato nel vasto territorio del food&beverage, fino a includere gli alimenti funzionali (JRC, 2008);
- le applicazioni attuali e plausibili dell'IA nei processi di produzione alimentare;
- il contesto non tecnologico, con le sue spinte e vincoli;
- le intersezioni esistenti e potenziali tra questi domini.

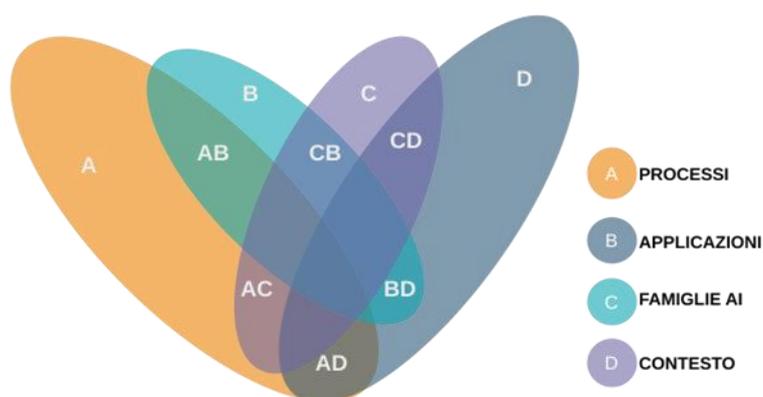


Figura 2: Sottoinsiemi dell' studio

Questa riflessione iniziale, basata su un primo screening di letteratura, ha portato alla formulazione delle domande di ricerca.

Ne deriva il filo logico principale che collega *processi* ⇒ *famiglie di IA* ⇒ *contesto* ⇒ *applicazioni*.

Questo approccio ha anche permesso di delimitare in maniera abbastanza precisa l'ambito tecno-industriale trattato, cioè la fase di trasformazione intesa come *make*. I confini però restano ugualmente sfumati e con molti sconfinamenti.

Ne sono esempi:

- a) la difficile delimitazione della logistica nelle produzioni *in time+custom+on-demand* come nel caso dei pasti take-away preparati sul momento a partire da ordine online e consegnati al banco;
- b) l'integrazione tra manufacturing execution systems (MES)/manufacturing operations management (MOM) di nuova generazione nel modello Industria 4.0, a loro volta connessi con tecnologie operative fortemente dipendenti da Industrial Internet of Things (IoT), (Mantravadi S., et al., 2020).

È quindi emersa la necessità di trovare - almeno limitatamente a questo studio - una sistemazione ai maggiori contenitori di significato e alle loro relazioni:

- le fasi del processo di trasformazione e le relative componenti ;
- i tipi di applicazione dell'automazione (per cui IA è usata o candidata);
- le famiglie di IA, per quanto possibile in un quadro di evoluzione così accelerata.

Si rende cioè necessaria una tassonomia praticabile sia dei processi di trasformazione alimentare che della IA. Restano ovviamente irrisolte molte questioni di glossario: dove utile e possibile saranno utilizzate definizioni locali in assenza di terminologie controllate.

## 2.2 Raccolta dati

### 2.2.1 Strumenti di ricerca e fonti utilizzate

Gli strumenti di ricerca utilizzati sono stati le piattaforme Scopus e Google Scholar per la raccolta degli articoli rilevanti, in aggiunta alle altre piattaforme di Open Access (ArXiv, Zano) o di pubblico dominio.

I sistemi di ricerca dei database utilizzati funzionano tramite l'inserimento di un input sotto forma di frase, titolo dell'articolo, parole chiavi etc. e tramite un algoritmo di ricerca vengono rilasciati come output tutti gli articoli in cui vi è, nel titolo o il corpo del testo, la medesima parola o frase, che è stata precedentemente inserita nella barra di ricerca.

Nel momento in cui vengano utilizzate più parole chiave o frasi, che devono essere presenti entrambe nell'articolo, è necessario delimitare ogni frase (o parola) con “- “ed anteporre in mezzo alle stesse l'operatore AND per permettere al motore di ricerca di presentare tutti gli articoli contenenti le suddette informazioni.

La ricerca nel database può essere effettuata anche utilizzando dei filtri di ricerca come “search within”, presente a sinistra della barra di ricerca dei documenti, in cui è possibile ricercare non solo in base alle keywords, all'abstract o al titolo dell'articolo, ma anche tramite inserimento riferimenti di articoli quali DOI, l'ISSN, ISBN per i libri o altri. La fase di ricerca può essere effettuata anche ponendo altri filtri come la tipologia di documenti, anno di pubblicazione ed autori.

### **2.2.2 Qualificazione delle fonti e dei dati**

I principali criteri considerati per la scelta della letteratura sono:

- autorevolezza e reputazione dell'autore: considerare l'esperienza e la competenza dell'autore, la sua affiliazione istituzionale e il suo impatto nella comunità scientifica;
- reputazione, la qualità e l'autorevolezza della rivista in cui l'articolo è stato pubblicato. Riviste con un alto fattore di impatto sono generalmente considerate più prestigiose;
- metodo di revisione tra pari (peer-review): articoli sottoposti a peer review, nel quale esperti nel campo hanno valutato la qualità e la validità della ricerca;
- contenuto scientifico: valutazione della pertinenza e rilevanza dell'argomento trattato nell'articolo scientifico rispetto all'area di ricerca, analizzare la metodologia utilizzata, i dati raccolti e l'analisi condotta;
- “freschezza” della pubblicazione: utilizzando un intervallo temporale che va dal 2017 al 2023, con lo scopo di ottenere una rilevanza scientifica recente, trascurando le pubblicazioni più datate.

I materiali utilizzati provengono prevalentemente da giornali soggetti a peer review.

In alcuni casi in cui i documenti erano molto interessanti, ma anche molto recenti (il ritmo delle pubblicazioni è molto accelerato), si è preferito comunque includere i materiali in preprint anche se non ancora passati da peer-review.

In altri casi, come nel caso dei testi a supporto di teorie e tecniche consolidate, si sono utilizzati i documenti di riferimento anche se non recenti.

Data l'impossibilità oggettiva di valutare l'autorevolezza e reputazione dell'autore e le metodologie di ricerca (talvolta esse stesse innovative), sul corpo documentale raccolto sono stati fatti i seguenti ulteriori controlli di qualità:

- controllo per escludere eventuali articoli ritrattati;
- mappatura della rete di autori e istituzioni.

Come è noto, nel 2023 si è registrato il numero più elevato di ricercatori (oltre 1600) è stato raggiunto il picco record di articoli riguardanti l'Intelligenza Artificiale e le sue applicazioni (Van Noorden, 2023), ed è quindi ormai necessario almeno un controllo di primo livello. Tramite il database Scopus è possibile, anteporre le parole chiave "Food" & "Artificial intelligence" e capire il numero di pubblicazioni che trattassero l'argomento in considerazione ed avere una prima scrematura (Figura 3):

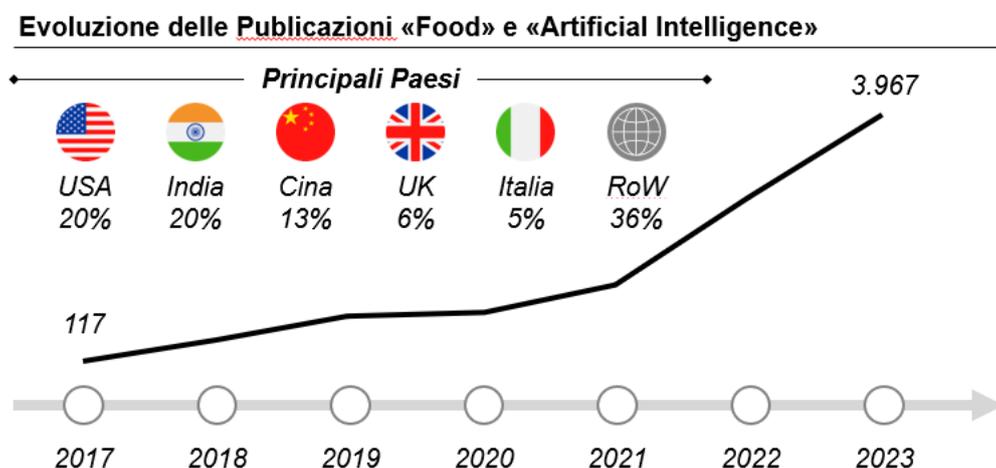


Figura 3: Numero Pubblicazioni sul tema trattato e principali paesi interessati nella ricerca (elaborazione PPT esemplificativa da Scopus)

Come si può notare dalla figura 3, le pubblicazioni inerenti all'intersezione delle parole chiave porta all'elaborazione di circa 4000 documenti scientifici che trattano il tema, rifendosi a differenti trattazioni su tutto il compartimento agroalimentare.

I Principali paesi interessati allo studio sono USA, India e Cina, che detengono oltre il 50% della paternità delle pubblicazioni, seguite da Regno Unito ed, al quinto posto, Italia.

# Capitolo 3: Concetti chiave dell'Intelligenza Artificiale

## 3.1 Evoluzione storica dell'Intelligenza Artificiale

Il primo lavoro sostanziale nel campo dell'Intelligenza Artificiale è stato svolto a metà del XX secolo dal logico britannico e pioniere dell'informatica Alan Mathison Turing. Nel 1935 Turing descrisse una macchina di calcolo astratta costituita da una memoria illimitata e da uno scanner che si muove avanti e indietro nella memoria, simbolo per simbolo, leggendo ciò che trova e scrivendo altri simboli. Le azioni dello scanner sono dettate da un programma di istruzioni, anch'esso memorizzato nella memoria sotto forma di simboli. Questo è il concetto di programma memorizzato di Turing, e in esso è implicita la possibilità che la macchina operi sul proprio programma, modificandolo o migliorandolo. La concezione di Turing è oggi nota semplicemente come macchina universale di Turing. Tutti i computer moderni sono essenzialmente macchine di Turing universali.

Per trovare il termine Intelligenza Artificiale bisogna attendere gli anni '50 quando il termine è stato coniato per la prima volta. Nel 1956, il Dartmouth Workshop ha segnato la nascita dell'IA come campo di studio (Solomonoff, Ray J., 1985).

Negli anni '80 è emersa la tecnologia degli expert system con numerose applicazioni per la diagnosi medica, e il contemporaneo sviluppo di tecniche di IA come la 'backpropagation' per l'addestramento delle reti neurali. Tuttavia, il progresso è stato frenato dalla limitata potenza di calcolo disponibile.

Quando nel 1997 Deep Blue di IBM ha sconfitto il campione di scacchi Garry Kasparov, dimostrando la potenza dell'IA nei giochi strategici, l'attenzione anche mediatica si è riaccesa. Nel 2011, Watson di IBM ha sconfitto campioni umani in Jeopardy! utilizzando l'elaborazione del linguaggio naturale e l'apprendimento automatico. Nel 2015 AlphaGo, sviluppato da DeepMind, ha sconfitto i migliori giocatori di Go del mondo. Questi successi hanno segnato l'inizio del passaggio dell'IA dalla ricerca teorica alle applicazioni pratiche.

Nel 2017 è stato pubblicato il rivoluzionario articolo "Attention is All You Need" (Vaswani, Ashish, et al., 2017) che ha introdotto l'architettura Transformer. Questo modello ha rivoluzionato l'elaborazione del linguaggio naturale e ha gettato le basi per modelli come GPT-3.5, che consentono la generazione e la comprensione di testo simili a quelli umani. ChatGPT, basato su GPT-3.5, è l'esempio principale delle capacità dell'IA nella conversazione.

I progressi nell'IA vanno però oltre l'elaborazione del linguaggio naturale, anche se è questo ambito che ha reso popolare l'IA. Le reti generative di tipo adversarial networks (GAN) hanno permesso sintesi molto evolute di immagini e video, e sono oggi integrate nei sistemi di diagnostica medica avanzata (Aggarwal, Alankrita et al., 2021). Gli algoritmi di apprendimento con rinforzo hanno compiuto progressi significativi nei sistemi di controllo autonomo. AlphaFold sviluppato da DeepMind e basato su deep learning esegue previsioni sulla struttura delle proteine, con risultati che hanno cambiato radicalmente i processi di progettazione del farmaco (MIT Technology Review, 2020).

Il percorso non è stato sempre agevole: alcuni fallimenti<sup>4</sup> hanno portato a pessimismo e tagli ai finanziamenti della ricerca. Due periodi in particolare (1974-1980 e 1987-2000) sono stati definiti come l'*inverno dell'IA*, ma a partire dal 2012 circa, l'interesse per l'IA da parte delle comunità di ricerca e delle aziende ha portato a un sostanziale aumento dei finanziamenti e degli investimenti, con effetti a catena e portando all'attuale boom che ha visto il 2023 come *annus mirabilis* dell'IA.

## 3.2 Sulla definizione e tassonomia dell'IA

L'organizzazione internazionale di standardizzazione ISO definisce l'IA come "capability of an engineered system to acquire, process and apply knowledge and skills", come sistema basato sulla IA "AI-based system → system including one or more components implementing AI" e come sistema autonomo "autonomous system > system capable of working without human intervention for sustained periods" (ISO, 2022)<sup>5</sup>.

Questa definizione, compatta e operativa, ha il suo baricentro nel sistema ingegnerizzato e necessariamente trascura una parte della complessità della nozione di IA. Vale quindi la pena di cogliere l'opportunità data dal fatto che questo lavoro di tesi ricade nel periodo in cui l'Unione

---

<sup>4</sup> Tra questi il fallimento della traduzione automatica (1966); (1969) critiche ai perceptron (le prime reti neurali artificiali a singolo strato) (1971-75); frustrazione della DARPA nei confronti del programma di ricerca sulla comprensione del parlato dell'Università Carnegie Mellon (1973); forte diminuzione della ricerca sull'IA nel Regno Unito in risposta al rapporto Lighthill (1973-74); Tagli della DARPA alla ricerca accademica sull'IA in generale (1987); crollo del mercato delle macchine LISP (1988); cancellazione di nuove spese per l'IA da parte della Strategic Computing Initiative (Anni '90); abbandono di molti sistemi esperti (Anni '90); fine degli obiettivi originari del progetto sui computer di quinta generazione.

<sup>5</sup> Organizzazione internazionale di standardizzazione, <https://www.iso.org/home.html>

Europea diventerà la prima autorità pubblica al mondo a introdurre una regolamentazione vincolante sull'IA, con l'AI Act (Consiglio UE, 2023).

Per pervenire al regolamento, le istituzioni comunitarie hanno fatto un lungo lavoro, che si è avvalso del Centro Comune di Ricerca della Commissione europea (JRC, 2020) e delle migliori conoscenze ed expertise disponibili nelle organizzazioni scientifiche e politiche europee ed internazionali.

Considerando che anche l'ambito 'food' è fortemente regolamentato, è ragionevole utilizzare le definizioni normative come guida ai concetti fondamentali dell'IA. Il lavoro sinottico del JRC riporta le definizioni maturate nei diversi paesi, con alcune differenze.

Il High-Level Expert Group on AI ha concordato sulla seguente definizione della IA (Rossi, F., 2020) che è poi stata ripresa dal AI Act: "L'Intelligenza Artificiale (IA) si riferisce a sistemi progettati dall'uomo che, dato un obiettivo complesso, agiscono nel mondo fisico o digitale percependo l'ambiente circostante, interpretando i dati strutturati o non strutturati raccolti, ragionando sulla conoscenza derivata da questi dati e decidendo le azioni migliori da intraprendere (secondo parametri predefiniti) per raggiungere l'obiettivo dato. I sistemi di IA possono anche essere progettati per imparare ad adattare il loro comportamento analizzando come l'ambiente è influenzato dalle loro azioni precedenti. Come disciplina scientifica, l'IA comprende diversi approcci e tecniche, come l'apprendimento automatico (machine learning di cui il deep learning e il reinforced learning sono esempi specifici), il ragionamento automatico (che comprende la pianificazione, la programmazione, la rappresentazione, ragionamento, ricerca e ottimizzazione della conoscenza) e la robotica (che comprende il controllo, la percezione, i sensori e gli attuatori, nonché l'integrazione di tutte le altre tecniche nei sistemi cyber-fisici).<sup>6</sup>

---

<sup>6</sup> "Artificial intelligence (AI) refers to systems designed by humans that, given a complex goal, act in the physical or digital world by perceiving their environment, interpreting the collected structured or unstructured data, reasoning on the knowledge derived from this data and deciding the best action(s) to take (according to pre-defined parameters) to achieve the given goal. AI systems can also be designed to learn to adapt their behaviour by analysing how the environment is affected by their previous actions. As a scientific discipline, AI includes several approaches and techniques, such as machine learning (of which deep learning and reinforcement learning are specific examples), machine reasoning (which includes planning, scheduling, knowledge representation and reasoning, search, and optimization), and robotics (which includes control, perception, sensors and actuators, as well as the integration of all other techniques into cyber-physical systems)"

Già nella definizione si accenna a una tassonomia, che il JRC propone e precisa come in Tabella 1:

La tassonomia proposta dal JRC<sup>7</sup> è anche finalizzata a una lettura applicativa della IA, attraverso i collegamenti con quelli che sono definiti segmenti tecno-economici (*techno-economic segments - TES*) e che rappresentano il livello più generale di intersezione tra IA e applicazioni.

- Il dominio del *Ragionamento* affronta il modo in cui le macchine trasformano i dati in conoscenza o deducono (inferiscono) fatti dai dati.
- Il dominio della *Pianificazione* (automatizzata) riguarda la progettazione e l'esecuzione di strategie per svolgere una certa attività, tipicamente eseguita da agenti intelligenti, robot autonomi e veicoli senza pilota. Le soluzioni sono complesse e devono essere scoperte e ottimizzate nello spazio multidimensionale.
- Il dominio dell'*Apprendimento* (automatico, o *machine learning*) riguarda la capacità dei sistemi di apprendere, decidere, prevedere, adattarsi e reagire automaticamente ai cambiamenti, migliorando sulla base dell'esperienza, senza essere esplicitamente programmati. Il machine learning (ML) è incluso nella maggior parte delle categorizzazioni della IA come approccio algoritmico di base per ottenere IA indipendentemente dal tipo di apprendimento (rinforzo, supervisionato, semi-supervisionato, non supervisionato).
- Nel dominio della *Comunicazione* il concetto principale si riferisce alla capacità della macchina di identificare, elaborare, comprendere e/o generare informazioni nelle comunicazioni umane scritte e parlate e comprende applicazioni come la generazione di testi, l'estrazione di testi, la classificazione e la traduzione automatica.
- Il dominio della *Percezione* si riferisce alla capacità dei sistemi di rendersi conto dell'ambiente circostante attraverso i sensi: visione, udito, manipolazione, ecc. La visione artificiale (*computer vision*) si riferisce al riconoscimento di pattern di immagini per compiti specifici o, in senso più ampio, alla visione artificiale, con applicazioni per il

---

<sup>7</sup> Joint Research Centre (European Commission), R. Righi, G. De Prato, M. Cardona, M. Vázquez-Prada Baillet, S. Samoili, and M. López Cobo, *The AI Techno-Economic Segment Analysis: Preliminary Report*, Publications Office of the European Union, LU, 2019. <https://data.europa.eu/doi/10.2760/576586>.

riconoscimento di volti e corpi, il riconoscimento di contenuti video, la ricostruzione 3D, la sicurezza pubblica, la salute, ecc.

- Il dominio trasversale dell'*Integrazione* e dell'*Interazione* si occupa della combinazione di percezione, ragionamento, azione, apprendimento e interazione con l'ambiente, come pure di caratteristiche come la distribuzione, il coordinamento, la cooperazione, l'autonomia per produrre interazione e integrazione. In questo ambito la *Robotica* e l'*Automazione* si riferiscono all'applicazione di strumenti tecnologici intelligenti per assistere o sostituire l'attività umana, o per consentire azioni che non sono umanamente possibili, per superare limitazioni tecniche, ottimizzare il lavoro o i costi di produzione. Fanno parte di questo dominio i sotto-domini che riguardano i veicoli autonomi, connessi e i sistemi di guida assistita (CAV), le tecnologie di comunicazione *vehicle-to-everything* (V2X), i sistemi senza pilota (droni), così come la robotica e l'automazione dei processi per usi industriali, sociali e di altro tipo che sono trattati come suddivisioni separate dell'IA.
- Il dominio trasversale dei *servizi di IA* si riferisce a qualsiasi infrastruttura, software e piattaforma (cognitive computing, framework di ML, bot e assistenti virtuali, software di intelligenza adattiva, ecc.) forniti come servizi o applicazioni (serverless, API, piattaforme) di solito nel cloud, che sono disponibili *off-the-shelf* ed eseguiti su richiesta, riducendo il bisogno di creare e gestire infrastrutture complesse.
- Il dominio dell'*Etica* e della *Filosofia* dell'IA riguarda le questioni filosofiche ed etiche che si stanno moltiplicando e suscitando l'attenzione dei cittadini e l'interesse politico dei governi, man mano che i sistemi intelligenti si diffondono. L'etica dell'IA è considerata un sotto-dominio trasversale, perché i progressi e le applicazioni dell'IA in diversi settori devono garantire la conformità ai principi e ai valori etici, comprese le normative applicabili. Dato l'impatto attuale e potenziale sugli esseri umani e sulla società, la creazione di fiducia nell'IA è al centro di diverse iniziative da parte di enti e istituzioni politiche.

Nello stesso studio il JRC ha anche ricavato un insieme di parole chiave, potenzialmente molto utile anche per lavori futuri.

	<b><u>Dominio IA</u></b>	<b><u>sotto-dominio IA</u></b>
<b>Centrale</b>	<i>Ragionamento</i>	Rappresentazione della conoscenza Ragionamento automatico Ragionamento di senso comune Pianificazione e programmazione
	<i>Pianificazione</i>	Ricerca
		Ottimizzazione
	<i>Apprendimento (ML)</i>	Apprendimento automatico
	<i>Comunicazione</i>	Elaborazione del linguaggio naturale (NLP)
	<i>Percezione</i>	Visione artificiale Elaborazione audio
<b>Trasversale</b>	Integrazione e interazione	Sistemi multi-agente Robotica e automazione Veicoli connessi e automatizzati
	Servizi	Servizi di IA
	Etica e filosofia	Etica dell'IA
		Filosofia dell'IA

Tabella 1: Tassonomia dell'IA tratta dal lavoro di JRC (cit.)

Una vista complementare, basata sulle famiglie di tecnologie, è presentata nel poster di (Mauro José Pappaterra, 2022) riportata in figura 4:

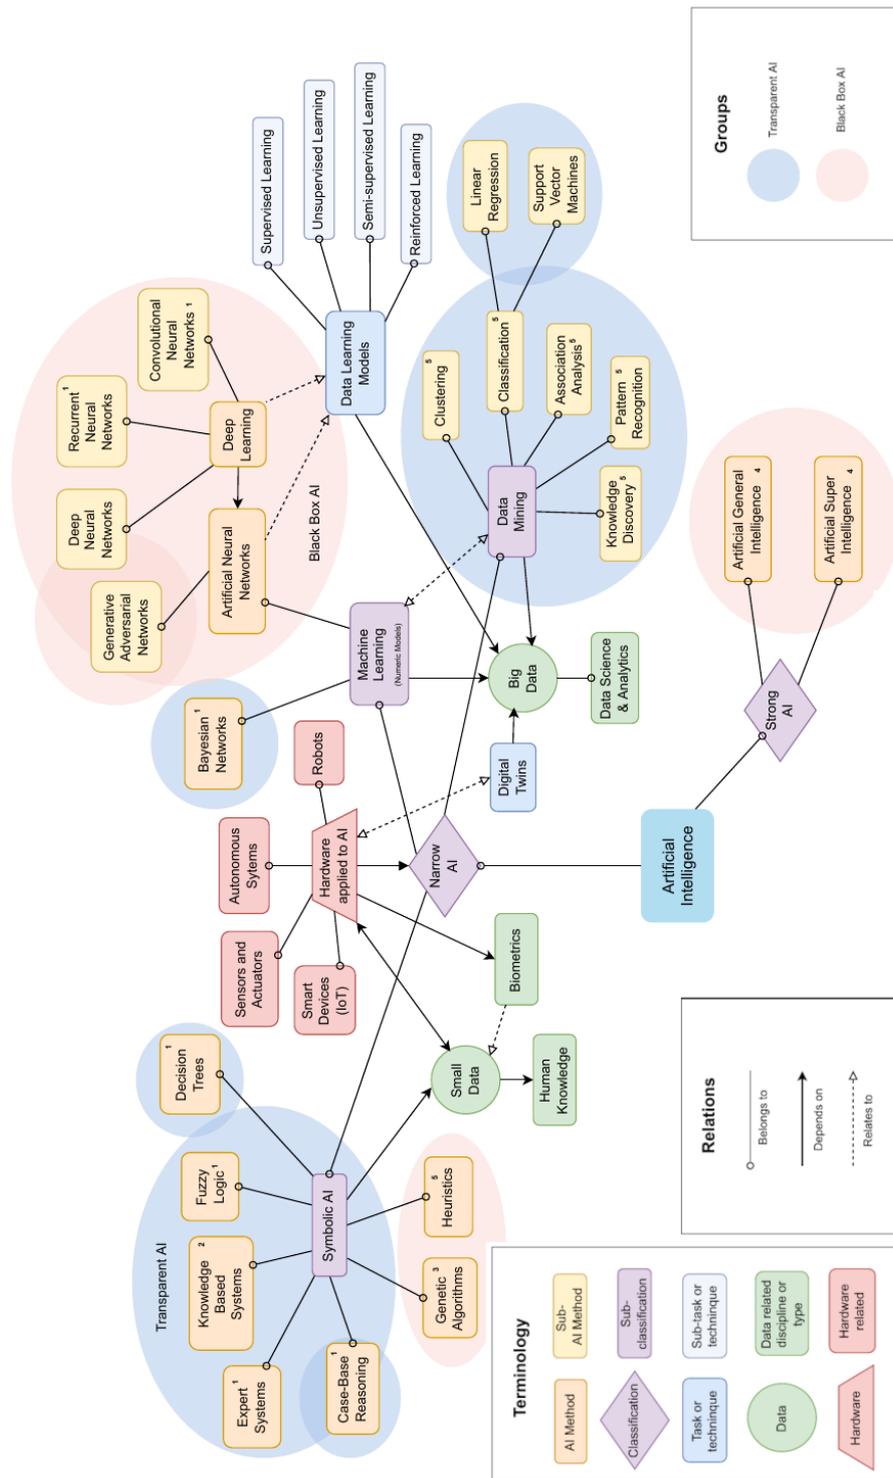


Figura 4: Tassonomia dell'IA basata sulle relazioni tecnologiche, Pappaterra M.J. (2022) "Artificial Intelligence Taxonomy" Available at: <https://doi.org/10.13140/RG.2.2.18114.25284/1>.

Considerare entrambi gli approcci aiuta a comprendere quanto sia complesso il sistema multidisciplinare che caratterizza l'IA e permette anche di orientarsi nella ricerca e interpretazione della letteratura. Dopo una prima tassonomia è così possibile ottenere un primo livello descrittivo delle famiglie di IA e delle applicazioni generali. Verranno discussi i principali algoritmi/metodi e come si associano alle applicazioni/funzioni generali.

## 3.3 Descrizione di tecniche ed algoritmi di IA

### 3.3.1 Machine Learning

Il Machine Learning (ML) (o Apprendimento automatico) è una branca dell'Intelligenza Artificiale che si concentra sulla costruzione di sistemi in grado di apprendere dai dati cercando di interpretare le relazioni significative tra gli input ed output prestabiliti. A differenza della programmazione tradizionale, in cui l'uomo definisce esplicitamente le regole e la logica, il ML consente ai computer di apprendere e prendere decisioni dai dati sottoposti senza essere esplicitamente programmati per il compito combinando elementi di informatica, statistica e scienza dei dati. Il processo di apprendimento inizia fornendo agli algoritmi di apprendimento automatico le informazioni sotto forma di dati e consentendo al sistema di imparare di più sulle informazioni proposte. Con il tempo, i sistemi di ML possono identificare modelli, diversi in relazione al risultato che si vuole ottenere, e prendere decisioni in maniera automatizzata e con un intervento umano richiesto minimo (Manesh Batta, 2020).

Esistono vari tipi di metodi di apprendimento automatico: l'apprendimento supervisionato, in cui l'algoritmo impara da un set di dati di addestramento che include sia gli input che gli output desiderati; l'apprendimento non supervisionato, che prevede l'addestramento con dati che non hanno risposte etichettate e viene utilizzato per trovare una struttura nei dati; e l'apprendimento per rinforzo, in cui un agente impara a prendere decisioni eseguendo azioni e ricevendo feedback sui risultati di tali azioni (Janiesch et al., 2021).

Le applicazioni pratiche di questi metodi sono ampie e diversificate e vanno dai servizi di uso comune come i sistemi di raccomandazione nell'e-commerce e le piattaforme di streaming ad applicazioni più complesse come le auto a guida autonoma, il riconoscimento vocale e la modellazione predittiva in finanza e sanità. I modelli di apprendimento automatico sono in grado di migliorare la diagnosi medica, automatizzare le attività di routine nella produzione,

migliorare la personalizzazione nel marketing e molto altro ancora. Il campo continua a evolversi rapidamente, con ingenti investimenti in ricerca e sviluppo che aprono quasi quotidianamente nuove possibilità di applicazione e nuove prospettive (Sarker Iqbal H., 2012).

### **3.3.2 Reti Neurali Artificiali**

Le reti neurali (artificial neural network in inglese, ANN), sono un tipo di modello di machine learning progettato per imitare la funzione e la struttura del cervello umano. Sono costituite da nodi interconnessi, o neuroni artificiali, organizzati in strati: uno strato di ingresso, uno o più strati nascosti e uno strato di uscita. In questo sistema, ogni nodo elabora le informazioni che riceve dal nodo precedente e le trasmette allo strato successivo che rielabora e le ritrasmette a sua volta con una connessione tale da assomigliare alle sinapsi presenti nel cervello, in grado inoltre, di imparare dai propri errori e di migliorare nel tempo diventando così sistemi adattivi, esattamente come il cervello umano. Vengono utilizzate per riconoscere le relazioni sottostanti in un insieme di dati e possono adattarsi a input mutevoli, generando il miglior risultato possibile senza dover riprogettare i criteri di output (A.D. Dongare, 2012).

Le reti neurali funzionano elaborando grandi insiemi di dati etichettati o non etichettati durante la fase di addestramento. Imparano a svolgere i compiti analizzando gli esempi di addestramento e regolando i pesi delle connessioni tra i nodi in base all'errore delle previsioni con un processo di apprendimento generalmente supervisionato, in cui viene fornita alla rete la risposta corretta per ogni esempio durante l'addestramento, diventando capaci, una volta addestrate, di elaborare con maggiore precisione gli input sconosciuti. La loro natura di "scatola nera" rende inaccessibile il percorso con cui fanno le loro previsioni, con importanti implicazioni di natura etica e legale.

### **3.3.3 Deep Learning**

Il Deep Learning (apprendimento profondo), è un sottoinsieme del Machine Learning, che impiega reti neurali artificiali con vari strati di unità di elaborazione per ricavare modelli complessi nei dati. Queste reti neurali, soprattutto quelle con molti strati (da cui il termine "profondo"), consentono al sistema di apprendere e prendere decisioni intelligenti autonomamente. Un aspetto fondamentale dell'apprendimento profondo è la capacità di apprendere automaticamente le rappresentazioni delle caratteristiche dai dati grezzi, eliminando la necessità di estrarre manualmente le caratteristiche.

Ciò è particolarmente evidente in compiti come il riconoscimento di pattern di immagini complessi e del parlato, dove i modelli di deep learning possono imparare automaticamente a identificare modelli e a fare previsioni o classificazioni accurate sulla base dei dati appresi (Chollet Francois, 2017).

### **3.3.4 Apprendimento Rinforzato**

L'apprendimento Rinforzato (Reinforced Learning, RL) rappresenta un'area del Machine Learning in cui un agente impara a prendere decisioni eseguendo azioni in un ambiente e ricevendo un feedback sotto forma di ricompense o penalità. Questo feedback aiuta l'agente a comprendere le conseguenze delle sue azioni e a perfezionare gradualmente la sua strategia per massimizzare queste ricompense cumulative. Il processo di apprendimento è tipicamente inquadrato come un processo decisionale di Markov, con l'agente che mira a scoprire una politica che detta l'azione migliore da intraprendere per ogni stato per perseguire il risultato maggiormente favorevole a lungo termine. L'unicità della RL sta nel fatto che si concentra sull'apprendimento dall'interazione con l'ambiente, piuttosto che da istruzioni dirette o da serie di dati statici: provando diverse strategie, osservando i risultati e regolando le azioni future in base ai successi e ai fallimenti passati (Woergoetter et al., 2008).

Il RL viene utilizzato nella robotica per insegnare alle macchine a svolgere compiti complessi che sarebbero difficili da programmare esplicitamente, come camminare o manipolare oggetti. Nei giochi e nelle simulazioni, gli algoritmi di RL hanno raggiunto prestazioni superiori a quelle umane in giochi complessi come il Go, gli scacchi e lo shogi (p. es. AlphaZero) dimostrando la capacità di RL di gestire problemi con vasti spazi di ricerca e strategie intricate. L'RL viene applicato alla guida autonoma per prendere decisioni in ambienti dinamici, alla finanza per il trading algoritmico e alla sanità per la raccomandazione di trattamenti personalizzati. La versatilità e l'adattabilità di RL lo rendono uno strumento potente per risolvere un'ampia gamma di problemi che richiedono un processo decisionale sequenziale e l'interazione con ambienti incerti.

### **3.3.5 Apprendimento supervisionato**

L'apprendimento supervisionato (Supervised Learning, SL) è una tecnica di Machine Learning in cui un algoritmo viene addestrato su un insieme di dati di input e output. L'obiettivo è quello di far apprendere all'algoritmo una relazione tra gli stessi in modo che possano essere fatte

previsioni o classificazioni su nuovi dati sottoposti facendo previsioni qualitative mediante la regressione, oppure ipotesi quantitative sui valori con classificazione (Trevor Hastie et al., 2001). In un problema di apprendimento supervisionato, si forniscono all' algoritmo dei dati di addestramento che contengono coppie di input e output già etichettate. Ad esempio, si cerca di addestrare un algoritmo per riconoscere immagini di animali, i dati di addestramento potrebbero consistere in immagini di animali (input) accompagnate dalle etichette corrispondenti che indicano quale animale è raffigurato (output). Una volta forniti i dati di addestramento, l'algoritmo inizia il processo di apprendimento con l'obiettivo di trovare una funzione o un modello in grado di mappare input ed output in modo accurato. Durante il processo di addestramento, l'algoritmo regola i suoi parametri in base ai dati di addestramento, cercando di ridurre al minimo l'errore tra le previsioni dell'algoritmo e le etichette effettive e valuta la prestazioni su dati non visti durante l'addestramento attraverso la divisione dei dati disponibili in un insieme di addestramento e un insieme di test. Di conseguenza, l'algoritmo viene addestrato sui dati di addestramento e quindi valutato sui dati di test per vedere quanto bene generalizza alle nuove istanze.

Le prestazioni dell'algoritmo vengono valutate utilizzando metriche appropriate per il tipo di problema. Ad esempio, per un problema di classificazione, potrebbe essere utilizzata l'accuratezza (percentuale di previsioni corrette), mentre per un problema di regressione, si potrebbe utilizzare l'errore quadratico medio (Susheel et al., 2017). Una volta che il modello ha mostrato di funzionare bene sui dati di test, può essere utilizzato per fare previsioni su nuovi e con l'obiettivo principale di fare previsioni o prendere decisioni su nuovi dati non visti in precedenza.

### **3.3.6 Apprendimento non supervisionato**

L'apprendimento non supervisionato è una tecnica di machine learning in cui un algoritmo viene addestrato su un insieme di dati senza essere fornite delle etichette o delle risposte corrette. L'obiettivo principale dell'apprendimento non supervisionato è quello di trovare pattern o strutture nascoste nei dati senza la guida di etichette o output predefiniti (Gareth James et al., 2023)

Inizialmente, vengono forniti all'algoritmo dei dati di addestramento, ma a differenza dell'apprendimento supervisionato, questi dati non sono etichettati e, perciò, l'algoritmo riceve solo input, senza alcuna informazione su quali dovrebbero essere le risposte corrette.

Successivamente, l'algoritmo esplora i dati alla ricerca di pattern, relazioni o strutture nascoste attraverso diverse tecniche, come il clustering, la riduzione della dimensionalità, la scoperta di regole di associazione ed altro. Una volta analizzati i dati e trovata la struttura o dei pattern, è necessario interpretare i risultati e questo può richiedere un'analisi umana per comprendere cosa rappresentano esattamente i cluster o le relazioni scoperte dall'algoritmo.

In breve, l'apprendimento non supervisionato è utile quando si desidera esplorare e scoprire pattern o strutture nei dati senza la guida di etichette o output predefiniti. Questa tecnica è ampiamente utilizzata in settori come il riconoscimento di modelli, l'analisi dei dati, il riconoscimento del linguaggio naturale ed altri (Muhammad Usama et al., 2019).

### **3.3.7 Apprendimento semi-supervisionato**

L'apprendimento semi-supervisionato è una tecnica che si inserisce fra l'apprendimento supervisionato e l'apprendimento non supervisionato. In questo tipo di apprendimento, l'algoritmo viene addestrato su un insieme di dati che contiene sia dati etichettati (come nell'apprendimento supervisionato) che dati non etichettati (come nell'apprendimento non supervisionato) per imparare una rappresentazione dei dati e una relazione tra input e output, attraverso due principali approcci di tipo semi-supervisionato ovvero classificazione e clustering:

Nella classificazione, l'approccio semi-supervised learning sfrutta l'informazione fornita dai dati etichettati per migliorare le prestazioni del modello, mentre utilizza i dati non etichettati per raffinare ulteriormente le previsioni del modello e migliorare la sua capacità di generalizzazione. Questo viene spesso realizzato attraverso tecniche di transfer learning, active learning o co-training, dove il modello utilizza i dati non etichettati per scoprire nuove informazioni che possono essere incorporate nel processo di apprendimento (Padmanabha Reddy et al., 2018).

Nel clustering, invece, il modello cerca di combinare l'informazione fornita dai dati etichettati con la struttura intrinseca dei dati non etichettati per migliorare la qualità e la coerenza dei cluster identificati dal modello. Questo può essere realizzato attraverso tecniche come il constrained clustering, dove i vincoli derivati dai dati etichettati sono incorporati nel processo di clustering per guidare l'assegnazione dei punti non etichettati ai cluster.

Complessivamente, il semi-supervised learning offre un compromesso tra l'efficienza e l'efficacia del learning supervisionato e non supervisionato, sfruttando le informazioni

disponibili nei dati etichettati e non etichettati per migliorare le prestazioni del modello. Questa tecnica è particolarmente utile in situazioni in cui è costoso o difficile ottenere un grande numero di dati etichettati, ma sono disponibili molte istanze di dati non etichettati.

### **3.3.8 Naive Bayes**

Il metodo Naive Bayes è un algoritmo di apprendimento semplice ma efficace che sfrutta la regola di Bayes e l'ipotesi di indipendenza condizionale tra gli attributi (Webb Geoffrey, 2010). Ciò significa che l'algoritmo presuppone che la presenza di una particolare caratteristica in una classe non sia correlata alla presenza di qualsiasi altra caratteristica. Nonostante questa forte assunzione sia spesso violata nella pratica, Naive Bayes offre spesso un'accuratezza di classificazione competitiva utilizzando i dati del campione per stimare la probabilità posteriore di ciascuna classe data da un oggetto, che può essere utilizzata per la classificazione o altre applicazioni di supporto alle decisioni. È efficiente dal punto di vista computazionale, in quanto, il tempo di addestramento e di classificazione è lineare rispetto al numero di esempi di addestramento e di attributi.

Naive Bayes è stato applicato in diversi campi, tra cui la classificazione dei testi e il rilevamento dello spam, ottenendo spesso risultati sorprendenti nonostante la sua semplicità.

### **3.3.9 k-Nearest Neighbour**

L'algoritmo dei K-Nearest Neighbors, o k-NN, è un metodo utilizzato nel machine learning per classificare o prevedere valori su nuovi dati. Funziona considerando un set di dati di addestramento in cui ogni punto è rappresentato come un vettore di caratteristiche in uno spazio multidimensionale. Quando viene presentato un nuovo punto dati, l'algoritmo calcola la sua distanza rispetto a tutti i punti nel set di addestramento utilizzando una specifica metrica di distanza, come la distanza euclidea e, successivamente, seleziona i K punti più vicini, che rappresentano un iperparametro scelto in anticipo e che influenza le prestazioni dell'algoritmo, al nuovo punto in base alla distanza calcolata. Per problemi di classificazione, si effettua una votazione tra i K vicini più vicini per determinare la classe del nuovo punto, mentre per problemi di regressione si calcola la media dei valori dei K vicini. Il valore di K è un iperparametro che deve essere scelto in anticipo e può influenzare le prestazioni dell'algoritmo (Guo Gondge et al., 2003).

Il k-NN è semplice da capire e da implementare e può gestire dati con relazioni complesse, tuttavia, può essere computazionalmente costoso per insiemi di dati di grandi dimensioni e risulta sensibile al rumore e agli outlier nei dati del dataset. Il k-NN è utilizzato prevalentemente nella classificazione di immagini, nel riconoscimento della scrittura manuale, nella segmentazione dei clienti, nel rilevamento delle frodi e nella diagnosi medica (Uddin et al., 2022).

### **3.3.10 Decision Tree**

Un albero decisionale è un algoritmo predittivo utilizzato nel Machine Learning per il supporto decisionale. Si tratta, infatti, di una rappresentazione grafica delle possibili soluzioni su una decisione basata su determinate condizioni, che viene strutturata in un modello gerarchico ad albero che comprende un nodo radice, rami, nodi interni e nodi foglia (Navada Arundathi et al., 2011). L'algoritmo parte dal nodo radice e si dirama per dimostrare i vari risultati; ogni ramo rappresenta una possibile decisione e conduce a ulteriori nodi interni o a nodi terminali (nodi foglia). Gli alberi decisionali sono molto usati per la loro semplicità di rappresentazione visiva dei dati, che li rende facilmente comprensibili e vengono impiegati nel marketing, nelle diagnosi mediche e nella gestione aziendale. L'accuratezza di un albero decisionale è tipicamente quantificata utilizzando metriche di errore e man mano che l'algoritmo accede a un maggior numero di dati, è in grado di prevedere i risultati per i dati futuri, rendendolo uno strumento utile per il processo decisionale e la modellazione predittiva in produzione (Kim et al., 2022).

### **3.3.11 Random Forest**

Random Forest è un algoritmo di machine learning innovativo, fondato sul concetto dell'ensemble learning, che combina molteplici alberi decisionali indipendenti durante il processo di addestramento, formando una "foresta" in cui ciascun albero viene addestrato su un sottoinsieme casuale dei dati di addestramento e delle caratteristiche disponibili (Biau Gerard et al., 2016). Durante la previsione, le previsioni di tutti gli alberi nella foresta vengono combinate attraverso una votazione o una media per ottenere una previsione finale. Consentendo di ridurre la varianza e migliorare la capacità di generalizzazione del modello, rendendolo particolarmente adatto a problemi con grandi quantità di dati e caratteristiche.

### **3.3.12 Fuzzy Logic**

La logica fuzzy (logica sfumata) è un approccio nell'ambito dell'intelligenza artificiale che si differenzia dalla logica binaria per la gestione di concetti vaghi o sfumati. Invece di trattare le variabili come categoricamente vere o false, la logica fuzzy consente di rappresentare la verità su una scala continua, dove le variabili possono assumere valori compresi tra 0 e 1, indicando il grado di appartenenza a un certo insieme. Questo significa che, anziché etichettare una variabile come "alto" o "basso", questa logica permette di esprimere il concetto di "quanto è alto" o "quanto è basso" in modo più sfumato (Gerla Giangiacomo, 2001).

Nell'intelligenza artificiale, la logica fuzzy trova applicazioni in una varietà di campi, come i sistemi di controllo, l'elaborazione del linguaggio naturale, il riconoscimento di pattern e la robotica. Ad esempio, nei sistemi di controllo, la logica fuzzy consente di stabilire regole linguistiche basate su input vaghi anziché su regole basate su condizioni binarie, consentendo di gestire e manipolare dati offrendo una maggiore flessibilità e adattabilità rispetto alla logica classica binaria.

### **3.3.13 Knowledge Based Systems**

Un Knowledge-Based System (Sistema Basato sulla Conoscenza) nell'ambito dell'intelligenza artificiale è un tipo di sistema progettato per rappresentare, acquisire, manipolare e utilizzare la conoscenza per risolvere problemi o prendere decisioni in un determinato dominio di applicazione. Questi sistemi sono progettati per emulare il modo in cui gli esseri umani utilizzano la conoscenza e l'esperienza per affrontare compiti complessi.

I Knowledge-Based System sono utilizzati in una varietà di settori e applicazioni, inclusi i sistemi esperti, i sistemi di supporto decisionale, i sistemi di diagnostica medica, i sistemi di gestione del know-how aziendale e molti altri. Grazie alla loro capacità di rappresentare e utilizzare la conoscenza umana, questi sistemi possono affrontare problemi complessi e supportare decisioni in contesti in cui la conoscenza è essenziale.

### **3.3.14 Case-Base Reasoning**

Il Case-Based Reasoning (CBR), o ragionamento basato sui casi, nell'ambito dell'Intelligenza Artificiale, è un approccio che si basa sull'utilizzo di esperienze passate, o "casi", per risolvere problemi nuovi. Funziona in modo simile al modo in cui le persone affrontano nuove situazioni prendendo spunto dalle esperienze passate simili (Kolodner Janet, 1992).

Il processo inizia con la memorizzazione di una collezione di casi passati, ciascuno dei quali rappresenta una situazione specifica, una soluzione adottata e i risultati ottenuti. Quando si affronta un nuovo problema, il sistema CBR cerca casi simili nella sua base di conoscenza e adatta le soluzioni passate alla situazione attuale includendo la modifica dei dettagli della soluzione passata o la combinazione di più casi per risolvere il problema attuale e dimostrandosi un approccio efficace per affrontare problemi complessi e dinamici nell'ambito dell'Intelligenza Artificiale.

### **3.3.16 Recurrent Neural Network**

Le Recurrent Neural Networks (RNN), o reti neurali ricorrenti, sono un tipo di architettura di rete neurale artificiale progettata per lavorare con dati sequenziali o dati che hanno una struttura temporale. A differenza delle reti neurali tradizionali, le RNN hanno una struttura che consente loro di mantenere una "memoria" o uno "stato" interno, che consente loro di elaborare sequenze di dati in modo sequenziale e catturare relazioni a lungo termine nei dati.

Nelle RNN, l'output di un nodo in un determinato momento dipende non solo dall'input corrente, ma anche dagli output precedenti e dallo stato interno della rete e questo consente alle RNN di catturare informazioni sulla sequenza dei dati e di mantenere una sorta di "memoria" delle informazioni passate, che può essere utilizzata per guidare l'elaborazione dei dati futuri. Esse trovano principale applicazione nel riconoscimento di immagini, sintesi dei discorsi, traduzione del linguaggio naturale ed altro (Lipton Zachary et al., 2015).

### **3.3.17 Modelli Sequence to Sequence**

I modelli Sequence-to-Sequence (Seq2Seq models) sono una classe di architetture di rete neurale progettate per elaborare sequenze di dati e generare sequenze come output e sono di solito implementati con RNN o architetture transformers. Sono costituiti da due componenti principali: un codificatore e un decodificatore. Il codificatore prende una sequenza di input (per esempio una sequenza di parole in una frase) e la codifica in una rappresentazione vettoriale di lunghezza fissa, definita "contesto" o "thought vector". Il decodificatore prende quindi questo vettore di contesto come input e genera una sequenza di output, passo dopo passo.

I modelli Seq2Seq hanno avuto particolare successo perché hanno consentito la gestione di sequenze di input e output di lunghezza variabile nella traduzione automatica, dove prendono una frase in una lingua, la codificano in un vettore e quindi la decodificano in una frase in

un'altra lingua. Vengono utilizzati anche nella generazione di sequenze per il riepilogo del testo, la risposta alle domande e le risposte dei chatbot (Yousuf et al., 2021).

### **3.3.18 Reti Long Short-Term Memory**

Le reti LSTM (Long Short-Term Memory) sono un tipo avanzato di rete neurale ricorrente (RNN) progettata per risolvere il problema del gradiente (vanishing gradient problem) (Basodi et al., 2020) che può verificarsi durante l'addestramento delle RNN standard e che è un problema comune alle RNN tradizionali in cui il contributo delle informazioni decade geometricamente nel tempo, rendendo difficile per il modello apprendere le dipendenze a lunga distanza. Le LSTM sono in grado di apprendere le dipendenze a lungo termine nelle serie di dati, che è fondamentale per compiti che richiedono la comprensione del contesto su lunghi intervalli di tempo. Questo risultato è ottenuto grazie a un'architettura complessa che comprende celle di memoria e porte multiple di input, di output e di forget che regolano il flusso di informazioni. Queste porte controllano la misura in cui un nuovo input influisce sulla memoria, la misura in cui la memoria viene utilizzata per calcolare le attivazioni in uscita e la velocità con cui la memoria decade nel tempo.

Le LSTM sono utilizzate soprattutto nell'elaborazione del linguaggio naturale, nel riconoscimento vocale e nella previsione delle serie temporali, dove la capacità di catturare le dipendenze a lungo raggio è vantaggiosa (Van Houdt et al., 2020).

### **3.3.19 Gated Recurrent Units (GRU)**

Le Gated Recurrent Units (GRU) sono un tipo di architettura di rete neurale ricorrente (RNN) utilizzata nel campo del deep learning. A differenza delle RNN tradizionali, le GRU utilizzano meccanismi di gating per controllare e gestire il flusso di informazioni tra le celle della rete. Questi gates sono essenzialmente reti neurali che decidono quali informazioni devono essere passate al passo successivo. Questo aiuta a mitigare il problema del gradiente (vanishing gradient problem).

Come le LSTM, le GRU sono utilizzate in compiti che coinvolgono dati sequenziali, come l'elaborazione del linguaggio naturale, il riconoscimento vocale e l'analisi delle serie temporali per esempio nel controllo di processi industriali complessi (Chung et al., 2014).

### 3.3.20 Backpropagation

La backpropagation, abbreviazione di "backward propagation of errors", propagazione a ritroso degli errori, è un algoritmo utilizzato nell'addestramento delle reti neurali artificiali. Essa funziona calcolando il gradiente della funzione di perdita (loss function) rispetto ai pesi della rete, che viene poi utilizzato per aggiornare i pesi e minimizzare la funzione di perdita. Il processo inizia con un passaggio in avanti in cui i dati di input vengono propagati attraverso la rete per generare un output. L'errore della rete viene quindi calcolato confrontando questo output con l'output desiderato. Nel passaggio all'indietro, questo errore viene retro-propagato attraverso la rete, dallo strato di output allo strato di input, regolando i pesi in modo che l'errore diminuisca. La backpropagation è un'applicazione efficiente della regola della catena (regola di derivazione che permette di calcolare la derivata della funzione composta di due funzioni derivabili), ed è un componente chiave in molti algoritmi di ottimizzazione, oltre che per scenari di supervised learning, in cui è disponibile un output noto e desiderato per ciascun valore di input (Du et al., 2023).

### 3.3.21 Convolutional Neural Network

Le reti neurali convoluzionali (CNN) sono un tipo di modello di deep learning, particolarmente adatto all'analisi dei dati visivi. Sono progettate per apprendere automaticamente e in modo adattivo gerarchie spaziali di caratteristiche dai dati di input. L'architettura di una CNN comprende tipicamente uno strato di input, strati convoluzionali, strati di pooling e strati completamente connessi. I livelli convoluzionali applicano filtri ai dati di ingresso per estrarre le caratteristiche, mentre i livelli di pooling effettuano un downsample dei dati per ridurre i calcoli. Lo strato completamente connesso effettua la previsione finale apprendendo i filtri ottimali mediante la backpropagation e gradient descent (LeCun, et al. 2015). Le CNN sono utilizzate prevalentemente in compiti di computer vision, come il riconoscimento di immagini e video, ma possono anche essere adattate per lavorare con dati audio e altri segnali e, nonostante il loro potenziale rischio di overfitting e la limitata interpretabilità, le CNN si sono dimostrate molto efficaci in compiti che richiedono l'analisi di dati visivi complessi.

### 3.3.22 AI Based Image Filtering

Le tecniche di filtraggio delle immagini basate Sull'IA sono approcci avanzati per migliorare e manipolare le immagini, In particolare viene implementato principalmente per l'arrotondamento o la sfocatura delle immagini, che riduce il rumore e rimuove i dettagli più

fini, oltre che per il rilevamento dei bordi e l'enfaticizzazione dei contorni all'interno di un'immagine.

Nel filtraggio gaussiano, una rete neurale convoluzionale (CNN) viene addestrata per apprendere i parametri ottimali di un kernel gaussiano che verrebbe applicato all'immagine di input, imparando a regolare le dimensioni e la forma del kernel per uniformare efficacemente l'immagine preservando le caratteristiche importanti.

Questa tecnica è utile nel riconoscimento degli oggetti, nella segmentazione delle immagini e nell'estrazione delle caratteristiche nella visione artificiale, dove il rilevamento dei bordi è fondamentale per comprendere la struttura e il contenuto delle immagini. I metodi di filtraggio delle immagini gaussiano e Sobel basati su machine learning sono strumenti versatili e pervasivi nell'analisi delle immagini (Adnan et al., 2021).

### **3.3.23 Image Segmentation**

La segmentazione delle immagini (Image segmentation) è una tecnica di visione artificiale che prevede la suddivisione di un'immagine in più segmenti o regioni, ciascuno corrispondente a un oggetto distinto o a una parte significativa dell'immagine. L'obiettivo è separare ed etichettare diversi oggetti o regioni all'interno di un'immagine per estrarre informazioni che poi serviranno per ulteriori analisi o categorizzazioni attraverso l'identificazione dei pixel o gruppi di pixel che condividono caratteristiche simili, come colore, intensità, trama o prossimità spaziale. Vengono utilizzati vari algoritmi e metodi, tra cui thresholding (segmentation a soglia), segmentation region-based, edge-based segmentation, e approcci basati sul deep learning in particolare con CNN.

L'immagine segmentation aiuta le macchine a identificare e comprendere l'ambiente circostante consentendo di interpretare e dare un senso a dati visivi complessi suddividendoli in segmenti significativi. Viene utilizzato sia nell'analisi esplorativa delle immagini per il rilevamento di anomalie, che nella visione artificiale in robotica e nel controllo della qualità industriale (Rezaei et al., 2021).

### **3.3.24 Object Detection**

Il rilevamento degli oggetti (Object detection), esemplificato da metodi largamente impiegati come YOLO (You Only Look Once), è un'attività di visione artificiale che prevede l'identificazione e la localizzazione di oggetti di interesse all'interno di un'immagine o di un fotogramma video.

Funziona non solo riconoscendo la presenza di oggetti ma anche specificando accuratamente la loro posizione con riquadri di delimitazione prevedendo simultaneamente sia le etichette delle classi di oggetti che le coordinate del riquadro di delimitazione per più oggetti all'interno di un singolo passaggio sull'immagine. I principali modelli per il rilevamento degli oggetti viene sostanzialmente diviso in tre fasi ovvero la selezione delle regioni informative, seguita dall'estrazione delle principali caratteristiche, fino alla classificazione (Zhao Zhong-Qiu et al., 2019).

Il rilevamento di oggetti si utilizza evidentemente in una vasta gamma di attività e settori: sistemi di sorveglianza, imaging medico e classificazione di immagini basata sui contenuti, gestione dell'inventario, monitoraggio dei clienti, e naturalmente nella robotica e nei sistemi di produzione con processi in linea. In questo ultimo ambito i modelli di object detection, in particolare quelli di tipo YOLO, hanno fatto avanzare rapidamente il campo della visione artificiale aprendo la strada a nuove applicazioni nell'automazione basata su IA (Upulie et al., 2021).

### **3.3.25 Clustering**

Il clustering nell'Intelligenza Artificiale è un metodo di analisi dei dati che consiste nel raggruppare insieme oggetti simili in base alle loro caratteristiche. L'obiettivo principale del clustering è quello di suddividere un insieme di dati in gruppi omogenei, in modo che gli oggetti all'interno dello stesso gruppo siano più simili tra loro rispetto agli oggetti appartenenti a gruppi diversi, senza la necessità di etichettare i dati in modo esplicito, ma piuttosto utilizzando solo le caratteristiche intrinseche dei dati stessi (Janil Anil et al., 1999).

Ci sono diversi algoritmi di clustering utilizzati in pratica, ognuno dei quali ha le proprie caratteristiche e applicazioni. Alcuni dei più comuni includono il k-means clustering, il clustering gerarchico, il DBSCAN (Density-Based Spatial Clustering of Applications with Noise) e molti altri.

Il clustering viene utilizzato in una vasta gamma di applicazioni, come analisi dei dati, segmentazione del mercato, riconoscimento di pattern, analisi delle immagini e altro ancora. È una tecnica potente per esplorare e comprendere la struttura dei dati, identificare tendenze nascoste e trovare relazioni interessanti tra gli oggetti nell'insieme di dati.

### 3.3.26 Classification

La classificazione nell'ambito dell'Intelligenza Artificiale è un processo che consiste nel categorizzare o assegnare un'etichetta a un insieme di dati in base alle loro caratteristiche o attributi. L'obiettivo è quello di creare un modello in grado di predire correttamente l'etichetta o la classe di nuovi dati non ancora visti, basandosi sulle informazioni apprese dai dati di addestramento.

Il processo di classificazione coinvolge due fasi principali: l'addestramento del modello e la sua valutazione. Durante la fase di addestramento, il modello viene esposto a un insieme di dati di addestramento, ognuno dei quali è associato a un'etichetta o a una classe nota. Il modello impara a riconoscere i pattern nei dati e ad associarli alle etichette corrette attraverso l'uso di algoritmi di apprendimento automatico.

Una volta addestrato, il modello viene valutato utilizzando un insieme di dati di test separato, che non sono stati utilizzati durante l'addestramento generando predizioni per questi dati che vengono confrontati con le etichette di test note per valutare le prestazioni del modello (Ceri Stefano, 2013).

Ci sono diversi algoritmi di classificazione utilizzati nell'IA, tra cui il classificatore bayesiano, l'albero decisionale, la regressione logistica, le support vector machine (SVM) e le reti neurali, solo per citarne alcuni. Ogni algoritmo ha le sue caratteristiche, punti di forza e limitazioni, e può essere applicato a diversi tipi di dati e problemi di classificazione.

La classificazione è ampiamente utilizzata in una vasta gamma di applicazioni, come il riconoscimento di immagini, il filtraggio della posta indesiderata, la diagnosi medica, l'analisi del sentiment nei social media e molto altro ancora. Grazie alla sua versatilità e alle sue capacità predictive, la classificazione è una tecnica fondamentale nell'ambito dell'Intelligenza Artificiale.

### 3.3.27 Regressione Lineare

La regressione lineare nell'ambito dell'Intelligenza Artificiale è un metodo utilizzato per modellare la relazione tra una variabile dipendente (o target) e una o più variabili indipendenti (o features) attraverso una relazione lineare approssimativa.

Il processo di regressione lineare coinvolge il calcolo di una retta (in un caso bidimensionale) o un iperpiano (in un caso multidimensionale) che meglio si adatta ai dati disponibili. Questo

viene fatto cercando di minimizzare la somma dei quadrati delle differenze tra i valori osservati della variabile dipendente e i valori predetti dalla retta o dall'iperpiano.

Per trovare i parametri ottimali per la retta o l'iperpiano, tipicamente si utilizza l'algoritmo della discesa del gradiente o il metodo dei minimi quadrati. L'algoritmo cerca di ottimizzare i pesi associati a ciascuna feature in modo che la differenza tra i valori predetti e quelli osservati sia ridotta al minimo possibile.

Una volta addestrato il modello di regressione lineare, è possibile utilizzarlo per fare previsioni su nuovi dati, utilizzando le relazioni lineari apprese durante la fase di addestramento.

La regressione lineare è comunemente utilizzata in molte applicazioni di Intelligenza Artificiale, come l'analisi dei dati, la previsione finanziaria, la modellazione economica, la previsione delle vendite e altro ancora. Anche se è un modello relativamente semplice, può essere molto efficace quando la relazione tra le variabili è approssimativamente lineare e quando si desidera interpretare i coefficienti del modello in modo semplice e intuitivo (Aldridge Irene, 2023).

### **3.3.28 Regressione Logistica**

La regressione logistica è una tecnica di modellazione statistica utilizzata nell'ambito dell'Intelligenza Artificiale per la classificazione di dati binari o multiclassi. A differenza della regressione lineare, che viene utilizzata per variabili dipendenti continue, la regressione logistica è specificamente progettata per prevedere la probabilità che un'istanza di dati appartenga a una classe specifica.

Il funzionamento della regressione logistica si basa sull'utilizzo di una funzione logistica, nota anche come funzione sigmoide, per trasformare le previsioni lineari in probabilità comprese tra 0 e 1. Questa funzione comprime l'output del modello in un intervallo che può essere interpretato come probabilità, dove valori più vicini a 1 indicano una maggiore certezza nella classe positiva e valori più vicini a 0 indicano una maggiore certezza nella classe negativa.

Durante il processo di addestramento, il modello di regressione logistica ottimizza i pesi associati alle variabili di input, utilizzando tecniche come la massima verosimiglianza o la discesa del gradiente. Questo viene fatto per massimizzare la probabilità che il modello assegni correttamente le etichette di classe ai dati di addestramento.

Una volta addestrato, il modello di regressione logistica può essere utilizzato per fare previsioni su nuovi dati, fornendo le probabilità predette per ciascuna classe e classificando l'istanza di

dati in base alla probabilità più alta risultando ampiamente utilizzata in una vasta gamma di applicazioni di intelligenza artificiale, come il riconoscimento di pattern, l'analisi del rischio, la diagnosi medica, la classificazione del testo e altro ancora. Grazie alla sua semplicità e interpretabilità, la regressione logistica è un modello popolare e versatile per la classificazione dei dati (John Wiley & Sons, 2013).

### **3.3.29 Macchina a Vettori di Supporto**

Il Support Vector Machine (macchine vettoriali di supporto, SVM) rappresenta un modello di apprendimento supervisionato con algoritmi di apprendimento associati utilizzati per l'analisi di classificazione e regressione.

Viene utilizzato per varie applicazioni pratiche grazie alla loro efficacia in spazi ad alta dimensionalità e alla loro versatilità nel modellare complesse relazioni non lineari (Joachims, T., 1998). Sono comunemente applicate in campi come la bioinformatica per la classificazione dei geni, la classificazione delle immagini, il riconoscimento dei caratteri scritti a mano e la categorizzazione dei testi. Uno dei loro vantaggi principali è la capacità di gestire l'overfitting, soprattutto quando il numero di caratteristiche è maggiore del numero di campioni e, grazie alla loro capacità di modellare complessi confini decisionali non lineari con processi di addestramento relativamente semplici e computazionalmente efficienti, ne ha favorito l'utilizzo sia nella ricerca accademica che nelle applicazioni industriali.

### **3.3.30 Analisi delle Componenti Principali**

La Principal Component Analysis (PCA), Analisi delle componenti Principali, è una tecnica di riduzione della dimensionalità utilizzata nell'ambito dell'Intelligenza Artificiale per semplificare un insieme complesso di dati mantenendo le sue caratteristiche più importanti o informative, accelerando i tempi di calcolo e ridurre il rischio di overfitting nei modelli di apprendimento automatico .

L'obiettivo della PCA è quello di proiettare i dati originali in un nuovo sistema di coordinate in cui le variabili (o feature) sono disposte in modo che la maggior parte della varianza dei dati sia spiegata dai primi componenti principali. Questi componenti principali sono combinazioni lineari delle variabili originali, e ciascuno cattura una quantità crescente di varianza nei dati, garantendo che le informazioni più rilevanti siano preservate.

La PCA è ampiamente utilizzata in una varietà di applicazioni, come l'analisi delle immagini, il riconoscimento dei pattern, la compressione dei dati, la visualizzazione dei dati e altro ancora. Grazie alla sua capacità di ridurre la dimensionalità dei dati mantenendo le informazioni più importanti, la PCA è uno strumento prezioso per l'analisi e la comprensione dei dati in molte discipline scientifiche e di ingegneria.

### **3.3.31 Visione Artificiale**

La computer vision (CV) è un campo dell'intelligenza artificiale che consente a computer e sistemi di ricavare informazioni significative da immagini digitali, video e altri input visivi e di agire in base a tali informazioni. La sfida principale della computer vision è quella di elaborare e interpretare il mondo visivo: ciò comporta il riconoscimento di modelli, l'individuazione di oggetti, la comprensione di scene e persino la previsione di proprietà dell'ambiente (come la profondità o il movimento). Il processo inizia con l'acquisizione dei dati visivi, spesso attraverso telecamere o sensori, seguita da varie fasi di analisi come la segmentazione delle immagini, il rilevamento degli oggetti e il riconoscimento delle immagini. La computer vision si basa prevalentemente sul machine learning, in particolare il deep learning con le reti neurali, che vengono addestrate su grandi insiemi di immagini per migliorarne la capacità di riconoscere pattern (schemi) e prendere decisioni basate su input visivi (Xu Shuyuan, 2021).

Le applicazioni della computer vision si stanno estendendo rapidamente grazie ai progressi dell'IA e alla crescente potenza di calcolo, nel settore industriale, ad esempio, viene utilizzata per l'ispezione della qualità e il rilevamento dei difetti nei processi in linea. Nel campo della sanità, la computer vision assiste nelle procedure diagnostiche, nell'analisi delle radiografie o delle immagini di risonanza magnetica alla ricerca di anomalie. È fondamentale per i veicoli autonomi, che hanno bisogno di "vedere" e navigare nell'ambiente circostante. Nella vendita al dettaglio, la visione computerizzata è stata sperimentata per l'acquisto senza casse, tracciando via via gli articoli che i clienti aggiungono al carrello. La computer vision svolge un ruolo importante nei sistemi di sicurezza (sia safety che security), nelle applicazioni di riconoscimento facciale e nell'intrattenimento, dove viene utilizzata per migliorare gli effetti visivi di film e videogiochi. La CV è in continua evoluzione e le prospettive sono di una rapida crescita delle capacità (Szegedy, C., et al., 2016).

### **3.3.32 Pattern Recognition**

Il pattern recognition, o riconoscimento dei pattern, nell'ambito dell'Intelligenza Artificiale, si riferisce alla capacità di un sistema di identificare e interpretare modelli, relazioni o strutture significative all'interno di un insieme di dati. Il processo coinvolge l'identificazione e l'analisi di regolarità o strutture ricorrenti nei dati al fine di estrarre informazioni utili o prendere decisioni.

Il funzionamento del pattern recognition inizia con la raccolta di dati, che possono essere immagini, suoni, testi o altre forme di dati. Successivamente, vengono estratti e selezionati gli attributi o le caratteristiche rilevanti dai dati, che sono utilizzati per rappresentare ogni istanza di dati in modo appropriato per l'analisi. Questi attributi possono essere, ad esempio, colori e texture per immagini, frequenze per segnali audio, o parole chiave per documenti di testo.

Una volta che i dati sono stati preparati, vengono applicati algoritmi di pattern recognition per identificare e interpretare i modelli nei dati. Questi algoritmi possono includere tecniche di apprendimento supervisionato, come le reti neurali, i support vector machine o i classificatori bayesiani, che richiedono un insieme di dati di addestramento etichettati per apprendere i modelli. Altri approcci possono essere basati su tecniche di clustering per identificare pattern non etichettati o semisupervisionati che combinano entrambi gli approcci.

Una volta addestrati, i modelli di pattern recognition possono essere utilizzati per fare predizioni o classificare nuovi dati non ancora visti, utilizzando i modelli appresi durante la fase di addestramento. La Computer Vision risulta utile per molteplici compiti quali il data mining, analisi di immagini, classificazione di documenti ed altro (Jain Anil et al., 1999).

### **3.3.33 Knowledge Discovery**

La knowledge discovery nell'Intelligenza Artificiale, spesso indicata come KDD (Knowledge Discovery in Databases), si riferisce al processo di estrazione di conoscenza utile, interessante e precedentemente sconosciuta da grandi volumi di dati. Questo processo comprende diverse fasi, tra cui la selezione dei dati, la pulizia dei dati, la trasformazione dei dati, l'estrazione dei modelli e la valutazione dei risultati.

La knowledge discovery inizia con la raccolta di dati da varie fonti, come database, file di testo, dati sensoriali o dati provenienti da internet. Successivamente, i dati vengono elaborati per identificare eventuali errori, mancanze o incongruenze attraverso processi di pulizia e pre-

elaborazione dei dati. Questo passaggio è fondamentale per garantire che i dati siano affidabili e adatti all'analisi.

Una volta che i dati sono stati preparati, vengono applicati algoritmi e tecniche di data mining per estrarre modelli, pattern o relazioni nascoste nei dati. Questi modelli possono includere regole di associazione, alberi decisionali, clustering, regressione, classificazione e molti altri. L'obiettivo è quello di scoprire nuove informazioni o tendenze nei dati che possono essere utilizzate per prendere decisioni informate o per ottenere una migliore comprensione del fenomeno studiato.

Infine, i risultati dell'analisi vengono valutati e interpretati per determinare la loro rilevanza e utilità. Questo processo può coinvolgere la verifica dei modelli scoperti, la validazione incrociata, l'interpretazione dei risultati e la presentazione delle scoperte agli stakeholder (Fayyad Usama et al., 1996).

### **3.3.34 Elaborazione del Linguaggio Naturale**

L'elaborazione del linguaggio naturale (NLP) è un campo che si colloca all'intersezione tra informatica, intelligenza artificiale e linguistica e si concentra sull'interazione tra computer e linguaggio umano (Billis Manaris, 1998). L'obiettivo dell'NLP è quello di consentire ai computer di comprendere, interpretare e rispondere al linguaggio umano in modo valido attraverso lo sviluppo di algoritmi e sistemi in grado di elaborare, analizzare e generare il linguaggio umano nelle sue varie forme, tra cui il linguaggio parlato, scritto e dei segni. Questi compiti richiedono al computer di comprendere le complessità del linguaggio umano, tra cui la sintassi, la semantica, la pragmatica e le sfumature contestuali che ne derivano. I moderni sistemi NLP si affidano soprattutto all'apprendimento automatico, in particolare alle tecniche di deep learning, per imparare da grandi corpora linguistici e migliorare nel tempo le loro capacità di elaborazione del linguaggio.

Gli assistenti virtuali di uso comune come Siri e Alexa utilizzano il NLP per comprendere e rispondere ai comandi vocali, mentre i filtri per le e-mail la utilizzano per classificare le e-mail in categorie di spam e non spam. Nel servizio clienti, i chatbot utilizzano il NLP per fornire risposte automatiche alle richieste dei clienti. Inoltre, l'NLP svolge un ruolo cruciale nella business intelligence, estraendo intuizioni e sentimenti dai dati dei social media, dalle recensioni e dai feedback dei clienti, ai servizi di traduzione automatica come Google Translate. I progressi del NLP sono stati notevolmente favoriti dallo sviluppo di librerie e architetture

Transformer all'avanguardia e modelli preaddestrati, rendendo i recenti progressi largamente accessibili (Wolf et al., 2020).

### **3.3.35 Tokenizzazione**

La tokenizzazione (tokenization) è una tecnica fondamentale di elaborazione del linguaggio naturale (NLP) utilizzata nell'IA soprattutto nell'analisi del testo per scomporre un testo in unità più piccole, solitamente parole o unità di sottoparole denominate token. Il processo prevede la suddivisione di una sequenza continua di caratteri, come una frase o un documento, in unità o token discreti. La tokenizzazione ha diversi scopi, tra cui la preelaborazione del testo, l'estrazione delle funzionalità e la modellazione del linguaggio naturale (Thawani et al., 2023).

La tokenizzazione gioca un ruolo cruciale nella maggior parte delle attività di NLP (classificazione del testo, sentiment analysis, traduzione automatica, riconoscimento di entità denominate).

### **3.3.36 Named Entity Recognition**

Le entità denominate sono parole o frasi che si riferiscono a entità specifiche, come nomi di persone, organizzazioni, luoghi, date e altro. La tecnica Named Entity Recognition (riconoscimento di entità denominate, NER) è una tecnica di elaborazione del linguaggio naturale che si concentra sull'identificazione e la categorizzazione di entità denominate all'interno di dati di testo (Zhang Li et al., 2004). I sistemi NER funzionano analizzando il testo di input ed etichettando le parole o le frasi corrispondenti alle entità denominate con categorie predefinite come "persona", "organizzazione", "ubicazione", "data" ecc.

Questo processo spesso comporta l'utilizzo di modelli di machine learning, in particolare modelli di etichettatura di sequenze (sequence labeling) o approcci basati sul deep learning (LSTM bidirezionali) per la post-elaborazione.

L'approccio NER trova applicazione nell'information retrieval, nei sistemi di risposta automatica alle domande e chatbot, e nell'analisi del sentiment, poiché consente ai sistemi di estrarre e comprendere informazioni importanti da dati di testo non strutturati, semplificando l'organizzazione e l'elaborazione di grandi volumi di informazioni testuali (Yadav et al., 2018).

### **3.3.37 Part-Of-Speech tagging**

Part-of-Speech (POS) tagging (etichettatura della parte del discorso, POS) è un'attività di elaborazione del linguaggio naturale (NLP) che consiste nell'assegnazione di etichette o tag grammaticali a ciascuna parola in un testo in base al suo ruolo sintattico all'interno di una frase

(Martinez Angel, 2012). Questi tag rappresentano la parte del discorso a cui appartiene una parola (sostantivi, verbi, aggettivi, avverbi, pronomi, ecc.). Il POS tagging viene in genere eseguito utilizzando modelli specializzati di machine learning (Hidden Markov Models, Conditional Random Fields) o approcci basati sul deep learning come le RNN e modelli di Transformers.

Il POS tagging svolge un ruolo cruciale in molte applicazioni del NLP perché aiuta a chiarire le ambiguità dei significati delle parole, ad analizzare le frasi e ad estrarre caratteristiche significative dal testo (Chiche et al., 2022).

### **3.3.38 Word Embeddings**

Le tecniche di Word embeddings (incorporamenti di parole), per esempio Word2Vec e GloVe, sono tecniche utilizzate nella NLP per rappresentare le parole come rappresentazioni vettoriali continue in uno spazio ad alta dimensionalità. Questi embeddings catturano le relazioni semantiche e le informazioni contestuali tra le parole, consentendo alle macchine di comprendere meglio il significato delle parole in base al contesto circostante in grandi corpora testuali. Word2Vec, ad esempio, utilizza le reti neurali per apprendere le rappresentazioni vettoriali delle parole prevedendo la probabilità che le parole appaiano insieme nelle frasi. GloVe, invece, crea vettori di parole sfruttando le statistiche globali sulla co-occorrenza.

Le tecniche di word embeddings si utilizzano nel NLP perché consentono ai modelli di generalizzare meglio, gestire sinonimi e contrari e catturare sfumature semantiche, migliorando così le prestazioni fornendo una rappresentazione delle parole più significativa e contestualizzata (Gutiérrez et al. 2019).

### **3.3.39 Bagging**

Il bagging (Bootstrap Aggregating) nell'Intelligenza Artificiale è una tecnica di ensemble learning che mira a migliorare la stabilità e le prestazioni dei modelli di apprendimento automatico, riducendo la varianza e il rischio di overfitting (Manesh Batta, 2020). Il concetto che sta alla base di questa tecnica sta nella creazione di sottoinsiemi di dati di addestramento, ognuno dei quali contiene un campione casuale con sostituzione dai dati originali.

Una volta addestrati tutti i modelli nell'insieme, le previsioni di ciascun modello vengono combinate per ottenere un risultato finale, che può essere ottenuto tramite votazione (nel caso della classificazione) o media (nel caso della regressione) delle previsioni dei singoli modelli.

L'idea chiave è che combinando le previsioni di più modelli, l'ensemble sarà in grado di generalizzare meglio sui dati di test, migliorando le prestazioni complessive del modello.

### **3.3.40 Boosting**

Il boosting è una tecnica di ensemble learning che, nell'ambito dell'Intelligenza Artificiale, mira a migliorare le prestazioni predittive di un modello combinando più modelli di base in modo sequenziale. In questo approccio, ogni nuovo modello è costruito per correggere gli errori dei modelli precedenti, focalizzandosi sui casi di addestramento che sono stati classificati erroneamente.

Il processo di boosting inizia addestrando un primo modello di base utilizzando l'intero set di addestramento. Successivamente, si assegna un peso maggiore agli esempi di addestramento classificati erroneamente da questo modello iniziale, in modo che i successivi modelli di base si concentrino sui casi più difficili. Ogni modello successivo è quindi addestrato su un set di dati ponderato, dove il peso attribuito ai casi di addestramento correttamente classificati è ridotto e il peso dei casi classificati erroneamente è aumentato.

Nel complesso, l'output finale del modello ensemble è ottenuto attraverso la combinazione ponderata delle previsioni di tutti i modelli di base mediante un processo iterativo che continua fino a quando il modello ensemble raggiunge un livello desiderato di accuratezza o finché non viene soddisfatto un criterio di arresto predefinito (De Marco Andrea, 2019).

Il boosting è particolarmente efficace nell'affrontare problemi di classificazione complessi e nella riduzione dell'errore di generalizzazione, contribuendo a produrre modelli di machine learning più robusti e performanti. Alcuni degli algoritmi di boosting più noti includono AdaBoost, Gradient Boosting e XGBoost.

### 3.4 Tendenza all'integrazione di tecniche ed algoritmi

La tendenza dell'IA a combinare più tecniche e algoritmi è sempre più evidente in vari campi, con l'obiettivo di migliorare l'efficacia e la stabilità. In uno studio (Epstein, Z., et al. 2021) hanno osservato che sia l'etichettatura che le spiegazioni del sistema di etichettatura hanno aumentato significativamente il discernimento nella condivisione delle intenzioni sulle piattaforme di social media. Questo approccio illustra come la combinazione di diverse tecniche di intelligenza artificiale possa migliorare l'affidabilità e l'efficacia della diffusione delle informazioni e dell'interazione con l'utente.

Nel settore sanitario, l'integrazione di più algoritmi di intelligenza artificiale si è dimostrata promettente nel migliorare l'accuratezza diagnostica. Olayah F., et al. (2023) hanno sviluppato sistemi ibridi che combinano modelli di CNN, reti ANN e tecniche di Random Forest per diagnosticare e classificare diversi tipi di lesioni cutanee sulla base di immagini dermatoscopiche. I modelli ibridi hanno raggiunto un'impressionante AUC<sup>8</sup> del 94,41%, sensibilità dell'88,90%, accuratezza del 96,10%, precisione dell'88,69% e specificità del 99,44%. Ciò dimostra il potenziale della combinazione di varie tecniche di intelligenza artificiale per ottenere un'elevata precisione nella diagnostica medica.

Allo stesso modo, in altre applicazioni come i sistemi energetici e il processo decisionale finanziario, la tendenza all'integrazione cresce. Per esempio, le metodologie ibride che utilizzano metodi di ottimizzazione avanzati nei sistemi energetici hanno mostrato una migliore affidabilità e capacità di ricerca. In finanza, i metodi di ensemble spiegabili che combinano più modelli base utilizzando diversi algoritmi di apprendimento automatico hanno migliorato la previsione del rischio di credito pur mantenendo l'interpretabilità. Questi esempi evidenziano collettivamente la tendenza dell'intelligenza artificiale a sfruttare i punti di forza di diverse tecniche e algoritmi, puntando a prestazioni, affidabilità e applicabilità migliorate in diversi domini.

Nel settore manifatturiero, la tendenza a combinare più tecniche e algoritmi di intelligenza artificiale (AI) sta diventando sempre più evidente, guidata dalla necessità di migliorare l'efficienza, il rapporto costo-efficacia e il controllo di qualità. Un esempio è l'uso di algoritmi

---

<sup>8</sup> AUC sta per 'Area under the ROC Curve', dove ROC è la curva caratteristica di performance di classificazione Receiver Operating Characteristic curve. L'AUC fornisce una misura aggregata delle prestazioni su tutte le possibili soglie di classificazione. Un modo di interpretare l'AUC è la probabilità che il modello classifichi un esempio positivo casuale più in alto rispetto a un esempio negativo casuale.

genetici per l'ottimizzazione nella produzione personalizzata di massa. Alfayoumi et al. (2023) hanno proposto una soluzione di IA che riduce al minimo tempi e costi utilizzando una funzione multi-obiettivo per ottimizzare entrambi contemporaneamente, dimostrando che questo approccio supera i metodi di ottimizzazione tradizionali mostrando come l'integrazione di diverse strategie di intelligenza artificiale possa portare a processi di produzione più efficienti ed economici.

La tendenza all'integrazione di tecniche IA è forte anche nella produzione intelligente, in particolare nei sistemi mecatronici. Il lavoro di Lila (2021) ha esplorato come le tecniche di IA integrate non solo automatizzano i processi ma apportano anche un livello di intelligenza e adattabilità ai sistemi di produzione.

La combinazione dell'apprendimento automatico con tecniche di ottimizzazione come i dispositivi integrati di Particle Swarm Optimization (PSO, un tipo di intelligenza degli sciame) e Internet of Things (IoT) sta migliorando il processo decisionale nei sistemi cyber-fisici all'interno della produzione (Gad, A., 2022). Nethani et al., (2023) hanno suggerito una nuova strategia che migliora la precisione e l'efficacia del processo decisionale analizzando i dati in tempo reale utilizzando algoritmi di apprendimento automatico e riducendo la complessità computazionale attraverso l'ottimizzazione PSO. Questo approccio poliedrico mostra come l'IA si sta evolvendo nel settore manifatturiero, con particolare attenzione all'integrazione dell'analisi dei dati in tempo reale nelle capacità decisionali.

Nell'ambito del food manufacturing, in cui la sicurezza e qualità dei controlli sui processi risulta fondamentale, vengono applicate tecniche di Machine Learning e Deep Learning in concomitanza con la visione artificiale per graduare le materie prime, individuare difetti ed impurità e controllare le fasi di trasformazione (Zhu Lili et al., 2021)

L'osservazione rilevante per questo studio è che in molti casi l'apporto delle singole tecniche o algoritmi sia difficile, incompleta o impossibile, e quindi il significato della comparazione di performance tra algoritmi viene indebolito. Resta ovviamente la possibilità del confronto tra soluzioni ingegnerizzate, anche se con notevoli difficoltà di generalizzazione.

### 3.5 Principali applicazioni funzionali dell'IA negli ambiti produttivi

Come si rileva dalla letteratura, se si restringe il campo agli ambiti produttivi (più o meno indipendentemente dal settore) le applicazioni funzionali dell'IA possono essere raggruppate in un insieme contenuto di funzioni:

- riconoscimento e generazione di linguaggio naturale;
- pattern recognition (riconoscimento di schemi) e confronto con modelli;
- scoperta di regolarità (schemi, pattern) in quantità variabili di dati, anche molto grandi, sia statici che dinamici;
- adeguamento del comportamento, e delle regole di comportamento, alle condizioni esterne;
- predizione dell'andamento di serie di dati governati da regole complesse;
- predizione del comportamento aggregato di agenti non modellabili completamente.

Queste funzioni ben si prestano ai contesti gestionali di modelli data-driven, di natura empirica, caratteristici dei sistemi di automazione industriale in costante evoluzione e in contesti a forte variabilità dei driver esterni (quantità, qualità, tipi di input) e interna (capacità, efficienza).

Calate nella realtà operativa dell'ambiente produttivo queste funzioni trovano applicazione

- nell'interazione uomo macchina;
- nella progettazione, nell'ottimizzazione e controllo di processo (energia, velocità, quantità, qualità); (sia off-line che on-line);
- nella sicurezza (safety, security, data protection);
- nel controllo di qualità (compliance, difettosità, ranking);
- nell'automazione dei processi make a tutti i livelli;
- nell'interpretazione di dati per la previsione e ottimizzazione (di processo, logistica, di mercato).

Inoltre questi ambiti vengono collegati dalle applicazioni IA che per loro natura sono tanto più efficaci quanto più accesso hanno al contesto, per esempio dati sulle intenzioni, esiti, e risposta del cliente (Plathottam et al., 2023).

# Capitolo 4: I processi di trasformazione alimentare

## 4.1 Definizione e tassonomia dei processi di trasformazione alimentare

Per definire l'estensione del focus primario della tesi siamo partiti dalla definizione del settore industriale di riferimento la produzione di prodotti alimentari, che comprende un gran numero di attività: dalla lavorazione della carne alla produzione di latticini, dalla produzione di bevande a base di frutta e verdura ai prodotti da forno.

I trattamenti e lavorazioni nella produzione alimentare sono principalmente finalizzati a

- convertire in prodotti commestibili prodotti che altrimenti non lo sarebbero;
- conservare i prodotti;
- garantire livelli di qualità (di conformità obbligatoria e volontari);
- ampliare la disponibilità e accessibilità dei prodotti;
- fornire varietà e scelta;
- migliorare la convenienza economica complessiva;
- aggiungere valore ai prodotti (riconducibile all'aumento della disponibilità a pagare).

I trattamenti e le lavorazioni sono *de facto* suddivisi in

- lavorazione primaria: conversione delle materie prime in prodotti alimentari, per esempio macinazione, refrigerazione, essiccazione, ecc.
- lavorazione secondaria: per modificare le proprietà degli ingredienti, per esempio carni lavorate, prodotti lattiero-caseari, bevande e bevande alcoliche
- lavorazione terziaria: confezionamento di alimenti, cottura, congelamento, disidratazione, inscatolamento, imbottigliamento.

È talvolta utilizzata anche una diversa classificazione (Fellows, P., 2021) che si limita a distinguere tra trasformazioni primarie (*grossolane, rough*) e secondarie (*profonde, deep*).

Il primo livello di lavorazione degli alimenti consiste nel preparare le materie prime per il consumo o per la successiva lavorazione. Questa fase, la fase di lavorazione primaria, comporta azioni di base come la pulizia, la selezione e la classificazione. Ne sono esempi:

- la selezione delle materie prime e la loro separazione per dimensione o condizione (p. es. frutta, uova);
- la macinazione dei cereali in farina (p. es. grano, mais o riso).
- la decorticazione e la sgusciatura di noci e semi (p. es. mandorle e semi di girasole).
- l'estrazione di oli da frutta e semi (p. es. olio di oliva o di girasole).
- la macellazione di animali da carne e la preparazione di tagli (p. es. manzo, maiale o pollame).

In questa fase, l'attenzione si concentra sulla trasformazione delle materie prime in forme che possano essere facilmente utilizzate nel successivo livello di lavorazione o confezionamento.

La lavorazione secondaria riceve in ingresso gli alimenti dopo la prima lavorazione e li trasforma in qualcosa di diverso. Ne sono esempi

- la preparazione di pane e dolci a partire dalla farina e dai lieviti;
- la fermentazione degli alimenti (p. es. yogurt, crauti, bevande alcoliche);
- la modellazione e insaporimento delle carni (p. es. salami, wurstel, carni affumicate).
- la miscelazione e modellazione di prodotti dolciari (p. es. cioccolatini, merendine, caramelle).

La lavorazione secondaria è essenziale per ampliare la gamma di prodotti alimentari con consistenze, sapori e aspetti diversi, ed è il cuore della produzione degli alimenti *industriali*.

L'ultimo livello di lavorazione, ovvero in quelle definite terziarie degli alimenti aggiunge valore *non dipendente dal prodotto alimentare per sé*. Riguarda soprattutto il confezionamento, la marchiatura e l'etichettatura dei prodotti alimentari per renderli pronti per la vendita al dettaglio, e talvolta per preservarne la qualità e il gusto. Questa fase è anche fondamentale per fornire informazioni essenziali lungo la catena logistica e per fornire ai consumatori finali informazioni come gli ingredienti, il contenuto nutrizionale, la scadenza. Inoltre la fase terziaria è strettamente collegata al marketing e alla progettazione per rendere i prodotti attraenti. Sono esempi di alimenti trasformati per via terziaria:

- i piatti surgelati pronti per l'alimentazione o per la cottura (p. es. pizza, lasagne o soffritti);
- prodotti in scatola (p. es. zuppe, verdure o frutta);

- kit preconfezionati per la cucina.

Questa segmentazione dei processi alimentari ha anche dato origine a una classificazione in funzione del livello di processing dei prodotti, NOVA.

Il sistema NOVA è stato proposto per l'accresciuta necessità di categorizzare anche normativamente gli alimenti in base al grado, tipo e finalità di lavorazione applicata (alimenti non lavorati o minimamente lavorati, lavorati e ultra-lavorati, e ingredienti culinari), oltre che di nutrienti.

La classificazione NOVA porta con sé implicitamente un legame tra grado di trasformazione e salubrità, e influenza le linee guida delle agenzie internazionali e nazionali che si occupano di alimentazione e salute (Gonzalez Fischer, C., et al., 2016).

Considerando lo schema NOVA, la progettazione del prodotto acquisisce un rilievo primario, su cui l'IA sta avendo un impatto sempre maggiore, per esempio per ottenere lo stesso esito organolettico riducendo od eliminando delle lavorazioni, o sostituendo ingredienti additivi sospettati di essere dannosi (Doherty, A., et al., 2021).

## 4.2 Sistemi di classificazione

I sistemi di classificazione riflettono questa situazione e sono articolati e complessi, anche per le differenti esigenze e modalità statistiche a seconda della scala (nazionale, europea, mondiale) e delle culture gestionali continentali e nazionali (vedi Figura 5).

Le fonti statistiche istituzionali sulle attività economiche sono sembrate le più idonee a offrire un panorama complessivo nell'ambito applicativo della tesi:

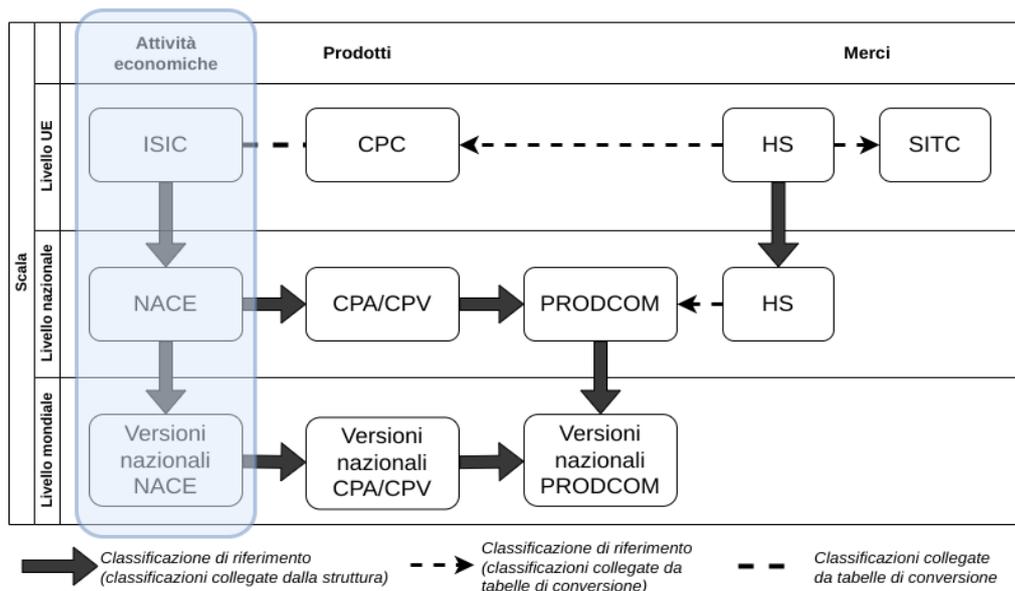


Figura 5: Fig. 6: Sistemi ufficiali di classificazione delle attività economiche; evidenziati quelli utilizzati. Fonte: "Nace Rev.2 Introductory Guidelines – En.Pdf", <https://circabc.europa.eu/>

Infatti per il nostro scopo abbiamo ritenuto che fosse meglio far riferimento alla linea delle attività economiche che raggruppano meglio i processi produttivi, perché le classificazioni dei prodotti o merci non offrirebbero un quadro utile alla definizione dei processi per la trasformazione alimentare (come osservato sopra in relazione alla codifica NOVA).

Ricaveremo i nessi fra tecniche di IA, lavorazioni e prodotto direttamente dai casi applicativi della letteratura esaminata. Ci siamo limitati quindi alla classificazione internazionale ISIC ed europea delle attività economiche NACE e alla versione nazionale italiana, l'ATECO.

Con una tavola sinottica sono stati comparati i sistemi di classificazione ricavando un set comune di attività alle quali associare schemi comuni di lavorazione.

Il set presente è riportato in Tabella 2 ed evidenzia i principali settori di lavorazione alimentare, delimitando l'ambito alle fasi di trasformazione industriale food&beverage:

ATECO	Descrizione	ATECO	Descrizione
10	Industrie alimentari	10.71.2	Produzione di pasticceria fresca
10.1	Lavorazione e conservazione di carne e produzione di prodotti a base di carne	10.72	Produzione di fette biscottate e di biscotti; produzione di prodotti di pasticceria conservati
10.11	Lavorazione e conservazione di carne (escluso volatili)	10.73	Produzione di paste alimentari, di cuscus e di prodotti farinacei simili
10.12	Lavorazione e conservazione di carne di volatili	10.81	Produzione di zucchero
10.13	Produzione di prodotti a base di carne (inclusa la carne di volatili)	10.82	Produzione di cacao, cioccolato, caramelle e confetterie
10.2	Lavorazione e conservazione di pesce, crostacei e molluschi	10.83	Lavorazione del tè e del caffè
10.3	Lavorazione e conservazione di frutta e ortaggi	10.84	Produzione di condimenti e spezie
10.31	Lavorazione e conservazione delle patate	10.85	Produzione di pasti e piatti preparati
10.32	Produzione di succhi di frutta e di ortaggi	10.85.0	Produzione di pasti e piatti pronti (preparati, conditi, cucinati e confezionati)
10.39	Altra lavorazione e conservazione di frutta e di ortaggi	10.86	Produzione di preparati omogeneizzati e di alimenti dietetici
10.39.0	Lavorazione e conservazione di frutta e di ortaggi (esclusi i succhi di frutta e di ortaggi)	10.89	Produzione di prodotti alimentari nca
10.4	Produzione di oli e grassi vegetali e animali	10.89.01	Produzione di estratti e succhi di carne
10.41	Produzione di oli e grassi	10.91	Produzione di mangimi per l'alimentazione degli animali da allevamento
10.41.1	Produzione di olio di oliva da olive prevalentemente non di produzione propria	10.92	Produzione di prodotti per l'alimentazione degli animali da compagnia
10.41.2	Produzione di olio raffinato o grezzo da semi oleosi o frutti oleosi prevalentemente non di produzione propria	11.01	Distillazione, rettifica e miscelatura degli alcolici
10.42	Produzione di margarina e di grassi commestibili simili	11.02.1	Produzione di vini da tavola e v.q.p.r.d.
10.51	Industria lattiero-casearia, trattamento igienico, conservazione del latte	11.02.2	Produzione di vino spumante e altri vini speciali
10.51.1	Trattamento igienico del latte	11.03	Produzione di sidro e di altri vini a base di frutta
10.51.2	Produzione dei derivati del latte	11.04	Produzione di altre bevande fermentate non distillate
10.52	Produzione di gelati	11.05	Produzione di birra
10.61	Lavorazione delle granaglie	11.06	Produzione di malto
10.62	Produzione di amidi e di prodotti amidacei	11.07	Industria delle bibite analcoliche, delle acque minerali e di altre acque in bottiglia
10.71.1	Produzione di prodotti di panetteria freschi		

Tabella 2: Principali settori di lavorazione alimentare ricavati da codici ATECO per fasi alimentari, Fonte: Allegato-8-Codici-Ateco-2007.pdf



# Capitolo 5: L'IA nella filiera della produzione alimentare

## 5.1 Funzione maggiormente diffuse dell'IA nella trasformazione alimentare

Le finalità principali delle applicazioni dell'IA nel settore food&beverage manufacturing (Sadiku M., et. al, 2020) e che si ritrovano con ricorrenza all'interno delle fasi make dello screening sono:

- velocità e precisione nello smistamento di prodotti e confezioni (sorting);
- conformità alla sicurezza alimentare di prodotto (compliance) e di processo (es. miglioramento della pulizia);
- velocità e precisione nei processi di lavorazione che hanno condizioni di contesto o materia variabile;
- simulazioni e previsioni gestionali (supply chain, logistica interna ed esterna, efficienza di processo);
- elaborazione di dati, simulazioni e previsioni per il marketing e lo sviluppo di prodotto.

Calandole nella realtà operativa dell'ambito make delle imprese, queste finalità si possono ricondurre a quattro grandi categorie:

1. controllo della qualità sulle materie prime;
2. miglioramento dei processi di trasformazione;
3. controllo della qualità sul prodotto lavorato;
4. controllo della qualità nel packaging e stoccaggio.

Le specifiche attività con applicazione di IA per ognuna di queste categorie sono riportate in Tabella 3:

	Lavorazione primaria	Trasformazione secondaria	Lavorazioni terziarie
<b>Controllo della qualità della materia prima</b>	Controllo di conformità Controllo di difettosità Classificazione (ranking)		
<b>Controllo durante il processo di trasformazione</b>		Previsione per l'ottimizzazione del processo (conservabilità, requisiti di lavorazione) Ottimizzazione dinamica (energia, velocità, quantità, qualità) Controllo dinamico di processi lenti Controllo dinamico dei processi veloci: in linea Controllo di conformità in linea Controllo di difettosità in linea Classificazione (ranking) in linea	
<b>Controllo della qualità del prodotto a fine lavorazione secondaria</b>			Controllo di compliance Controllo di difettosità Classificazione (ranking, sorting per classi di qualità)
<b>Controllo su packaging e stoccaggio</b>			Controllo di compliance Controllo di difettosità Classificazione della conservabilità (ranking per scadenza, storia di conservazione, destinazione) Controllo dinamico del processo (contenuto dinamico dell'etichetta) Classificazione (ranking) e sorting

Tabella 3: Suddivisione delle fasi di controlli nella fasi

### 5.1.1 Applicazioni dell'intelligenza artificiale nel controllo qualità

Una sfida che caratterizza gli impianti di lavorazione alimentare è che le materie prime spesso non sono uniforme ed uno stabilimento si trova a smistare milioni di istanze di un particolare prodotto in base alle dimensioni, alla forma, al colore ed altro, per cercare di ottimizzare le risorse e ridurre gli sprechi.

Alla fine del XX secolo il 90% di tutto lo smistamento degli alimenti veniva fatto manualmente, ora invece una parte significativa dello smistamento viene svolta in maniera automatizzata permettendo di ridurre notevolmente i costi di manodopera, di aumentare la velocità e di migliorare i rendimenti.

Ad esempio, un'applicazione comune è l'utilizzo di algoritmi di visione artificiale per l'ispezione e il controllo della qualità dei prodotti alimentari, che vengono addestrati per rilevare difetti, contaminanti o anomalie nelle materie prime alimentari, come macchie, muffe, corpi estranei o deterioramento mediante il riconoscimento del pattern (Mery Domingo et al., 2013).

Inoltre, l'IA può essere utilizzata per analizzare dati provenienti da sensori e strumenti di monitoraggio durante la produzione alimentare, al fine di identificare tendenze o deviazioni che potrebbero indicare problemi di qualità nelle materie prime. Analisi dei dati di temperatura, umidità, pH o composizione chimica può essere utilizzata per rilevare anomalie che potrebbero indicare la presenza di contaminanti o deterioramento nelle materie prime alimentari.

I sistemi di apprendimento automatico possono essere utilizzati per sviluppare modelli predittivi per prevedere la qualità delle materie prime alimentari in base a vari fattori, come la provenienza, le condizioni di trasporto, la stagionalità o la manipolazione durante la catena di approvvigionamento. Questi modelli possono essere utilizzati per prendere decisioni informate sulle operazioni di produzione e sulla gestione delle scorte, avviando azioni correttive o di allarme in tempo reale evitando un problematico collo di bottiglia nella produzione.

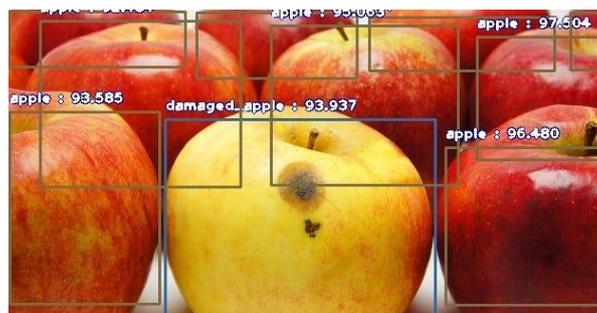


Figura 6: Controllo qualità su materie prime (Shutterstock Images)

### 5.1.2 Applicazione dell'intelligenza artificiale nel processo di trasformazione

L'IA sta rivoluzionando la produzione di alimenti e bevande anche nella fase di lavorazione, con un ampio spettro di applicazioni che vanno dalle tecniche di elaborazione automatizzata dei piani di lavoro a sofisticati meccanismi di controllo della qualità, garantendo conformità, sicurezza ed economicità del prodotto.

L'ambizione massima nei processi produttivi è di utilizzare le tecnologie IA per ottenere modelli Digital Twin. Questi modelli combinano IA e software di analisi con dati in tempo reale provenienti dagli impianti di produzione. Questo approccio consente ai produttori di creare modelli di simulazione digitale che si aggiornano in tempo reale, contribuendo a prevenire eventi ad alto rischio e a semplificare il processo di produzione, la sicurezza e la prevedibilità operativa (Bottani et al. 2020).

Anche se fuori dal perimetro di questo studio, merita un cenno l'ambiente dei ristoranti, che sono un'estensione dell'industria alimentare e delle bevande, dove l'IA viene utilizzata nei processi tecnologici di preparazione del cibo, come le insalate. L'applicazione di tecnologie robotiche per le interazioni cliente-cliente e articolo-articolo analizza le preferenze del cliente e migliora il processo di ordinazione (Neilenko et al., 2021)

Sebbene ciò sia ancora correlato al lato dei servizi dell'industria alimentare, si vede come la tendenza dell'IA sia all'integrazione progressiva delle fasi della produzione e del servizio di alimenti e bevande.



*Figura 7: Fase lavorazione su prodotti alimentari (Shutterstock Images)*

### 5.1.3 Applicazione dell'intelligenza artificiale sul prodotto finito

La fase di controllo qualità post-elaborazione della produzione di alimenti e bevande è elettiva per le applicazioni IA: qui viene utilizzata per monitorare e controllare la qualità dei prodotti prima che vengano commercializzati e venduti, per esempio analizzandone le immagini per identificare eventuali difetti o contaminazioni visibili per la tutela del consumatore finale. Infatti, attraverso il machine learning, l'IA può essere addestrata per riconoscere diversi tipi di contaminanti o difetti specifici attraverso l'analisi dei dati che possono essere rilevati da una vasta gamma di sensori, nello spettro visivo ed elettromagnetico, chimico e in altre dimensioni. Per le sue performance, l'IA nel controllo qualità post-lavorazione contribuisce a eliminare o ridurre il collo di bottiglia dei controlli di conformità per la sicurezza alimentare e il rispetto degli standard normativi.

I controlli si possono estendere però anche lungo tutto il processo (e di solito è così nelle strutture più moderne), con monitoraggi e analisi continue dei dati di produzione per identificare potenziali problemi lungo tutta la linea, come contaminazioni e deviazioni di temperatura e altri parametri fisici che sono fattori determinanti della qualità nella produzione di alimenti e bevande. Questo approccio proattivo al controllo qualità aiuta i produttori a rispettare le regole e a ridurre il rischio di richiami, proteggendo così sia il marchio che i consumatori (Chhetri Krishna Bahadur, 2023).



*Figura 8: Controllo su prodotto finito (Shutterstock Images)*

### 5.1.4 Applicazione dell'intelligenza artificiale nel packaging

L'uso di sistemi di IA nelle fasi di confezionamento è prevalentemente mirato a monitorare, valutare e controllare la qualità, l'accuratezza e la conformità dei contenitori dei prodotti alimentari e delle loro etichette.

Sono dominanti i sistemi avanzati di ispezione visiva, che utilizzano algoritmi di apprendimento automatico, in genere basati su reti CNN, per ispezionare e analizzare gli imballaggi con precisione e ad alta velocità. Questi sistemi sono in grado di rilevare un'ampia gamma di difetti di imballaggio, etichettatura, freschezza e contaminazioni non facilmente visibili all'occhio umano (Xiaouxuan Li et al., 2023).



*Figura 9: Controllo qualità sul packaging (Shutterstock Images)*

Un'altra applicazione significativa dell'IA nel controllo della qualità degli imballaggi è l'ottimizzazione dei processi di imballaggio attraverso l'analisi predittiva. Gli algoritmi di IA possono analizzare grandi quantità di dati operativi per ottimizzare le disposizioni di grouppage (con confezionamenti variabili), ma anche prevedendo potenziali inefficienze nelle linee, identificando adeguamenti operativi che consentono la manutenzione preventiva o il riadeguamento dei piani di lavoro. Questa capacità predittiva riduce al minimo i tempi di inattività e l'impatto sulla capacità produttiva, mentre garantisce una qualità costante. Nel confezionamento l'IA può anche ottimizzare l'utilizzo delle risorse, riducendo gli sprechi di materiali e perseguire l'efficienza energetica, contribuendo all'adozione di soluzioni di imballaggio sostenibili e convenienti (Mohammad Hassan et al., 2023).

Un ruolo cruciale nel garantire la conformità agli standard normativi e la tracciabilità negli imballaggi di alimenti e bevande. I sistemi IA possono essere addestrati per verificare la

conformità alle normative sull'etichettatura, tra cui l'elencazione corretta degli ingredienti, delle informazioni nutrizionali e delle date di scadenza. Se integrata con blockchain e registri digitali (come sempre più spesso accade), l'IA facilita la tracciabilità trasparente e a prova di manomissione lungo tutto il percorso del prodotto dalla produzione al consumo. L'impatto della tracciabilità riguarda anche la fiducia dei consumatori e la loro fidelizzazione. Gli aspetti sopra citati hanno nel packaging il momento cruciale, perché è lì che si concentra l'esposizione delle informazioni nelle etichettature (visibili o nascoste che siano). Il packaging è quindi un nodo cruciale anche in relazione alla conservazione e stoccaggio dei prodotti alimentari, le tecnologie di IA si possono riscontrare anche nella previsione delle caratteristiche del prodotto in fase di conservazione, attraverso il monitoraggio di parametri di salubrità, ma anche di controllo delle emissioni di anidride carbonica nell'ambiente, requisito importante nella produzione alimentare (Kollia Ilianna et al., 2021).

## 5.2 Applicazione dell'IA per funzione, tipologia di prodotto e fase

Per facilitare la lettura vengono riassunte qui di le abbreviazioni utilizzate nei capitoli successivi per indicare gli algoritmi/tecniche (tabella 4):

Abbreviazioni	Significato	Abbreviazioni	Significato
AE	Auto-encoders	MLP	Multilayer Perceptron (feedforward artificial neural network)
ANN	Artificial neural networks	MLPcr	Multilevel Principle Component Regression
BP	Backpropagation	MV (MVS)	Machine Vision (System)
BP-ANN	Backpropagation - Artificial Neural Network	NB	Naive Bayes
BOOST	Boosting (for bias reducing)	PLS-DA	Partial least squares discriminant analysis
CDDnet	Cross-domain denoising network	PLSR	Partial Least Squares Regression
CNN	Convolutional Neural Network	PCA	Principal Component Analysis
CV	Computer Vision	RBFNN	Radial basis function neural network
DL	Deep learning	RNN	Recurrent Neural Networks
DNN	Deep neural network	RCNN	Region-based Convolutional Neural Networks
DT	Decision Trees	ResNet	Residual Networks
e2eDL	End-to-End Deep learning	RF	Random Forest
Faster RCNN	Region object detection model	SAE	Stacked auto-encoders
FCNN	Fully Connected FNN	SNN	Sequential neural network
FNN	Feedforward neural network	SIMCA	Soft independent modelling by class analogy

<b>GBT</b>	Gradient Boosted Trees machine learning algorithm	<b>SPP</b>	Spatial Pyramid Partition
<b>KNN (k-NN)</b>	k-nearest neighbors algorithm	<b>SPPe</b>	Spatial Pyramid Partition ensemble
<b>LDA</b>	Linear Discriminant Analysis	<b>SVM</b>	Support Vector Machine
<b>LDA</b>	Linear discriminant analysis	<b>U-S</b>	Under-sampling
<b>LR</b>	Logistic/Linear regression	<b>VGG16</b>	16-layer convolution neural network model
<b>ML</b>	Machine learning	<b>YOLO</b>	You Only Look Once

Tabella 4: Acronimi di IA

### 5.2.1 Tecniche ed algoritmi applicati sul controllo delle materie prime:

Settore NACE ATECO	Prodotto	Finalità specifica	Algoritmo / tecnica	Risultati	Referenza
10.3	Albicocca	Riconoscimento nocciolo frutto	LDA, KNN, DT, NB	LDA-KNN: 100% SVM: 96,77%	Ropelewska et., al (2023)
10.3	Ananas	Qualità	SVM	SVM: 97%	Mohd Ali et al., (2022)
10.3	Anguria	Dolcezza frutto	GBT, SVM, LR, ANN, RF, DT, KNN, NB	GBT: 92% SVM: 91,5% LR: 91% ANN: 90% RF: 91,5% DT: 87,5% KNN: 85,5% NB: 89,5%	Chawgien et., al (2021)
10.3	Arancia	Malattie	KNN, CNN, SVM	KNN: 90% CNN: 25% SVM: 15%	K, Thilagavathi et., al (2023)
10.3	Avocado	Maturazione (1*)	SVM	SVM: 90%	Islam et al., (2018)
10.3	Banana	Tipo frutto e stato maturazione	SVM, KNN+SVM	SVM: 99,1% KNN+SVM: 96,6%	Sabilla et al., (2019)
10.3	Cetriolo	Malattie	6 tipi di CNN	MobileNetV2: 93,23%	Mia et al., (2021)
10.3	Ciliegia	Qualità	CNN	CNN: 99%	Park et al., (2021)
10.3	Fragola	Qualità	CNN (E-AlexNet)	CNN: 95,75%	Ni et al., (2021)
10.3	Fragola	Distinzione qualità in classi	RF	RF: 87,95% RF: 78,99%	Ribeiro et al., (2021)
10.3	Kiwi	Maturazione	RF, PLSR, SVM	RF risulta il meglio performante	Du et al., (2021)

Settore NACE ATECO	Prodotto	Finalità specifica	Algoritmo / tecnica	Risultati	Referenza
10.3	Limone	Qualità	CNN	CNN (2*)	Hanh & Bao, (2023)
10.3	Mandorla	Classificazione	SVM, CNN	SVM: 92,72% (3*)	Halac et al., (2017)
10.3	Mango	Maturazione	SVM	SVM: 96%	Nandi et al., (2020)
		Classificazione	SVM, NB	-	Pise et al., (2018)
10.3		Qualità	RF, LDA, SVM, KNN	RF: 98,1% (4*)	Truong Minh Long & Truong Thinh, (2020)
10.3	Mela	Difetti di pastosità	SVM, CNN	CNN: 92%	Fan et al., (2020)
10.3	Mela	Qualità	CNN (AlexNet, VGGNet)	AlexNet: 91,11% VGGNet: 86,94%	Lasghari et al., (2020)
10.3	Melograno	Presenza batterio	KNN, SVM, RF, ANN	KNN-SVM-RF-ANN: 96% (5*)	Sanchez et al., (2020)
10.3	Nespola	Qualità	PLS, RF, XGBoost	XGBoost (6*)	Munera et al., (2021)
10.3	Papaya	Maturazione	CNN (VGG19)	VGG19: 100% (7*)	Behera et al., (2021)
10.3	Pera	Qualità	SVM+raggi X	SVM+raggi X: (90,2-95,1%)	Van de Looverbosch et al., (2020)
10.3	Pomodoro	Classificazione	KNN	KNN (8*)	Pacheco et al., (2019)
10.3	Uciuva	Classificazione	ANN+SVM+KNN+DT	-	Cas96tro et al., (2019)
10.3	Aglione	Riconoscimento stato vegetale	LDA+KNN	LD+KNN: 97,5%	Wang et al., (2021)
10.3	Cavolfiore	Malattia	RF	RF: 89%	Rajbongshi et al (2022)
10.3	Carota	Classificazione	LS+SVM	LS+SVM: 90,3%	Sharma et al., (2021)
10.3	Carota	Classificazione	CDDNet (9*)	CDDNet: 99, 82%, 93,01%	Deng et al., (2021)
10.31	Patata	Contaminazione (10*)	LDA	LDA: 92%	Smeesters et al., (2021)
10.31	Patata	Classificazione	CNN	CNN: 86,6% (11*)	Su et al., (2020)
10.3	Spinaci	Qualità	ANN+SVM	- (12*)	Koyama et al., (2021)
10.2	Pesce	Riconoscimento	SVM	SVM: 94,2%	Sharim et al., (2019)
10.2	Pesce	Freschezza	CNN (VGG16)	CNN (VGG16): 98,21%	Taheri-Garavand et al., (2020)
10.2	Pesce	Contaminazione	SVM	SVM: 99%	Astuti et al., (2022)
10.2	Pesce	Freschezza	KNN	- (13*)	Yudhana et al., (2022)
10.1	Carne	Riconoscimento	8 algoritmi ML (ensemble)	81,5-99% (14*)	Penning et al., (2020)

Settore NACE ATECO	Prodotto	Finalità specifica	Algoritmo / tecnica	Risultati	Referenza
10.1	Carne	Classificazione	CNN (VGG16)	CNN (VGG16): 98,6% (15*)	GC et al., (2021)
10.1	Carne di maiale	Qualità del taglio	SVM	SVM: 92,5%, 75% (16*)	Sun et al., (2018)
10.1	Carne di maiale	Qualità della carne	KNN	KNN: 93,33%	Lumogdang et al., (2020)
10.12	Carne di pollo	Classificazione	SVM	SVM: 77,2%	Barbon et al., (2018)
10.61	Riso	Classificazione	CNN, SVM	CNN: 89,75% SVM: 85,06%	Hong Son et al., (2019)
10.61	Riso	Qualità	SVM+LR	SVM+LR: 94%	Diaz et al., (2023)
10.3	Pomodoro (17*)	Qualità	NN (YOLOV5x)	-	Manjubargavi et al., (2023)
10.3	Uva	Qualità	XGBoost (GBT)	-	Armstrong et al., (2023)

Tabella 5: Tecniche ed algoritmi IA applicati al controllo sulle materie prime

Le note sono state riportate nella tabella sottostante:

Rif.	Nota
1*)	può essere applicato anche alle altre tipologie di frutti per la classificazione dello stato di maturazione durante il controllo qualità
2*)	sono stati studiati vari modelli ed il meglio performante è risultato un tipo di CNN
3*)	sono state proposte diverse tipologie di algoritmi, sia SVM che CNN, il più performante è stato "SVM hybrid" nel 50-50 ratio
4*)	non è stato possibile aprire e leggere i risultati, perciò, è stato indicato l'insieme di questi algoritmi come risultato
5*)	non è stato possibile aprire e leggere i risultati, perciò, è stato indicato l'insieme di questi algoritmi come risultato
6*)	sono stati utilizzati questi 3 algoritmi per 3 differenti classificazioni ed è risultato che XGBoost rappresenta l'algoritmo con una percentuale maggiore di successo
7*)	sono stati analizzati approcci ML e TL (transfer learning) e il più performante risulta essere VGG19
8*)	KNN ha performato generalmente meglio a livello di accuratezza
9*)	il CDDNet rappresenta un modello di deep learning, classificazione binaria 99,82% mentre ottiene 93,01% per il multi-classe
10*)	questo articolo risulta molto utile perché le patate risultate conformi vengono poi utilizzate per essere fritte
11*)	accuratezza complessiva (dimensioni 94,5%, aspetto 91,6%)
12*)	vengono fatte 3 classificazioni: 70, 77, 84%
16*)	il modello KNN ha performato meglio dell'NB
14*)	vengono forniti nel testo alcune informazioni sui risultati di ogni algoritmo
15*)	questo modello ha performato meglio rispetto ad un altro
16*)	accuratezza per due classificazioni
17*)	viene sottolineato il fatto che si tratta di un controllo qualità volto alla produzione di ketchup
18*)	qualità uva tramite attributi neuro sensoriali (aroma, gusto ecc.) utilizzata per predire, di conseguenza, la qualità del vino

Tabella 6: Note sugli elementi di riferimento

### ***Osservazioni Analitiche per il controllo su frutta e verdura:***

Lo studio condotto da Islam et al., (2018) permette di distinguere il grado di maturazione post-raccolta dell'avocado in quattro diverse fasi, utilizzando la spettroscopia dielettrica in combinazione con una macchina a vettori di supporto (SVM) come classificatore per dati appartenenti a specifiche categorie. Il risultato ottenuto propone un'accuratezza del 93% nella distinzione in classi di appartenenza.

Questa metodologia potrebbe essere estesa ed applicata anche ad altri tipi di frutta, così come quella sperimentata nello studio di Behera et al., (2021) per la papaya. In questo approccio, vengono impiegati 9 classificatori di machine learning e 7 di transfer learning. Tra tutti, il modello weighted KNN e VGG19 ottengono il 100% di precisione nell'identificazione dello stato di maturazione post-raccolta.

La categorizzazione dei frutti in base a stati e livelli e stati è stata approfondita nella letteratura scientifica anche da Sabilla et al., (2019) per le banane e da Du et al., (2019) per i kiwi. La banana è stata classificata, oltre che per il suo stato di maturazione, anche per la sua taglia.

La metodologia propone una fase di collezionamento di fotogrammi in un dataset, seguita da una fase di pre-processamento e conversione delle immagini tramite principal component analysis per la riduzione della stessa in formato 236 e 128 pixels. In seguito, vengono testati KNN, SVM e DT come algoritmi per la classificazione delle immagini collezionate.

Lo studio prova che il miglior classificatore è il SVM per la taglia, con una precisione del 99,1%, mentre per la maturazione sia il KNN che il SVM portano allo stesso livello di accuratezza (Sabilla et al., 2019). Nella ricerca di Du et al., (2019), è stata effettuata, per la prima volta, una previsione quantitativa della qualità interna del kiwi utilizzando un naso elettronico.

Il naso elettronico, combinato con diversi metodi di riconoscimento dei pattern quali RF, PLSR e SVM, ha predetto con successo la maturità complessiva, i solidi solubili (SSC) e la compattezza del kiwi. I risultati hanno dimostrato che il modello RF ha superato PLSR e SVM, mostrando una maggiore capacità nell'estrazione di informazioni utili dai dati del naso elettronico relativi al kiwi.

Sono altresì presenti nella letteratura scientifica ricerche inerenti ad altre tipologie di prodotti ortofrutticoli che si servono algoritmi di intelligenza artificiale per la rilevazione delle condizioni del frutto o della verdura dal punto di vista qualitativo dello stesso.

Nella metodologia proposta da Mohd Ali et al., (2022) viene valutata la qualità dell'ananas dal punto di vista del pH, della consistenza e dello stato di conservazione a differenti temperature.

Con l'applicazione della termografia ad infrarosso le immagini vengono segmentate al fine dell'ottenimento di caratteristiche basate sui parametri dell'immagine.

La discriminazione nei parametri delle immagini in relazione alle diverse varietà e metodi di conservazione è stata eseguita con successo dalla macchina a supporto vettori (SVM) che ottiene accuratezza complessiva di classificazione superiore al 97%.

Gli studi di Sharma et al., (2021) ed Deng et al., (2021) apportano sensibili miglioramenti nel processo di selezione automatico delle carote in ambito industriale. Sharma et al., (2021) propone una metodologia che colleziona immagini prese da Google ed utilizza il descrittore HOG per l'estrazione delle caratteristiche. Successivamente, vengono utilizzati tre approcci per la classificazione, uno che si serve del KNN, uno del K-Fold Cross Validation ed infine CNN.

Viene anche costruito da Deng et al., (2021) un modello di deep learning, il CDDNet, che ottiene una precisione binaria del 99,82% nella classificazione delle carote difettose in superficie, e 93,01% nella classificazione multi-classe delle stesse.

La classificazione binaria viene fatta anche da Park et al., (2021) per le ciliegie, che ottenendo una precisione del 99% nella distinzione in buone o meno delle stesse basandosi sull'U-Net.

Per le fragole, invece, Ni et al., (2021) addestrano il modello E-AlexNet per l'identificazione della qualità, riuscendo ad ottenere una precisione dell'algoritmo pari a 95,75%. Sempre per il medesimo fine Ribeiro et al., (2021) utilizzano invece il RF che risulta essere preciso all'87,95% nel discriminare i frutti buoni ed integri rispetto agli altri.

Nella fase di processamento dei limoni è stato costruito da Hanh & Bao, (2023) un metodo per riconoscere lo stato e la rispettiva qualità utilizzando un algoritmo basato sul machine learning, che utilizza la rete YoloV4 per l'analisi dell'oggetto nella sua superficie e che permette di classificarlo. Per creare un algoritmo che ispezioni le mandorle, Halac et al., (2017) hanno proposto una metodologia basata sull'analisi delle componenti principali per identificare i parametri di forma e colore più significativi. Per ovviare a ciò, è stata utilizzata una tecnica di machine learning supervisionato, ovvero l'hybrid SVM, che, paragonato alle reti neurali artificiali, risulta performare meglio per il suddetto scopo.

Per classificare il mango, invece, si può far riferimento alla ricerca di Truong Minh Long & Truong Thinh, (2020) che propone alcuni modelli (KNN, SVM, LDA ed RF) che ricevono alcuni input relativi alle caratteristiche del frutto e rilasciano come output una classificazione dello stesso in tre categorie preimpostate. Il RF è risultato migliore in termini di accuratezza nella distinzione ottenendo un 98,1% di precisione nella gradazione del mango.

Per quanto riguarda le mele, e sono presenti nella ricerca scientifica gli studi apportati da Fan et al., (2020) e da Lashgari et al., (2020). Nel primo caso l'architettura CNN basata sul deep learning permette di classificare 200 mele in 72 ms con un'accuratezza del 92% nell'individuare difetti nelle stesse, mentre nel secondo studio, viene proposta una metodologia economica e non costosa per la rilevazione del livello di farinosità utilizzando AlexNet e VGGNet. Il primo presenta una precisione nell'individuazione del 91,11% di precisione rispetto all'86,94% del secondo.

Il lavoro di Munera et al., (2021) valuta l'utilizzo dell'iperimmaginazione spettrale in combinazione con tecniche di apprendimento automatico per distinguere difetti comuni nelle nespole. Al fine di ottenere un modello che riesca a valutare la conformità dei frutti sono stati impiegati tre classificatori, PLS, RF e XGBoost, abbinati a diverse tecniche di preelaborazione, sono stati impiegati per la valutazione tra caratteristiche conformi e difettose mediante tre approcci.

Nel primo, l'XGBoost ha ottenuto il miglior risultato, ovvero il 97,5%, classificando i pixel del frutto come sani o difettosi.

Nel secondo approccio, sempre analizzando i pixel dell'immagine e sempre utilizzando l'XGBoost, sono stati ottenuti rispettivamente il 96,7% ed il 95,9%. Per visionare la qualità della pera in fase di selezionamento, viene proposta una ricerca condotta da Van De Looverbosch et al., (2020) che utilizza raggi-x accoppiati con un algoritmo di estrazione delle caratteristiche e che utilizza il SVM come classificatore, che individua i frutti difettosi con un range di precisione che varia dal 90,2 al 95,1% in base alle caratteristiche utilizzate. In molti casi, per la valutazione della freschezza e dello stato di un alimento, vengono impiegate delle tecniche distruttive per il prodotto in considerazione.

In tal senso, per mantenere inalterato il prodotto e permettere al medesimo di poter essere lavorato e processato una volta controllato, è necessario utilizzare metodi differenti che non ne alterino le caratteristiche. Seguendo la ricerca pubblicata da Koyama et al., (2021), risulta

possibile valutare la freschezza di una verdura come gli spinaci utilizzando una tecnica non distruttiva.

Le foglie di spinaci sono state fotografate con uno smartphone in vari periodi di conservazione, ed è stata valutata la freschezza utilizzando dei pannelli sensoriali. Le immagini sono state elaborate al fine di estrarre caratteristiche esterne del prodotto che vengano poi utilizzate per addestrare modelli di apprendimento automatico. L'analisi della correlazione tra queste caratteristiche e la valutazione sensoriale ha mostrato associazioni positive per quattro caratteristiche di colore e negative per sei cluster di caratteristiche locali. I classificatori di SVM ed ANN hanno classificato con successo gli spinaci con precisione complessiva del 70% se si fa riferimento a quattro classi, 77% in tre classi e 84% in due classi, portando risultati simili alle valutazioni dei singoli pannelli sensoriali.

Questo suggerisce che modelli basati su tali algoritmi potrebbero sostituire le valutazioni di freschezza attualmente effettuate da pannelli non specializzati.

Sono presenti nella review, anche due metodologie per la classificazione dell'uva e per il controllo qualità della stessa nella fase di processamento. In tal senso si può far riferimento agli articoli di Castro et al., (2019) ed Armstrong et al., (2023). Nel primo viene individuata una combinazione di 3 spazi di colore incrociati con algoritmi di machine learning per la classificazione dell'uva in base al suo stato di maturazione.

I risultati della ricerca portano ad affermare che il SVM abbinato allo spazio colori  $L^*a^*b$  sia maggiormente accurato nell'identificazione degli stati rispetto a tutte le altre combinazioni e soprattutto rispetto ai classificatori KNN, DT ed ANN.

Nel secondo caso, invece, vengono dedotti i parametri sensoriali dell'uva utilizzata nella produzione del vino e per verificare che la stessa abbia i parametri prestabiliti.

Per ottenere quest'obbiettivo, l'applicazione di modelli machine learning basati su dati spettrali dell'estratto d'uva tramite la regressione XGBoost si sono dimostrati uno strumento rapido e risolutivo per la valutazione degli attributi sensoriali del vino partendo, però, dalla materia prima. Per quanto riguarda il pomodoro, sono state individuate nella letteratura scientifica due metodologie ciascuno che portano a risultati concreti in termini di classificazione del prodotto in termini di qualità.

Per il pomodoro, si fa riferimento alle ricerche di Pacheco & Lopez (2019) e di Manjubargavi & Subhashini (2023). Nell'articolo di Pacheco & Lopez (2019) viene testato il KNN come algoritmo che risulta essere maggiormente performante rispetto a MLP e K-means, con precisione del 90%.

Nel secondo caso invece, il lavoro proposto, si basa sull'utilizzo del deep learning per l'ispezione della qualità dei pomodori per la produzione di ketchup. Qui, i pomodori vengono analizzati in base alle loro caratteristiche esterne quali forma, colore e dimensioni.

Il processo viene seguito un metodo di rilevamento oggetti in tempo reale, ovvero il YOLO, che utilizza una rete neurale per il rilevamento in tempo reale degli oggetti. Una volta creato un dataset personalizzato con le immagini collezionate dei pomodori, il modello viene addestrato e testato utilizzando versioni dell'algoritmo di deep learning come YOLOv3 e YOLOv5, che utilizzano reti neurali convoluzionali per identificare gli oggetti. I risultati indicano che YOLOv5x ha la precisione e l'accuratezza più elevate tra tutti quelli considerati.

La media del valore della precisione è del 97.0%, sottolineando che con buona precisione è possibile prevedere in modo accurato i pomodori buoni e distinguerli da quelli marci. Utilizzando queste tecniche nelle industrie alimentari, è possibile mantenere la qualità del ketchup e aumentarne la produzione (Manjubargavi et al., 2023).

Un altro ortaggio molto impiegato in ambito agroalimentare è la patata, essa può essere consumata in tutte le sue forme e può essere sia lavorata che consumata nel suo stato post-raccolta. Sono stati individuati, anche in tal senso, articoli che mostrano, nella fase di selezione e processamento della stessa utilizzando modelli di intelligenza artificiale come strumento per la discriminazione delle stesse.

Il modello di rete neurale convoluzionale proposto da Su et al., (2020) ha raggiunto un tasso di successo elevato non solo in termini di classificazione delle dimensioni, al 94,5%, ma anche nella classificazione dell'aspetto, al 91,6%. L'accuratezza complessiva della valutazione della qualità è stata del 86,6%.

Gli ultimi due articoli riportati riguardano, invece, l'individuazione di malattie e contaminazioni con batteri mediante algoritmi d'intelligenza artificiale addestrati per il suddetto scopo. Per esaminare le contaminazioni del fungo di botrytis nel cavolfiore, si può far riferimento all'articolo pubblicato da Rajbongshi et al., (2022), dove vengono testati vari classificatori di

machine learning e viene proposto il RF come il più accurato per il compito prestabilito, ottenendo un 89% di accuratezza.

Lo stesso fungo può essere presente anche nel melograno e lo può contaminare rendendolo non commestibile. Utilizzando il SVM, in seguito all'estrazione dei fotogrammi è possibile rilevare la malattia con una precisione del 96% (Sánchez et al., 2020).

La dolcezza è un parametro importante da tenere in considerazione per la fase di processamento dell'anguria. Nell'articolo proposto da Chawgien et al., (2021) è stato sviluppato un metodo non distruttivo per classificare la dolcezza dell'anguria basato su segnali acustici e tecniche di elaborazione delle immagini.

Nella fase di identificazione delle caratteristiche principali sono stati considerati i segnali sonori di percussione, i pattern della buccia dell'anguria e il peso della stessa. Come classificatori di machine learning (ML) vengono applicate otto tecniche: Naïve Bayes, K- nearest neighbors, Decision tree, Random Forest, Artificial neural network, Logistic regression, Support vector machine e Gradient boosted trees. I modelli di ML applicati vengono valutati in base alla prestazione di classificazione in termini accuratezza e precisione. I risultati mostrano che il metodo basato sul GBT proposto, può discriminare in maniera puntuale la dolcezza dell'anguria con una accuratezza di classificazione più elevata rispetto agli altri, raggiungendo il 92%.

Il controllo qualità sull'aglio deve accertare che lo stesso non presenti forme di muffa che lo renderebbero inutilizzabile a fini alimentari. Nella letteratura è stato selezionato un articolo che propone una metodologia accurata per l'identificazione di questo problema nell'aglio. Delle immagini di aglio sono, sia normale che ammuffito, vengono acquisite tramite machine vision. Successivamente, viene costruito un modello di classificazione utilizzando l'apprendimento automatico e testato. Il modello KNN può riconoscere l'aglio ammuffito con un tasso di correttezza del 97,5% in 51,4 secondi. La correttezza combinata e l'efficienza risultano superiori rispetto agli algoritmi di classificazione come BPNN, KPCA-SVM, CNN, light-GBM ed altri nello stesso test (Wang & Zhao, 2021).

### **Osservazioni analitiche sul controllo di carne pesce e riso:**

In riferimento al controllo qualità ed ispezione della carne vengono proposti da Penning et al., (2020) due approcci per automatizzare la valutazione della qualità della carcassa utilizzando diversi metodi IA. Il primo si basa sull'analisi delle immagini, mentre il secondo utilizza la spettrometria di massa. Entrambi i metodi si servono di algoritmi di machine learning per aumentare la velocità e l'accuratezza della valutazione della qualità della carne. In generale, tutti ed 8 gli algoritmi impiegati hanno ottenuto un'accuratezza tra l'81,5% e il 99% nella previsione delle caratteristiche di qualità della carcassa anche se non viene specificato qual è stato l'oggetto di discriminazione per la stessa e quali siano stati gli algoritmi impiegati nella ricerca.

GC et al., (2021), costruisce una metodologia per classificare in maniera precisa e rapida 7 tagli di carne utilizzando un totale di 1.113 immagini di tagli di carne bovina come sottoinsiemi di dati per l'addestramento, la convalida ed il test. Il modello sviluppato tramite l'algoritmo di rete neurale di deep learning è stato in grado di classificare alcuni tagli di carne bovina con un'accuratezza fino al 100%. Due modelli di rete neurale convoluzionale (CNN), visual Geometry Group (VGG16) e Inception ResNet V2, sono stati utilizzati per addestrare, convalidare e testare questi modelli nella classificazione delle immagini dei tagli di carne bovina.

Il modello VGG16 ha superato il modello Inception ResNet V2, raggiungendo la massima accuratezza del 98,6% (figura X- media dei valori di accuratezza) su 116 immagini di test, mentre Inception ResNet V2 ha ottenuto un'accuratezza massima del 95,7% sulle stesse immagini di test. Sulla base delle metriche di prestazione di entrambi i modelli, la tecnologia di deep learning ha chiaramente dimostrato un impegno promettente nel riconoscimento dei tagli di carne bovina nell'industria.

Per il controllo qualità sulla carne di maiale, invece, sono state acquisite delle immagini a colori delle porzioni della stessa utilizzando computer vision, in seguito è stato creato un modello di intelligenza artificiale che si basa sul support vector machine (SVM) per la valutazione della qualità del colore e della marmorizzazione del maiale. I risultati hanno mostrato che il computer vision abbinata alla modellazione del support vector machine (SVM) ha raggiunto la massima precisione di previsione del 92,5% per il punteggio di colore misurato e del 75,0% per il punteggio di marmorizzazione misurato (Sun et al., 2018).

Lumogdang et al., (2019), nel loro esperimento, hanno cercato di identificare la freschezza della carne di maiale acquisendo immagini delle porzioni dello e valutato se nella carne vi era presenza di componenti di ammoniaca e idrogeno solforato. Successivamente, questi parametri sono stati classificati utilizzando l'algoritmo dei k-Nearest Neighbors (KNN) per distinguere la stessa come fresca, semi-fresca od inquinata discriminandola tramite l'algoritmo con una percentuale di successo pari al 93,33%. L'ultimo articolo individuata riguardante la carne è attribuito a Barbon et al., (2018) che testa la qualità della carne di pollo utilizzando il support vector machine con un'accuratezza pari al 77,2%.

Il secondo alimento per cui è stata individuata una rilevanza scientifica di applicazione è il pesce. Facendo riferimento a Sharmin et al., (2019) viene individuato un metodo per la ricognizione delle specie di pesce acquisendo delle immagini delle stesse e classificandole utilizzando tre classificatori diversi, ovvero (SVM), (KNN) ed ensemble, individuando il SVM come classificatore maggiormente accurato con la capacità di discriminazione che si attesta sul 94,2%.

L'aroma del pesce può essere considerato un altro attributo per attestare la qualità del pesce in fase di processamento. Secondo Astuti et al., (2022), per classificare il pesce in base a questa caratteristica costruisce un modello che propone di monitorare l'odore del pesce mediante l'uso di un set di sensori di gas in grado di rilevare odori specifici. I test effettuati su tre tipi di campioni, inclusi il batterio *Pseudomonas aeruginosa*, il tonno e il tonno contaminato, hanno dimostrato che un sistema di E-nose, dotato di otto sensori, è in grado di identificare gli odori del pesce con un'accuratezza dell'95% grazie all'utilizzo del support vector machine (SVM).

Un'altra caratteristica per monitorare la qualità del pesce è la freschezza dello stesso. L'analisi di questo parametro può essere fatta come proposto da Taheri-Garavand et al., (2020) applicando un metodo di CNN, ovvero il VGG16, che risulta essere una tecnica non invasiva, di basso costo precisa ma anche automatizzata per classificare lo stato di freschezza del pesce che ottiene una precisione del 98,21%. Per gli stessi motivi enunciati nella ricerca di Taheri-Garavand et al., (2020), queste tecniche non distruttive per il prodotto vengono applicate anche da Yudhana et al., (2022) sempre per il pesce ma utilizzando due algoritmi diversi come classificatori ovvero il KNN ed il NB. L'oggetto di discriminazione, in questo caso, è stato quello di classificare il pesce come buono o non buono basandosi sul riconoscimento dello stato dell'occhio dello stesso. Per far ciò sono stati testati, appunto, due classificatori ed il risultato

della ricerca è stato che il KNN risulta maggiormente accurato a livello di classificazione rispetto al NB.

L'ultimo alimento in cui è stata individuata una rilevanza scientifica nell'applicazione di algoritmi di intelligenza artificiale è il riso. Nella pubblicazione di Hong Son & Thai-Nghe, (2019) viene costruito un modello per l'identificazione della qualità del riso vietnamita come rotto oppure intero, seguendo un processo iterativo.

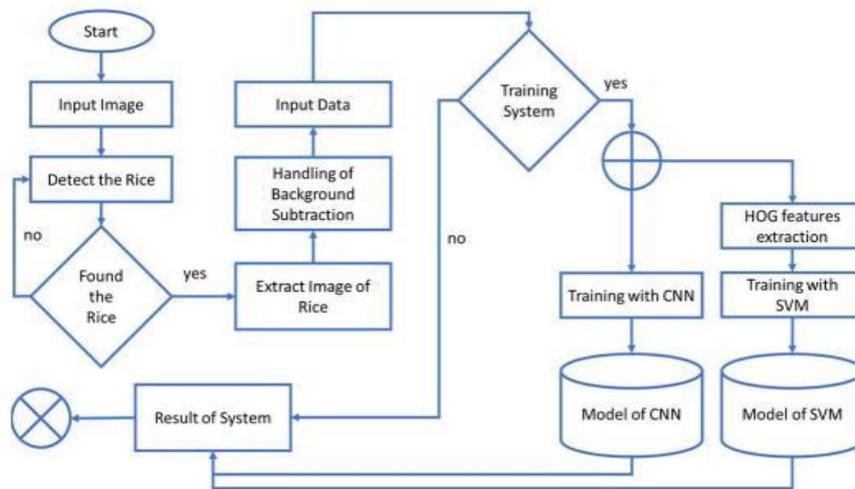


Figura 10: Modello per la classificazione del riso, Fonte: Hong Son & Thai-Nghe, (2019)

In questo processo vengono immesse immagini del riso, che può presentare un chicco intero o rotto, e questi fotogrammi, catturati con il supporto della computer vision, vengono utilizzati in prima istanza per addestrare i modelli utilizzati. In secondo luogo, una volta che il sistema ha imparato a riconoscere i chicchi come integri o no, vengono utilizzati il modello di deep learning CNN e quello di SVM per classificare il secondo set di immagini che servono per testare effettivamente la funzionabilità del modello. Il classificatore che risulta maggiormente performante risulta essere il CNN con una precisione di discrezione pari all'89,75%, che risulta essere superiore al SVM che svolge lo stesso compito ma con un'accuratezza dell'85,06%. Sempre nella classificazione del riso a livello qualitativo viene anche proposto un secondo modello, quello di Díaz et al., (2023), che testa due modelli differenti e che trova nel SVM il modello maggiormente accurato per questo scopo, che risulta essere un classificatore accurato al 94% e maggiormente preciso rispetto al modello di Hong Son & Thai-Nghe, (2019).

## 5.2.2 Tecniche ed algoritmi applicati nei processi di trasformazione

Nella tabella 6 vengono espone le tecniche ed algoritmi applicabili nel controllo nei processi di trasformazione:

Settore NACE ATECO	Prodotto	Tappa del processo di trasformazione	Finalità specifica	Algoritmo / Tecnica	Referenza
10.32	Mela	Essiccazione	Supporto per il rilevamento del contenuto di umidità nel processo di essiccazione effettuato con aria calda e raggi infrarossi	CNN	Huang et al., (2022)
10.32	Carota	Essiccazione	Utilizzo nel processo di essiccazione dei cubetti di carota	ANN	Aghbashlo et al., (2021)
10.32	Carota	Essiccazione	Utilizzo nel processo di essiccazione convettiva di cubetti di carota	ANN (1*)	Nazghelichi et al., (2021)
10.32	Banana	Essiccazione	Modello ANN per il controllo dell'essiccatore a microonde	ANN	Sabzevari et al., (2021)
10.32	Goji	Classificazione / smistamento	Classificazione del prodotto essiccato	LS-SVM	Nirere et al., (2022)
10.31	Manioca	Essiccazione	Monitoraggio dell'essiccazione dei chips	ANN	Hendrawan et al., (2018)
10.11	Carne	Classificazione / smistamento	Classificazione automatica delle fette in base alla direzione delle fibre nella carne dopo il taglio	PLSR ML(2*)	Ren et al., (2022)
11.05	Birra	Fermentazione	Controllo di sensori ad ultrasuoni per la verifica della concentrazione di alcool durante la fermentazione della birra	ML	Bowler et al., (2021)
10.41.1	Olive	Lavaggio	Classificazione online della qualità delle olive prima del lavaggio (SVM) e post lavaggio (ANN) (3*)	ANN, SVM	Puerto et al., (2019)
10.41.1	Olio oliva	Molitura, gramolatura, filtrazione	Tecnologia NIR ed E-nose per l'identificazione del livello di rancidità durante la produzione dell'olio	ANN	Gonzalez Viajo et al., (2021)
10.41.1	Olio oliva	gramolatura, filtrazione, imbottigliamento	Identificazione del livello organolettico di inacetimento accuratezza 84%) e muffa (accuratezza 72%)	SVM+NB+CT	Martinez et al., (2023)
10.41.1	Olio oliva	Molitura	Utilizzo associato a spettroscopia vis/NIR per la verifica del contenuto di olio durante le fasi di molitura	PLSR ML	Giovenzana et al., (2018)
10.2	Pesce	Taglio	Identificazioni dei punti di taglio del pesce	MVS	Azarmdel (2019)
10.2	Pesce	Controllo di Qualità e conformità	Verifica della presenza di sangue nei filetti di pesce	CNN, SVM	Misimi et al., (2017)
10.2	Pesce	Controllo di Qualità e conformità	Verifica della difettosità nei filetti di salmone	CNN	Xu et al., (2018) (59)
10.2	Pesce	Controllo di Qualità	Rilevamento delle lische nel salmone	Faster-RCNN+VGG16	Xie et al., (2021)
10.12	Pollo	Classificazione e smistamento	Riconoscimento, separazione e smistamento delle porzioni di pollo	ANN	Teimouri et al., (2018)
10.83	Thè	Classificazione e	Classificazione del grado di fermentazione	MLP, RF, SVM	Jin et al.,

Settore NACE ATECO	Prodotto	Tappa del processo di trasformazione	Finalità specifica	Algoritmo / Tecnica	Referenza
		smistamento	del thè nero		(2020)
10.83	Thè	Previsione e ottimizzazione	Previsione del contenuto di umidità delle foglie di thè durante la fase di appassimento	SVM (4*)	Lian et al., (2018)
10.83	Thè	Previsione e ottimizzazione	Previsione dello stato di fermentazione del thè nero	BP-ANN, RF, SVM	Zhu et al., (2019)
10.83	Thè	Monitoraggio	Monitoraggio dello stato di fermentazione del thè	k-NN, RF, DT, SVM, CNN (5*)	Kimutai et al., (2020)
10.83	Thè	Controllo di Qualità	Controllo di qualità su foglie essiccate di thé	ANN, DT, SVM, BN , (6*)	Bakhshipour et al., (2018)
10.83	Thè	Classificazione e smistamento	Controllo e calibrazione sui granuli di thè post-essiccazione	SPPe, CV	Rahman et al., (2021)
10.51	Formaggio	Monitoraggio e classificazione	Monitoraggio dello stato di maturazione del formaggio (7*)	k-NN, RF, DT, MLP, SVM, CNNs	Loddo et al., (2022)
11.04	Bevande	Imbottigliamento	Controllo della formazione di schiuma durante il riempimento di bevande non-gassate	CNN, RNN	Morelle et al., (2021)
cod. multipli	Farine e prodotti in polvere	Convogliamento degli ingredienti	Classificazione in linea degli ingredienti in polvere per evitare errori di caricamento	SVM	Ozturk et al., (2023)

Tabella 7: Tecniche ed algoritmi applicati nel controllo nei processi di trasformazione

Le note sono state riportate nella tabella sottostante:

Rif.	Nota
(1*)	ANN ha dato la migliore accuratezza
(2*)	PLSR applicata a HSI (Hyperspectral image acquisition) per la classificazione automatica delle fette in base alla direzione delle fibre nella carne dopo il taglio
(3*)	Inserito qui perché il lavaggio è parte del processo di trasformazione della produzione dell'olio (non c'è interruzione del processo e le olive lavate non possono essere avviate a un nuovo frantoio)
(4*)	Il metodo non lineare (SVM) performa meglio di quello lineare (PLS)
(5*)	Il CNN si è dimostrato più affidabile rispetto ad altri ML-algorithms quali SVM, RF, KNN, DT, LDA e NB
(6*)	ANN si è dimostrato più affidabile rispetto ad altri ML-algorithms quali SVM, RF, KNN, DT, LDA e NB
(7*)	Sono stati testati vari algoritmi: i risultati migliori si sono ottenuti CNNs

Tabella 8: Note sugli elementi di riferimento

## La sintesi dei principali algoritmi utilizzati nei processi di trasformazione:

Per alcuni prodotti sembrano prevalere alcune tecniche che mostrano performance migliori:

Prodotto	Lavorazione	Finalità	Miglior risultato	Referenza
Frutta e verdura (mela, carota, banana, manioca)	Essiccazione	Monitoraggio e controllo di processo	ANN	Huang et al., (2022) Aghbashlo et al., (2021) Nazghelichi et al., (2021) Sabzevari et al., (2021) Nirere et al., (2022) Hendrawan et al., (2018)
Pesce, carne, pollo	Ottimizzazione del taglio	Classificazione e controllo di processo	MVS	Ren et al., (2022) Azarmdel (2019) Misimi et al., (2017) Xu et al., (2018) Xie et al., (2021)
Pesce, carne, pollo	Controllo di Qualità e conformità in linea	Monitoraggio, classificazione e controllo di processo	CNN, SVM	Misimi et al., (2017) Xu et al., (2018) Xie et al., (2021)
Thé	Controllo di Qualità e conformità in linea	Monitoraggio, classificazione e controllo di processo	RF, CNN	Teimouri et al., (2018) Jin et al., (2020)
Olio di oliva	Controllo di Qualità e conformità in linea	Monitoraggio e controllo di processo	SVM, ANN	Gonzalez Viajo et al., (2021) Martinez et al., (2023)
Prodotti discreti (frutta, verdura, pesce, carne, pollo)	Caratterizzazione	Classificazione e smistamento	ANN,SVM	Nirere et al., (2022) Martinez et al., (2023) Misimi et al., (2017) Teimouri et al., (2018) Jin et al., (2020)
Prodotti continui (olio, birra)	Caratterizzazione	Classificazione e smistamento	ANN, CNN, SVM	Puerto et al., (2019) Gonzalez Viajo et al., (2021) Morelle et al., (2021)

Tabella 9: Tecniche di IA che mostrano performance migliori utilizzate nel processo di trasformazione

### **Osservazioni analitiche sulle tecniche IA nei processi di trasformazione:**

Per questo gruppo di applicazioni non si sono potute rilevare in maniera utilmente comparabile le prestazioni e le metriche degli algoritmi, che perciò sono state inserite, laddove sia stato possibile, nel testo.

Nella pubblicazione di Huang et al., (2022) viene studiato il processo di essiccazione delle fette di mela e monitorata la qualità attraverso lo sviluppo di un modello di rete neurale profonda (DNN) basata su 4526 gruppi di dati composti in fotogrammi di mela essiccata. Questo modello è stato impiegato con successo per prevedere variazioni nel rapporto di umidità (MR) e nel contenuto di umidità sulla base secca (DBMC) delle fette di mela durante l'essiccazione. Il DNN ha dimostrato un'elevata precisione predittiva se confrontato con altri modelli come il perceptron multistrato (MLP) e la regressione a vettori di supporto (SVR). Infatti, il DNN ha ottenuto risultati più precisi rispetto agli altri due modelli permettendo un monitoraggio preciso ed efficiente per controllare la freschezza e qualità del prodotto lavorato.

L'esame accurato e la possibilità di determinare come la qualità della frutta venga influenzata dopo l'essiccazione è un fattore importante del management della vita del prodotto a valle dell'essiccazione. La tecnologia di imaging iperspettrale (HSI) è una delle tecnologie avanzate adottate per valutare la qualità alimentare. La ricerca eseguita da Nirere et al., (2022) ha esplorato l'impatto dei metodi di preelaborazione dei dati di normalizzazione sugli esiti di misura e di predizione della qualità della frutta di goji essiccata.

Questa ricerca ha dimostrato che utilizzando la tecnologia HSI e integrando i metodi di preelaborazione SG-SVN nel modello di support vector machine a minimo quadrato (LS-SVM), si può prevedere con precisione la qualità della frutta di goji essiccata. L'algoritmo LS-SVM accoppiato con SG-SVN ha raggiunto un'accuratezza di previsione del 96,66%, la più alta tra le accuratezze di classificazione in questo ambito. I risultati dello studio dimostrano che la tecnologia HSI combinata con il modello LS-SVM è fattibile per la classificazione della qualità della frutta di goji essiccata.

Nello studio di Hendrawan et al., (2018) si è cercato di implementare un sistema di monitoraggio basato sulla visione artificiale per l'essiccazione delle patatine di manioca, in grado di ottimizzare il processo di essiccazione. L'obiettivo principale era quello di proporre algoritmi di ottimizzazione basati sull'intelligenza artificiale per individuare il set più significativo di pattern

dell'immagine adatto alla previsione del contenuto di acqua delle patatine di manioca durante il processo di essiccazione utilizzando un modello di rete neurale artificiale (ANN).

Questo sottoinsieme di pattern è stato testato con successo nel modello per descrivere la relazione tra le pattern dell'immagine e il contenuto di acqua delle patatine di manioca durante il processo di essiccazione, ottenendo un coefficiente di determinazione tra dati reali e previsti pari a 0,9.

Nella ricerca di Smeesters et al., (2021) viene costruito un modello per l'identificazione non distruttiva delle patate non adatte alla produzione di patatine fritte che presentano acrilamide nella fase di pre e post-frittura. Per identificare le soglie critiche di concentrazione nelle stesse viene proposta una metodologia che risulta essere funzionante per i campioni somministrati all'algoritmo nel 92% dei casi.

Anche per la carne il monitoraggio e controllo della qualità della carne durante la fase di essiccazione è un fattore determinante nella fase di lavorazione. Il controllo continuo del contenuto di umidità permette di ottenere prodotti alimentari sicuri e che rispettino i criteri stabiliti dall'azienda produttrice. Nell'esperimento condotto da Ren et al., (2022) viene costruito un modello basato sulla PCA che permette di rilevare il livello di essiccazione delle fibre della carne.

Un altro elemento considerato nella ricerca è la birra, un elemento che necessita di varie fasi di lavorazione partendo dal luppolo fino ad arrivare al prodotto finito. Una fase principale è rappresentata dalla fermentazione del mosto, che rappresenta un processo chimico in cui le cellule di lievito metabolizzano gli zuccheri trasformandoli in anidride carbonica ed alcol etilico.

Questa fase di trasformazione è stata controllata da Bowler et al., (2021) nella sua pubblicazione monitorando la qualità nella fermentazione del mosto in alcuni recipienti. Sono stati utilizzati due dei tredici lotti a disposizione per addestrare il modello basato sull'RNN e, successivamente, sono stati impiegati gli altri undici per testare il modello. Lo stesso ha ottenuto buoni risultati per le metriche utilizzate ovvero il coefficiente di determinazione ( $R^2$ ), l'errore quadratico medio (MSE) e l'errore assoluto medio (MAE).

Una corretta classificazione dei lotti di olive nello stato di pre e post lavaggio è necessaria al fine dell'ottenimento di un'alta qualità dell'olio d'oliva. L'articolo di Gonzalez Viejo & Fuentes, (2022) presenta un sistema di visione artificiale online che classifica automaticamente i lotti di olive in base al loro livello di qualità in diverse categorie.

L'approccio suggerito utilizza un vettore di pattern che concatena gli istogrammi delle immagini delle olive da diversi spazi di colore e i valori di texture di tre algoritmi (entropia dell'immagine, matrice di co-occorrenza a livelli di grigio e statistiche come Contrasto, Correlazione, Energia ed Omogeneità). Come classificatori sono stati utilizzati una Rete Neurale Artificiale (ANN) e una Macchina a Vettori di Supporto (SVM).

Per la validazione sperimentale, sono state analizzate 6325 immagini da 100 lotti, mostrando buoni risultati di classificazione con tassi di successo del 98,4% prima della fase di lavaggio con SVM, e del 98,8% dopo la pulizia usando l'algoritmo ANN.

Nella pubblicazione di Gonzalez Viajo et al., (2022) viene proposta l'implementazione di tecnologie digitali che utilizzano la spettroscopia ad infrarosso (NIR) e un modello di e-nose a basso costo, per la valutazione del livello di rancidità e gli aromi nell'olio d'oliva. Questi campioni sono stati valutati tramite 17 livelli di tramite lo sviluppo di quattro modelli di apprendimento automatico per classificare questi livelli. Tra tutti quelli testati l'ANN è quello maggiormente preciso.

Sempre nella fase di processamento e trasformazione delle olive in olio, sono state individuate altre due pubblicazioni scientifiche, ovvero quella di Martínez Gila et al., (2023) e quella di Giovenzana et al., (2018). Nel primo caso, l'integrazione di sensori a lingua elettronica per la rilevazione di due difetti organolettici che compaiono più frequentemente nell'olio d'oliva durante la fase di trasformazione, ovvero muffa e acidità. Questo sensore è stato costruito per identificare le principali caratteristiche del prodotto. Sono stati, infine, utilizzati tre algoritmi di classificazione (SVM, NB, DT), e il difetto di tipo muffa è stato identificato con un tasso di successo del 72%, mentre il difetto di tipo acetico è stato rilevato con un tasso di precisione dell'84%.

Nel loro studio di Ozturk et al., (2023) si concentrano sull'applicazione di tecniche di IA per affrontare il problema del caricamento errato di materiale in polvere sulle linee di produzione. Si tratta di un evento non raro, che può avere conseguenze sulla sicurezza e qualità del prodotto e sull'economia della produzione.

Anche in questo caso il contributo chiave dell'IA è l'utilizzo di tecniche di machine learning in combinazione con la spettroscopia nel vicino infrarosso (NIR) . Sono stati esplorati vari metodi di preelaborazione dei dati, metodi di selezione delle funzionalità e algoritmi ML per creare una pipeline ML ottimizzata. Lo studio ha rilevato che i risultati più accurati sono stati ottenuti

preelaborando i dati spettrali utilizzando auto-encoder (AE) e applicando SVM sui dati di spettrali provenienti dai sensori. Ulteriori miglioramenti sono stati apportati utilizzando tecniche di sottocampionamento e potenziamento (BOOST). Si è ottenuta una validità complessiva che sta nell'intervallo di 91,68% e 99,52% a seconda della velocità del campione, un risultato promettente per la classificazione degli ingredienti alimentari in polvere in movimento.

### 5.2.3 Tecniche ed algoritmi applicati sul prodotto finito

Settore NACE ATECO	Prodotto	Tappa del processo di trasformazione	Finalità specifica	Algoritmo / Tecnica	Referenza
10.11	Insaccati	Pre-confezionamento e conservazione	Verifica della presenza di adenosina-trifosfato negli insaccati con supporto di HSI e PLSR	PLSR	Feng et al., (2018)
10.2	Gamberetti	Pre-confezionamento e conservazione	Previsione non distruttiva della TVC nei gamberetti sgucciati utilizzando IA per trattare dati da imaging iperspettrale NIR	FCNN, SAE	Yu et al., (2019)
10.11	Carne agnello	Pre-confezionamento e conservazione	Monitoraggio non distruttivo della carica batterica carne d'agnello mediante Vis/NIR-HSI e IA	PLS-DA, SIMCA, BP, DT, RF	Zhang et al., (2022)
10.41.1	Olio di oliva	Pre- e post-confezionamento	Rilevamento dell'adulterazione degli oli d'oliva	NB, KNN, ANN, DT, SVM, LDA	Ordukaya et al., (2017)
10.41.1	Olio di oliva	Pre-confezionamento e conservazione	Identificare il livello di acidità dell'olio	PLS-PCA	Abu-Khalaf et al., (2021)
10.89	Snack di carne di maiale	Pre-confezionamento e conservazione	Classificazione e selezione in funzione della proprietà organolettiche	ANN, MLPN	Pawlak Tomasz et al., (2022)
10.84	Maionese	Pre-confezionamento e conservazione	Controllo qualità della maionese con analisi sensoriale predizione della durata di conservazione.	SVM, k-NN	Metri-Ojeda et al., (2023)
10.07	Succhi di frutta	Pre-confezionamento, conservazione, verifica di prodotto	Controllo e classificazione per valutare la qualità di succhi di frutta freschi e di pregio	SVM	Rasekh et al., (2021)

Tabella 10: Tecniche ed algoritmi applicati nel controllo del prodotto finito

#### Osservazioni analitiche sui controlli del prodotto finito:

Per questo gruppo di applicazioni non si sono potute rilevare in maniera utilmente comparabile le prestazioni e le metriche degli algoritmi, che perciò sono state inserite solamente nel testo.

La concentrazione di ATP (adenosina trifosfato) viene comunemente utilizzata per valutare la freschezza della carne (e anche per il pesce). La misurazione può essere correlata alla quantità di microrganismi, poiché l'ATP è presente in tutte le cellule viventi, compresi i microrganismi. La quantità di ATP nei batteri gram-negativi, che sono dominanti sulla superficie della carne di maiale, è nota; di conseguenza, il contenuto di adenosina trifosfato può essere utilizzato come indicatore di contaminazione microbica.

La misurazione con coltura e conteggio richiede però tempo e lavoro, invece la tecnica proposta in (Feng et al., 2018) permette la misurazione in linea (praticamente immediata) con una tecnica PLSR che consente anche di predire l'evoluzione del degrado.

Il test della carica batterica totale (TVC) è la misura dei livelli di contaminazione microbica su o in un prodotto. La carica batterica può provenire dalle materie prime utilizzate, o essere introdotta dagli operatori o dall'ambiente di produzione. La possibilità di effettuare il test in maniera non distruttiva sul prodotto finito introduce un notevole vantaggio industriale.

Nella soluzione proposta da Yu et al., (2019) l'IA contribuisce in maniera significativa alle performance della tecnologia di monitoraggio TVC dei gamberetti bianchi del Pacifico sgusciati utilizzando la tecnica di imaging iperspettrale (HSI) nel vicino infrarosso (NIR). I passaggi chiave sono (a) l'estrazione di pattern dalle immagini utilizzando codificatori automatici stacked (SAE), (b) sviluppo di un modello di previsione del TVC utilizzando una rete FCNN. Il metodo SAE-FNN ha dimostrato un'elevata precisione di previsione per determinare TVC ( $R^2$  di 0,927).

Nel settore della lavorazione della carne garantire la freschezza è fondamentale in termini di conformità e posizionamento di mercato.

Zhang et al., (2022) hanno mostrato come si possa sfruttare la potenza dell'IA in combinazione con l'imaging iperspettrale (HSI) nel visibile e nel vicino infrarosso (Vis-NIR) per monitorare e classificare diversi gradi di freschezza di campioni di carne di agnello. Oltre a innovazioni nel metodo di rilevamento, sono stati valutati vari modelli di IA (PLS-DA, SIMCA, BP, DT, RF) per determinare il modello di identificazione più accurato. Il modello RF ha dato le migliori prestazioni (93% per il set di addestramento e del 91% per il set di test). Anche in questo caso il contributo significativo dell'IA è nel migliorare le performance delle tecnologie di rilevamento (VIS-NIR in questo caso) per la valutazione rapida e non distruttiva del prodotto.

Lo studio di Ordukaya et al., (2017) si concentra sul rilevamento dell'adulterazione degli oli d'oliva per ridurre tempi e costi in questo processo. I ricercatori hanno raccolto dati grezzi dagli oli d'oliva utilizzando un naso elettronico e poi IA per alimentare gli indicatori del controllo qualità.

Nel primo metodo, gli input vengono applicati direttamente a vari classificatori di machine learning (NB, k-NN, LDA, DT, ANN e SVM).

Nel secondo, viene utilizzata l'analisi delle componenti principali (PCA) per ridurre i dati da 32 input a 8 input. Le prestazioni dei diversi classificatori vengono valutate in base alla loro accuratezza., rendendolo più efficiente ed economico rispetto ai tradizionali test chimici.

Nello studio di Abu-Khalaf (2022), per controllare i parametri di qualità dell'olio d'oliva è stato utilizzato un naso elettronico supportato da PLS-PCA. Il modello ha mostrato prestazioni elevate nella classificazione dei campioni di olio d'oliva in base alle categorie di qualità e i risultati hanno dimostrato che l'EN può prevedere/modellare l'acidità con buona precisione. Inoltre, il naso elettronico supportato da PLS-PCA è stata in grado di discriminare tra diverse categorie di qualità dell'olio d'oliva.

Lo studio di Pawlak Tomasz et al., (2022) mirava a utilizzare ANN per classificare in modo efficiente gli snack di carne di maiale "soffiata", un prodotto in rapida espansione nell'America del Nord (Canada, USA, Messico). Il contributo significativo dell'IA in questo studio è venuto da reti MLPN, utilizzando diversi set di addestramento di descrittori di colore e consistenza. La classificazione e l'individuazione dei determinanti ha contribuito all'ottimizzazione del prodotto finale dal punto di vista della composizione chimica, del colore e della consistenza.

Nel loro lavoro, Metri-Ojeda et al. (2023) hanno sviluppato modelli di classificazione applicando tecniche di IA all'analisi delle immagini per determinare l'accettabilità della maionese. Dalle immagini sono state estratte varie caratteristiche, comprese le informazioni sul colore da diversi spazi colore e differenze di intensità tra le regioni di interesse e lo sfondo. Hanno utilizzato modelli SVM, Gradient Boosting e k-NN e hanno valutato le relative prestazioni con una validazione incrociata.

I modelli hanno raggiunto un'elevata accuratezza (92,60–93,30%), precisione (89,00–93,30%), recall (91,40–96,43%) e misura F1 (91,90–92,30%), ma viene anche evidenziato che questi modelli non erano troppo diversi rispetto al gruppo di valutatori umani (che mostravano rispettivamente valori di 88,33%, 94,37%, 93,54% e 93,75%). L'esito ha comunque dimostrato il potenziale di una metodologia rapida, economica e semplice per stimare l'accettabilità come conformità ed accettazione della maionese nell'analisi sensoriale e studi riguardanti la conservabilità.

Rasekh et al., (2021) affrontano la sfida rappresentata dalla mancanza di metodi semplici, convenienti e non distruttivi per valutare la qualità di succhi di frutta freschi e di pregio, un segmento nel settore delle bevande che sta conoscendo una domanda sempre maggiore da parte dei consumatori. Lo studio esamina l'integrazione di IA con sensori MOS che sfruttano una tecnologia a semiconduttori a ossidi metallici per realizzazione di una 'macchina olfattiva' integrata. L'approccio prevede l'analisi dei modelli di risposta dei sensori utilizzando metodi

quali PCA, LDA e SVM. I risultati dello studio dimostrano che i metodi di classificazione basati su IA, in particolare SVM, QDA e LDA, hanno raggiunto tassi di precisione elevati con il 96,25%, il 95,8% e 94,4%, rispettivamente.

## 5.2.4 Tecniche ed algoritmi impiegati sui controlli nel packaging e stoccaggio

Settore NACE ATECO	Prodotto	Tappa del processo (packaging, stoccaggio ed altro)	Finalità specifica	Algoritmo / Tecnica	Referenza
10.83	Thè	Stoccaggio	Predire il tempo di conservazione residuo con campionamenti	SVM	Li et al., (2020)
10.2	Pesce fresco	Stoccaggio	Controllo dello stato attuale e predizione del tempo di conservazione residuo di filetti di tilapia con sondaggi non distruttivi	RBFNN	Shi et al., (2019)
10.11	Carne bovina cotta	Stoccaggio	Controllo dello stato attuale (carica batterica) e identificazione delle aree deteriorate con sondaggi non distruttivi su carne bovina cotta.	ensemble RF-CA-LS-SVM	Yang et al., (2017)
10.11	Carne di maiale	Stoccaggio	Controllo dello stato attuale (carica batterica) con rilevamento (non distruttivo) in tempo reale su carne di maiale in conservazione refrigerata.	PLSR-SVM	Zheng et al., (2017)
10.41.1	Olio di oliva	Stoccaggio	Rilevazione dello stato di ossidazione e dei parametri fondamentali per la valutazione della qualità e conformità dell'olio di oliva durante la conservazione	ANN, SVM-RBF, NB, MLR	Sanaeifar et al., (2018)
cod. Multipli	Cibi confezionati	Confezionamento	Classificazione delle funzioni intelligenti nel packaging	varie	Kerry et al., (2006)
10.61	Riso e cereali	Pesatura	Sostituire la pesatura meccanica con la stima visiva per poter andare in continuo	DL	Dalai et al., (2019)
10.85.0	Pizza	Controllo qualità	Sostituire l'ispezione visiva con operatore per poter andare in continuo	DL	Banus et al., (2018)
10.1	Salsicce, wurstel	Controllo qualità	Valutare simultaneamente e in maniera non distruttiva sia la carica batterica che le proprietà organolettiche	PLSR, ANN	Siripatrawan et al., (2018)
10.85.0	Cibi confezionati	Pre-consumo	Stima non contact del valore dei nutrienti e delle calorie degli alimenti	ML, Faster R-CNN	Ma et al., (2021)
cod. Multipli	Cibi preparati	Pre-vendita	Quantificare la fibra nei prodotti confezionati	ML, k-NN	Davies et al., (2021)
cod. Multipli	Cibi preparati	Pre-vendita	Previsione automatica, accurata e solida degli attributi alimentari per l'analisi rapida degli alimenti e la registrazione della dieta personale.	AdaBoost, NB, SVM, MLP, MLPcr	Deshmukh et al., (2021)
cod. Multipli	Cibi preparati	Pre-vendita	Prevedere micronutrienti sulla base delle informazioni esistenti sulle etichette degli alimenti.	ensemble, PLSR	Razavi et al., (2023)
11	Bevande	Riempimento / Confezionamento	Controllo del livello di riempimento	ANN	Abdulhamid et al., (2023)
11	Bevande	Riempimento / Confezionamento	Controllo low cost del livello di riempimento	SNN	Anush et al., (2021)

Tabella 11: Tecniche ed algoritmi applicati nel controllo su packaging, stoccaggio ed altro

### **Osservazioni analitiche sulle tecniche IA su packaging e stoccaggio ed altro:**

Per questo gruppo di applicazioni non si sono potute rilevare in maniera utilmente comparabile le prestazioni e le metriche degli algoritmi, che perciò sono state inserite solamente nel testo.

Il periodo di conservazione del tè è difficile da valutare con i tradizionali metodi di analisi sensoriale e chimica. Nella loro ricerca Li et al., (2020) combinano l'imaging iperspettrale (HSI) con metodi chemiometrici e IA per prevedere con maggiore accuratezza il periodo di conservazione del tè verde. Sulla base degli spettri preelaborati, sono stati applicati dei modelli basati su PLS-DA e SVM.

I risultati ottenuti sono accettabili (precisione superiore al 90%). Inoltre, sono stati applicati altri metodi statistici tipici dell'analisi chemiometrica con risultati ancora migliori una volta combinati con SVM. I risultati suggeriscono che l'HSI+SVM potrebbe essere una tecnica utile per valutare il periodo di conservazione del tè verde, fornendo un'alternativa per un monitoraggio in tempo reale della qualità del tè.

Passando nel campo dello stoccaggio dei deperibili, Shi et al., (2018) affrontano la conservazione dei filetti di tilapia (tonnetto) immagazzinati isotermicamente. Gli Autori utilizzano reti neurali con funzione di base radiale (RBFNN) in combinazione con l'imaging iperspettrale (HSI) per stimare con precisione la freschezza dei filetti di tilapia conservati in condizioni di temperatura variabili. Lo studio dimostra ancora una volta l'efficacia della combinazione HSI+ANN nella valutazione non distruttiva degli indicatori di freschezza dei prodotti conservati, in questo caso i filetti di tilapia conservati in condizioni non isotermiche, evidenziandone il potenziale per l'applicazione pratica nei processi di controllo della qualità.

Anche Yang et al., (2017) hanno applicato nel loro lavoro l'imaging iperspettrale (HSI) combinato con tecniche di IA. Il loro studio mirava a valutare l'idoneità della HSI+IA per valutare la freschezza della carne bovina cotta durante la conservazione e individuare le regioni contaminate sui campioni avariati. Lo stato di freschezza è stato riportato a tre classi: fresco, mediamente fresco e deteriorato, in base alla conta vitale totale (TVC) dei batteri. Il modello IA che ha utilizzato in maniera combinata RF-CA-LS-SVM ha dimostrato le prestazioni superiori (precisione complessiva del 97,14%) e le aree contaminate sono poi state identificate utilizzando l'analisi delle componenti principali (PCA).

Anche questa analisi mostra il potenziale dell'HSI+IA nel valutare accuratamente la freschezza e nel rilevare la contaminazione, ponendo così solide basi per futuri progressi nei sistemi di rilevamento online.

Zheng et al., (2017) hanno applicato sostanzialmente lo stesso approccio alla carne di maiale durante la conservazione refrigerata. L'HSI viene utilizzato per rilevare la carica batterica (TVC) e poi modelli di regressione parziale dei minimi quadrati (PLSR) e di regressione con SVM sono stati costruiti e ottimizzati attraverso varie tecniche di trasformazione e filtraggio. I risultati hanno rivelato che il modello di regressione con SVM ha funzionato molto bene con  $R^2$  di 0,94. Gli Autori hanno anche sviluppato un algoritmo di elaborazione delle immagini per estendere il modello di previsione a ogni pixel dell'immagine campione, consentendo la visualizzazione in tempo reale della TVC durante il rilevamento, quindi come metodo affidabile anche in tempo reale.

Il monitoraggio dei livelli di ossidazione e degli attributi di qualità durante lo stoccaggio dell'olio d'oliva è fondamentale per garantire il rispetto delle soglie legali, in particolare per gli oli d'oliva vergini di alto valore e con disciplinari regolati. Per semplificare questo processo e ridurre i tempi di analisi, l'utilizzo dei reagenti, la manodopera e i costi delle attrezzature, Sanaeifar et al., (2017) hanno proposto un nuovo approccio che integra la spettroscopia dielettrica e la visione artificiale. Questo metodo prevede l'estrazione delle caratteristiche cromatiche negli spazi colore RGB, HSV e  $L^*a^*b^*$ , insieme alle caratteristiche dielettriche (entro un intervallo di frequenza), da ciascun campione di olio d'oliva. Sono stati sviluppati e confrontati su questi dati modelli di classificazione e previsione utilizzando varie tecniche di apprendimento automatico (ANN, SVM, NB, MLR).

Tra i modelli di classificazione, la tecnica della rete bayesiana (NB) ha raggiunto la massima precisione del 100% nella classificazione degli oli d'oliva durante la conservazione nella modellazione predittiva, con indici di qualità come valore di perossido ed altri elementi. Questi risultati offrono spunti importanti per lo sviluppo di sistemi automatici, efficienti e affidabili per valutare e monitorare la qualità dell'olio d'oliva affrontando i diversi parametri sia singolarmente che come risultato complessivo.

È generalmente accettato che i sistemi di imballaggio intelligenti possano essere realizzati mediante tre tecnologie principali: (i) indicatori, che mirano a fornire maggiore praticità e/o informare i consumatori sulla qualità del cibo; (ii) supporti dati, quali codici a barre e etichette

di identificazione a radiofrequenza (RFID), che sono specificatamente destinati a scopi di archiviazione, distribuzione e tracciabilità; e (iii) sensori, che consentono una quantificazione rapida e definita delle analisi negli alimenti (Kerry et al., 2006). L'IA si adatta, sfrutta e integra tutte queste tecnologie per migliorarle o per creare funzionalità nuove.

Dalai et al., (2019) documentano la sperimentazione di sistemi di visione artificiale basati su IA utilizzati per automatizzare la pesatura e la lavorazione di prodotti alimentari, migliorando l'efficienza e riducendo i tempi di smistamento. Viene utilizzato deep learning per la segmentazione e un algoritmo combinatorio per l'ottimizzazione del packaging, ottenendo risultati promettenti per alimenti come riso e cereali.

Banús et al., (2021) documentano un sistema di chiusura e l'ispezione della sigillatura delle confezioni di pizza, attività tradizionalmente eseguite da operatori umani, ma limitate dal ritmo di produzione. Il sistema proposto è un sistema di visione artificiale automatizza l'ispezione dei sigilli e delle chiusure delle confezioni della pizza, garantendo un tasso di ispezione in linea del 100%.

Utilizza una rete di deep learning, (architettura ResNet18) per classificare le pizze come accettabili o difettose in base ai sigilli e alle chiusure con valori di precisione del 99,87% in media (max 99,95%, min. 99,74%). Il sistema raddoppia anche la velocità di produzione rispetto all'ispezione manuale, ed è adattabile in contesti simili anche con forme di imballaggio diverse.

Siripatrawan et al., (2018) hanno documentato un sistema di visione artificiale per la valutazione rapida e non distruttiva della qualità del prodotto (wurstel) e della durata di conservazione sia di conformità che di accettabilità, dimostrando il ruolo dell'IA nell'analisi dei dati multispettrali con ANN per migliorare la valutazione della qualità alimentare.

Deshmukh et al., (2021) hanno proposto un sistema per il calcolo delle calorie e degli altri nutrienti presenti negli alimenti come applicazione di visione artificiale con cui l'utilizzatore inquadra un alimento e ne ottiene il conteggio calorico. Vengono utilizzati moduli ML con algoritmi Faster RCNN.

Nella maggior parte dei paesi, l'etichettatura del contenuto di fibre su alimenti e bevande è attualmente volontaria, rendendo difficile sia ai consumatori che ai politici monitorare l'assunzione di fibre.

Nel loro lavoro, Davies et al., (2021) hanno sviluppato un approccio di apprendimento automatico per la previsione automatizzata e sistematica del contenuto di fibre sfruttando le informazioni nutrizionali comuni presenti sui prodotti confezionati. L'algoritmo di ML k-NN ha sovraperformato i metodi di previsione manuale esistenti, con  $R^2$  di 0,84 rispetto a 0,68.

Ma et al. (2021) hanno esplorato l'applicazione delle tecniche emergenti di ML per la previsione degli attributi alimentari, con vantaggi nell'analisi rapida degli alimenti per il monitoraggio della dieta personale. Gli Autori hanno condotto una valutazione completa di cinque modelli di ML, AdaBoost, NB, Linear SVM, Multi-Layer Perceptron (MLP) e una variante MLP personalizzata nota come MLPcr. L'indagine si è concentrata sulla previsione di nutrienti chiave in base alla composizione degli ingredienti, con particolare attenzione a carboidrati, proteine e sodio. I modelli di rete neurale, MLP e MLPcr, hanno dimostrato la massima precisione, raggiungendo fino a 0,9 per i carboidrati. Inoltre, una valutazione dettagliata dei risultati della previsione ha evidenziato il profondo impatto della distribuzione dei dati e della complessità multifattoriale sull'accuratezza della previsione.

Sempre nel campo della previsione di contenuti alimentari è stato affrontato con IA il problema delle carenze di micronutrienti, che si ritiene riguardi oltre un quarto della popolazione mondiale. Le etichette alimentari, progettate per informare i consumatori sul contenuto nutrizionale, hanno un ruolo potenziale per migliorare le diete, ma a causa di vincoli normativi e delle limitazioni delle etichette, queste spesso mancano di dati completi su vitamine e minerali, tralasciando quindi informazioni importanti. Per affrontare questo problema, Razavi et al., (2021) esplora la fattibilità dell'utilizzo di algoritmi di ML per prevedere micronutrienti come vitamine (A, C, B1, B2, B3, B6, B12, E, K) e minerali (magnesio, zinco, fosforo, selenio, manganese, rame) sulla base delle informazioni esistenti sulle etichette degli alimenti. Questi modelli predittivi potrebbero poi essere integrati in app mobili, offrendo ai consumatori informazioni sul contenuto di micronutrienti negli alimenti per fare scelte dietetiche più informate.

Per far questo è stato addestrato un insieme diversificato di algoritmi di classificazione e regressione di ML utilizzando i dati del Food and Nutrient Database for Dietary Studies (FNDDS) che comprende 5624 alimenti. I risultati indicano che, sebbene prevedere le quantità esatte di micronutrienti rimanga impegnativo ( $R^2$  di regressione tra 0,28 e 0,92), i modelli di classificazione migliorano progressivamente se la previsione riguarda delle classi quantitative

("basso", "medio" o "alto" contenuto) ottenendo una precisione superiore a 0,80 (in un intervallo tra 0,83 per il selenio e 0,94 per la vitamina B12).

Nell'ambito delle bevande, Anush et al., (2021) hanno affrontato il problema dell'ispezione e controllo del livello di riempimento, oltre ad altri fattori riconoscibili visivamente, come sigillatura ed etichettatura. Gli Autori hanno proposto un sistema poco costoso di ispezione automatizzata, sfruttando tecniche di elaborazione delle immagini all'interno di framework di machine learning, utilizzando in particolare ANN e superando l'aspetto critico di garantire l'uniformità di valutazione. L'aspettativa di ritorno sull'investimento è elevata, perché riduce le perdite finanziarie e di immagine derivanti da pratiche di imballaggio errate.

Sempre nello stesso filone dell'applicazione di visione artificiale al controllo sulle bevande in fase di packaging è il lavoro di Abdulhamid et al., (2023). Gli Autori osservano che, sebbene esistano modelli pre-addestrati come MobileNet, ResNet-50 e VGG-19, la loro efficacia dipende in gran parte dalla pertinenza dei dati di addestramento per il dominio applicativo specifico. Gli Autori propongono un nuovo approccio con un modello di rete neurale sequenziale (SNN) per il rilevamento e la classificazione del livello di riempimento della bottiglia. Le prestazioni del modello valutate rispetto alle soluzioni esistenti in uno scenario problematico multiclasse, hanno dimostrato una precisione superiore e robustezza negli scenari applicativi del mondo reale, superando le prestazioni dei modelli consolidati, candidandosi così come un'alternativa promettente per applicazioni simili.



## Capitolo 6: Sfide tecnologiche, industriali ed etiche

Come abbiamo visto attraverso l'esposizione, l'integrazione di IA nella trasformazione alimentare (e delle bevande) offre potenziali vantaggi in termini di miglioramento dell'efficienza, della qualità dei prodotti e della sicurezza alimentare. Tuttavia, proprio per le caratteristiche del settore, l'applicazione dell'IA in questo contesto presenta molte sfide ancora aperte.

Gli aspetti più importanti pro e contro l'adozione estensiva di soluzioni IA nelle sono da una parte gli indiscutibili vantaggi di efficienza con i relativi risvolti positivi sulla redditività, e dall'altra le preoccupazioni che riguardano l'affidabilità e i risvolti normativi e sociali: l'impatto del biasing (distorsione), delle cosiddette 'allucinazioni', di errori nascosti, della non ripetibilità, della indeterminatezza della catena di responsabilità, della sicurezza dei dati, l'impatto occupazionale e la carenza di competenze. Le proposte attuali per regolamentare l'IA sono in discussione nei corpi dell'UE da diversi anni, il Parlamento Europeo ha adottato specifiche risoluzioni sull'IA, richiedendo un quadro normativo completo che copra i principi etici e gli obblighi legali relativi allo sviluppo, alla distribuzione e all'uso di IA, robotica e tecnologie correlate nell'UE (Parlamento Europeo, 2020)<sup>9</sup>.

### 6.1 Motivi di cautela

I principali motivi di cautela sono determinati dalle seguenti preoccupazioni.

- Distorsione nei modelli di intelligenza artificiale (Schwartz, R. et al., 2022) I bias negli algoritmi IA possono derivare da dati di addestramento distorti o da una progettazione errata dell'algoritmo e produrre conseguenze indesiderate. Per esempio, un sistema di IA addestrato prevalentemente su determinati tipi di frutta potrebbe non classificarne accuratamente altri.
- Allucinazioni nelle previsioni dell'IA: si riferisce a casi in cui l'IA genera o prevede informazioni che non sono basate sui suoi dati di addestramento, come previsioni errate su processi o designazioni errate di prodotti. A volte gli errori non sono immediatamente evidenti, e potrebbero comportare conseguenze a catena lungo tutta la filiera, soprattutto se le cause stesse degli errori si propagano tra i sistemi. Il rilevamento e la

---

<sup>9</sup> *European Parliament resolution of 20 October 2020 with recommendations to the Commission on a framework of ethical aspects of artificial intelligence, robotics and related technologies (2020/2012(INL))*

correzione di questo tipo di errori richiede il monitoraggio e la convalida continui dei risultati dell'IA, ed è uno dei motivi per cui sistemi completamente autonomi e concatenati non sono ancora adottati se non in situazioni in cui l'errore non è costoso o impattante.

- Lacune di spiegabilità (explainability), ripetibilità, affidabilità. La *spiegabilità* si riferisce alla capacità dei modelli di IA di essere compresi dagli esseri umani, spiegando come vengono prese le decisioni o le previsioni. Gli organismi di regolamentazione potrebbero richiedere alle aziende di spiegare come i loro modelli di IA prendono decisioni, in particolare in aree critiche come il controllo di qualità e le ispezioni di sicurezza. Le preoccupazioni etiche riguardano la garanzia che i sistemi di IA prendano decisioni in modo giusto e imparziale: per esempio garantendo che tutti i prodotti in entrata siano valutati secondo gli stessi standard, senza discriminazioni sulla filiera di provenienza. I sistemi IA, in particolare quelli che coinvolgono modelli complessi di ML, potrebbero non produrre sempre risultati coerenti in condizioni simili, sollevando questioni di ripetibilità, condizione che insieme alla coerenza è fondamentale per la conformità normativa nella lavorazione degli alimenti.
- Interruzione della catena di responsabilità. È un aspetto particolarmente critico nella trasformazione alimentare, perché può sfumare i confini tra responsabilità, trasparenza e accountability (l'obbligo di dar conto), soprattutto quando le decisioni prese dai sistemi di IA portano a incidenti di sicurezza o comunque a conseguenze dannose. Determinare di chi sia la colpa- degli sviluppatori di IA, dell'azienda alimentare o del sistema di IA *per sé*- può essere difficile. Questa incertezza, dalle evidenti conseguenze giuridiche e amministrative può essere mitigata proprio dalla spiegabilità.
- Sicurezza dei dati. I sistemi IA sono difficili da 'chiudere' e possono esporre algoritmi proprietari e dati sui processi di produzione al rischio di manomissione e sabotaggio che possono portare a decisioni errate dei sistemi, con interruzione operativa o danni maggiori. Un altro problema è rappresentato dalla conformità del dataset di addestramento per gli algoritmi, che rappresenta un fattore delicato da considerare. C'è anche una questione di privacy, soprattutto quando la filiera è integrata end-to-end come nel caso della preparazione di cibi pronti on demand dal cliente finale.

- Ricollocazione lavorativa e impatto sulla forza lavoro. Trasformazioni potenziamente dirimpenti come la IA nell'industria alimentare possono produrre anche importanti cambiamenti nella dinamica e nell'assetto dell'occupazione. L'industria alimentare ha reparti già fortemente automatizzati, ma altri a forte intensità di manodopera, e ciò è tanto più vero quanto più piccole sono le imprese. La gestione di questi impatti probabilmente si ripercuoterà sulle decisioni di politica industriale, soprattutto dove l'intervento pubblico può essere efficace dal punto di vista della modulazione dei finanziamenti per l'innovazione (adozione IA) e per la riqualificazione dei lavoratori e delle lavoratrici. Dall'altra parte la domanda di persone con le competenze necessarie chiede uno sforzo importante al sistema dell'istruzione e della formazione professionale. La gestione di questi impatti probabilmente si ripercuoterà sulle decisioni di politica industriale, soprattutto dove l'intervento pubblico può essere efficace dal punto di vista della modulazione dei finanziamenti per l'innovazione (adozione IA). Da una parte la domanda di persone con le competenze necessarie chiede uno sforzo importante al sistema dell'istruzione e della formazione professionale, dall'altra la necessità di ricerca di personale altamente qualificato nell'utilizzo dell'IA potrebbe andare a danneggiare il personale presente all'interno dell'azienda. Nonostante il punto sottolineato dalla Commissione Europea, è ragionevole considerare quanto mostrato da Mihai Mutascu, 2021 nella suo studio, dove analizza l'effetto dell'Intelligenza Artificiale sulla disoccupazione in 23 paesi del mondo tra il 1998 ed il 2016, utilizzando un modello teorico ed empirico basato su stime di robustezza utilizzando un modello di regressione. I suoi risultati mostrano una relazione non lineare tra Intelligenza Artificiale e disoccupazione, che viene maggiormente influenzata dal livello di inflazione, mentre non sembrano esserci collegamenti sostanziali con questioni riguardanti popolazione e produttività. In condizioni di bassa inflazione, l'uso dell'Intelligenza Artificiale sembra migliorare l'occupazione, mentre sotto inflazione alta l'effetto scompare, venendo compensata da aumento di salari e crescita economica. Di conseguenza, secondo Mihai Mutascu risulta importante che i decisori politici sostengano l'uso della tecnologia per ridurre la disoccupazione nei paesi sviluppati, specialmente quando l'inflazione è bassa. Lo studio in questione risulta, ovviamente, inerente ad un periodo storico in cui l'IA si trovava in una fase embrionale di crescita, risulterebbero dunque necessari studi ed

approfondimenti ulteriori per verificare la suddetta relazione anche in un momento storico differente e con un'evoluzione diversa dell'IA che, come sappiamo risulta essere in progresso continuo.

- Adozione attuale della tecnologia: Svanberg, M. et al., (2024) osservano che per esempio nella computer vision, dove la modellazione dei costi è più sviluppata, ai costi 2023, le aziende statunitensi sceglierebbero di non automatizzare la maggior parte delle attività legate alla visione che hanno una "esposizione all'IA" e che solo il 23% dei salari dei lavoratori pagati per le attività di visione sarebbe interessante da automatizzare.

Questa lenta diffusione dell'IA può essere accelerata se i costi si riducono rapidamente o se l'IA viene distribuita tramite piattaforme AI-as-a-service che hanno una scala più grande rispetto alle singole aziende.

## 6.2 Motivi di ottimismo

Considerando la continua crescita della popolazione mondiale, che secondo le stime potrebbe raggiungere i circa 9,7 miliardi di persone entro il 2050<sup>10</sup>, risulta sempre più importante il concetto di sicurezza dei prodotti alimentari, oltre che di efficienza di produzione, sostenibilità ed il modo in cui questi seguano il processo farm-to-fork. L'industria alimentare è di per sé un compartimento molto ampio che va considerato nella sua visione olistica per capire come i benefici, apportati dall'utilizzo delle nuove tecnologie, sulle varie fasi di produzione, trasformazione e distribuzione possono impattare nell'intera filiera. L'Intelligenza Artificiale, in tal senso, si potrebbe inserire nell'intera supply chain di produzione alimentare e della catena di distribuzione, proponendo soluzioni per supportare le decisioni umane e rendere i processi maggiormente automatizzati ed efficaci, alcuni esempi possono essere:

- Partendo dal settore primario, che concerne principalmente agricoltura ed allevamento, esistono alcune soluzioni innovative che comprendono tecniche di IA in combinazione con IoT (Internet of Things) per la valorizzazione della produzione e del raccolto, partendo dalla gestione dell'utilizzo dell'acqua e dei parametri di efficienza del suolo monitorando anche le condizioni metereologiche e la presenza di agenti infestanti per piante e frutta ed ortaggi. Altre soluzioni riguardano il controllo della salute degli animali

---

<sup>10</sup> Godfray, H.C.J.; Beddington, J.R.; Crute, I.R.; Haddad, L.; Lawrence, D.; Muir, J.F.; Pretty, J.; Robinson, S.; Thomas, S.M.; Toulmin, C. Food security: The challenge of feeding 9 billion people. *Science* 2010, 327, 812–818

da allevamento in relazione al loro stato di salute e delle condizioni fisiche degli stessi (Faisal Karim Shaikh et al., 2022). Inoltre risulta possibile, con tecniche di IA, prevedere dati ed informazioni future utili per quantificare le rese del raccolto, come nel caso del riso (Sharma Sanjay et al., 2015), e nella produzione di latte (Gutierrez P. et al., 2020).

- La gestione dei sistemi di refrigerazione e della catena del freddo: Ne è un esempio l'articolo di Pérez-Gomariz et al., (2023) offre un'analisi approfondita dello stato dell'arte di modelli, basati su reti neurali artificiali, in grado di aumentare l'efficienza energetica nei sistemi di refrigerazione industriale e nel prevedere, controllare e diagnosticare il comportamento di tali sistemi con scopo di ottimizzazione degli stessi. Esistono anche altri aspetti analoghi che potrebbero essere maggiormente approfonditi, uno di questi è la gestione della Cold-Chain (Catena del Freddo) grazie all'intelligenza artificiale. Nello studio di Swati Dilip et al., (2022) viene sviluppato un sistema in grado di monitorare in tempo reale l'umidità e la temperatura di alcuni prodotti come latte, dell'uva e formaggio durante il trasporto refrigerato attraverso un sistema con sensori integrati in cui, una volta superata la temperatura prestabilita, il sistema invia un avviso anticipato per segnalare l'anomalia analizzando i dati tramite una tecnica di machine learning, ovvero Random Forest.
- Igiene e pulizia: I macchinari industriali e gli ambienti di lavoro necessitano di ricevere manutenzione dal punto di vista igienico al fine di evitare possibili contaminazioni dannose sul cibo in fase di lavorazione e processamento. Alcuni sistemi che combinano elementi basati sull'Intelligenza Artificiale con sensori o camere, come CIP (Cleaning in place) oppure COP (Clean out of the place), sono in grado di garantire ed aiutare nell'assolvere a questo compito (Tomas Norton et al., 2013).
- Confezionamento: nell'industria di produzione alimentare, una considerazione importante da fare riguarda il controllo automatizzato del confezionamento dei prodotti e l'accettazione della conformità degli stessi. Se ci si concentra sull'aspetto di controllo qualità sulla chiusura e sigillatura di prodotti alimentari termosaldati, viene proposto il CNN come efficace nell'individuazione dei difetti che si verificano in produzione, rendendo inoltre il modello estendibile a scenari simili per il controllo dei prodotti confezionati (Nùria et al., 2021).

Ottimizzare l'intera catena di produzione alimentare è fondamentale per una serie di ragioni cruciali che vanno oltre la semplice efficienza. Innanzitutto, possiamo considerare l'importanza

di creare valore aggiunto in ogni fase del processo. Dalla produzione agricola alla distribuzione, fino alla vendita al consumatore finale, ogni passaggio offre l'opportunità di migliorare la qualità dei prodotti, la loro disponibilità e la loro presentazione sul mercato.

Inoltre, ridurre gli sprechi è essenziale per migliorare la sostenibilità dell'intera catena di produzione alimentare. Ciò significa non solo minimizzare gli sprechi di materia prima durante la produzione, ma anche ottimizzare i processi di trasporto e distribuzione per ridurre le perdite lungo il percorso.

Questo non solo porta a una maggiore produttività economica, ma contribuisce anche a ridurre l'impatto ambientale, riducendo le emissioni di gas serra e l'uso di risorse naturali. Parallelamente, la riduzione dei costi è un obiettivo cruciale per garantire la sostenibilità economica dell'intera catena di produzione alimentare. Ottimizzare i processi e ridurre gli sprechi non solo porta a una maggiore redditività per le aziende, ma può anche portare a prezzi più competitivi per i consumatori, contribuendo così a migliorare l'accesso a cibi di qualità per un numero maggiore di persone. Va sottolineato il ruolo chiave della tecnologia nell'ottimizzazione della catena di produzione alimentare. Dalle tecnologie di monitoraggio e tracciabilità che consentono una maggiore trasparenza e sicurezza dei prodotti, alla robotica e all'Intelligenza Artificiale che migliorano l'efficienza dei processi produttivi, l'innovazione tecnologica svolge un ruolo fondamentale nel trasformare l'intero settore alimentare verso un futuro più sostenibile ed efficiente. In conclusione, ottimizzare l'intera catena di produzione alimentare non è solo una questione di efficienza economica, ma riguarda anche la creazione di valore, la riduzione degli sprechi, la sostenibilità ambientale e la competitività a lungo termine del settore alimentare. È un obiettivo ambizioso che richiede collaborazione e innovazione da parte di tutti gli attori coinvolti, ma i benefici che ne derivano sono di fondamentale importanza per la salute e il benessere delle persone e del pianeta.

Nel report presentato da McKinsey & Company (2019)<sup>11</sup>, infatti, per ogni euro speso nella produzione di cibo, vengono generati costi sociali, ambientali ed economici più che duplicati. In tal senso, come sottolineato dalla società di consulenza, l'utilizzo delle tecniche di Intelligenza Artificiale possono generare benefici in termini di riduzione di sprechi di cibo che in termini di ricavi pari 127 miliardi di dollari entro il 2030. Analogamente, secondo le predisposizioni europee

---

<sup>11</sup> McKinsey, 2019, "How AI can unlock a \$127B opportunity by reducing food waste"

nel taglio delle emissioni di gas serra, entro la stessa data ed almeno del 50%<sup>12</sup>, risulterebbe interessante capire come effettivamente queste tecniche possano contribuire nel raggiungere tale target.

Nel complesso sembra quindi che il fenomeno IA sarà impattante, ma anche graduale e che quindi c'è spazio per adeguare i progetti industriali delle filiere alimentari, ma anche per politiche e riqualificazioni per mitigare l'impatto sulla disoccupazione (Svanberg et al., 2023).

Nel frattempo le evoluzioni tecnologiche stanno proseguendo con accelerazione crescente e autosostenuta, con la possibilità ed è anche una speranza, che molte delle preoccupazioni elencate sopra siano risolte da soluzioni originali.

---

<sup>12</sup> *European Commission Coordinated Plan on Artificial Intelligence 2021 Review. Available online: <https://digital-strategy.ec.europa.eu/en/library/coordinated-plan-artificial-intelligence-2021-review> (accessed on 27 April 2021).*



## Capitolo 7: Conclusioni e sviluppi futuri

Tramite la ricerca bibliografica è stato possibile ottenere un quadro complessivo dell'IA e delle sue principali categorie, rilevandone studi su possibili applicazioni nel settore agroalimentare, e in particolare nell'industria delle lavorazioni alimentari.

Si è rilevato come la crescente complessità dell'industria alimentare, unita alla domanda di standard di qualità e sicurezza più elevati, abbia incentivato lo studio per l'adozione dell'IA, offrendo un'ampia gamma di funzionalità particolarmente adatte ad affrontare le sfide e le opportunità del settore: l'apprendimento automatico, la computer vision, l'elaborazione del linguaggio naturale, la robotica e l'analisi predittiva sono le tecniche principali di cui abbiamo rilevato la presenza in produzione o in fase di valutazione.

Si è rilevato che le applicazioni principali sono nell'ambito del riconoscimento (visivo o strumentale) per la discriminazione di pattern che qualificano il prodotto. In considerazione di ciò, il compartimento più ampio d'interesse per l'IA risulta essere quello inerente al controllo qualità sulle materie prime e che si rivolge prettamente al settore primario. Risulta abbastanza carente o poco trattati temi che riguardano l'analisi su attività strettamente collegate al settore terziario ed, in particolare, nella trattazione di argomenti quali la logistica e le fasi che si sviluppano dopo il controllo sul prodotto finito. In ogni caso potrebbe essere oggetto di discussione o approfondimento, considerando anche il periodo storico antecedente a quello trattato.

Altre funzionalità, come quelle predittive nei controlli di processo, sono ancora strettamente collegate alla struttura delle linee, e probabilmente saranno incorporate nelle prossime generazioni di macchine, come nel caso dei 'nasi', 'lingue' elettroniche, camere ed altro, che integrano capacità chemiometriche, di analisi dati, informatica e statistica a modelli IA. Si è anche visto che alcuni aspetti dell'integrazione attraverso tutte le lavorazioni e sezioni del sistema potrebbero essere decisivi per liberare il potenziale dell'IA di operare con grandi quantità di dati e in condizioni non strettamente deterministiche.

Le soluzioni esaminate risultano, secondo le parole degli autori, avere in generale una percentuale di successo elevata nelle loro applicazioni, e se utilizzate nella maniera corretta, possono anche in alcuni casi essere riprodotte e portare benefici all'intera filiera alimentare oltre che in termini di produttività ed efficienza, anche di sostenibilità.

Tuttavia, sebbene l'uso dell'IA nella trasformazione alimentare sia molto promettente, è necessario comprendere a fondo lo stato attuale dell'adozione dell'IA in questo settore, identificare le sfide ed esplorare le potenziali aree di miglioramento: proprio per le caratteristiche del settore, l'applicazione dell'IA in questo contesto presenta molte sfide ancora aperte.

Questo studio ha cercato di contribuire in questa direzione, esaminando le applicazioni, i benefici, le sfide e le considerazioni etiche associate all'IA nelle fasi *make* dei processi di trasformazione alimentare. Nel prossimo futuro è evidentemente necessario continuare a monitorare, documentare e interpretare le rapide evoluzioni che si presentano anche considerando il crescente interesse sull'argomento.

## Ringraziamenti al progetto NODES

Questa tesi è realizzata nell'ambito del progetto NODES, finanziato dal MUR sui fondi M4C2-Investimento 1.5 Avviso "Ecosistemi dell'Innovazione", nell'ambito del PNRR finanziato dall'Unione europea – NextGenerationEU (Grant agreement Cod. n.ECS00000036).

## Ringraziamenti Personali

Sono giunto al termine di questa esperienza di vita che mi ha dato tanto e mi ha permesso di conoscere una realtà nuova e stimolante. Come tutti i percorsi e cammini è doveroso riconoscere, non solo il merito e gli sforzi personali impiegati per portare a termine un obiettivo, ma anche il contributo e l'aiuto ricevuto dalle persone che direttamente o indirettamente ti hanno aiutato nel percorso.

In considerazione di ciò, ci tengo molto a ringraziare il Prof. Maurizio Galetto per avermi sottoposto questo tema attuale, stimolante e molto interessante. La Prof.ssa Elisa Verna per la sua disponibilità, gentilezza, comprensione ed aiuto che mi ha fornito per portare a termine la mia tesi.

La mia ragazza, Sara, che mi supporta e mi sprona a dare sempre il massimo in ogni situazione, un enorme ringraziamento va a te.

Ai miei genitori che mi hanno permesso di poter svolgere questo percorso di vita non facendomi mancare nulla e interessandosi sempre, grazie mille anche a voi.

A Matteo, un fratello ed una fonte d'ispirazione costante per la mia vita, ti dedico i miei più sentiti ringraziamenti per l'esempio ed il bene che mi vuoi.

Ad Andrea, Veronica, Nonna Rosa ed Anna, Paolo, grazie anche a voi.

Ai miei amici, che mi hanno permesso di svagarmi e di vivere questo percorso con gioia.



# Bibliografia

## Riferimenti bibliografici sul tema dell'IA (capitolo 3):

### Il quadro generale dell'IA:

Joint Research Centre (European Commission), R. Righi, G. De Prato, M. Cardona, M. Vázquez-Prada Baillet, S. Samoili, and M. López Cobo, *The AI Techno-Economic Segment Analysis: Preliminary Report*, Publications Office of the European Union, LU, 2019. <https://data.europa.eu/doi/10.2760/576586>.

Lecue, Freddy, "On the Role of Knowledge Graphs in Explainable AI", Edited by Pascal Hitzler and Krzysztof Janowicz, *Semantic Web*, Vol. 11, No. 1, January 31, 2020, pp. 41–51.

Pappaterra, Mauro José, "Artificial Intelligence Taxonomy", 2022. <https://rgdoi.net/10.13140/RG.2.2.18114.25284/1>.

Pappaterra, Mauro, "A Review of Literature and Public Datasets for the Application of Artificial Intelligence in the Railway Industry", 2022.

Porter, Bruce, Vladimir Lifschitz, and Frank Van Harmelen, *Handbook of Knowledge Representation*, 1st ed., Foundations of Artificial Intelligence, Elsevier, Amsterdam Boston, 2008.

### Tecniche ed algoritmi di AI:

A.D.Dongare, R.R.Kharde, Amit D.Kachare, *International Journal of Engineering and Innovative Technology (IJEIT)* Volume 2, Issue 1, July 2012, Introduction to Artificial Neural Network, ISSN: 2277-3754

Adnan Myasar Mundher, Mohd Shafry Mohd Rahim, Amjad Rehman, Zahid Mehmood, Tanzila Saba, and Rizwan Ali Naqvi, "Automatic Image Annotation Based on Deep Learning Models: A Systematic Review and Future Challenges", *IEEE Access*, Vol. 9, 2021, pp. 50253–50264.

Aldridge Irene, "The AI Revolution: From Linear Regression to ChatGPT and Beyond and How It All Connects to Finance", *The Journal of Portfolio Management*, July 6, 2023. <https://www.pm-research.com/content/ijpormgmt/early/2023/07/06/jpm.2023.1.519>

Basodi Sunitha, Chunyan Ji, Haiping Zhang, and Yi Pan, "Gradient Amplification: An Efficient Way to Train Deep Neural Networks", *Big Data Mining and Analytics*, Vol. 3, No. 3, September 2020, pp. 196–207.

Biau Gerard, and Erwan Scornet. "A random forest guided tour." *Test* 25 (2016): 197-227.

- Bills Manaris, "Natural Language Processing: A Human–Computer Interaction Perspective," Appears in *Advances in Computers* (Marvin V. Zelkowitz, ed.), Academic Press, New York, vol. 47, 1998, pp. 1-66.
- Bouwmans Thierry, et al. "Deep neural network concepts for background subtraction: A systematic review and comparative evaluation." *Neural Networks* 117 (2019): 8-66.
- Ceri, Stefano, et al. "Classification and Clustering." *Web Information Retrieval* (2013): 39-56.
- Chiche Alebachew, and Betselot Yitagesu, "Part of Speech Tagging: A Systematic Review of Deep Learning and Machine Learning Approaches", *Journal of Big Data*, Vol. 9, No. 1, January 24, 2022, p. 10.
- Chollet François, "Xception: Deep Learning with Depthwise Separable Convolutions", 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017, pp. 1800–1807. <https://ieeexplore.ieee.org/document/8099678>.
- Chung Junyoung, Caglar Gulcehre, KyungHyun Cho, and Yoshua Bengio, "Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling", arXiv, December 11, 2014. <http://arxiv.org/abs/1412.3555>.
- De Mauro Andrea, *Big data analytics : guida per iniziare a classificare e interpretare dati con il machine learning*, Apogeo, 2019, ISBN 9788850334780
- Du Kevin, Lucas Torroba Hennigen, Niklas Stoehr, Alexander Warstadt, and Ryan Cotterell, "Generalizing Backpropagation for Gradient-Based Interpretability", arXiv, July 6, 2023. <http://arxiv.org/abs/2307.03056>.
- Fayyad Usama, Gregory Piatetsky-Shapiro, and Padhraic Smyth. "Knowledge Discovery and Data Mining: Towards a Unifying Framework." *KDD*. Vol. 96. 1996.
- Gareth James, Daniela Witten, Trevor Hastie, Robert Tibshirani, Jonathan Taylor, *Unsupervised Learning, An Introduction to Statistical Learning*, 2023, ISBN : 978-3-031-38746-3
- Gerla Giangiacomo, *Fuzzy logic: mathematical tools for approximate reasoning*, Collana: Trends in logic, vol. 11, Dordrecht, Kluwer Academic Publishers, 2001, p. 269, ISBN 0-7923-6941-6
- Guo Gongde, et al. "KNN model-based approach in classification." *On The Move to Meaningful Internet Systems 2003: CoopIS, DOA, and ODBASE: OTM Confederated International Conferences, CoopIS, DOA, and ODBASE 2003*, Catania, Sicily, Italy, November 3-7, 2003. *Proceedings*. Springer Berlin Heidelberg, 2003.
- Gutiérrez Luis, and Brian Keith, "A Systematic Literature Review on Word Embeddings", in Jezreel Mejia, Mirna Muñoz, Álvaro Rocha, Adriana Peña, and Marco Pérez-Cisneros (eds.), *Trends and Applications in Software Engineering*, Vol. 865, *Advances in Intelligent*

- Systems and Computing, Springer International Publishing, Cham, 2019, pp. 132–141. [http://link.springer.com/10.1007/978-3-030-01171-0\\_12](http://link.springer.com/10.1007/978-3-030-01171-0_12).
- Jain Anil K., M. Narasimha Murty, and Patrick J. Flynn. "Data clustering: a review." *ACM computing surveys (CSUR)* 31.3 (1999): 264-323.
- Jain Anil K., Robert P. W. Duin, and Jianchang Mao. "Statistical pattern recognition: A review." *IEEE Transactions on pattern analysis and machine intelligence* 22.1 (2000): 4-37.
- Janiesch Christian, Patrick Zschech, and Kai Heinrich. "Machine learning and deep learning." *Electronic Markets* 31.3 (2021): 685-695.
- John Wiley & Sons, *Introduction to the Logistic Regression Model*, Applied Logistic Regression, 2013, pp. 1–33. <https://onlinelibrary.wiley.com/doi/abs/10.1002/9781118548387.ch1>
- Kim, Sung Wook, Jun Ho Kong, Sang Won Lee, and Seungchul Lee, "Recent Advances of Artificial Intelligence in Manufacturing Industrial Sectors: A Review", *International Journal of Precision Engineering and Manufacturing*, Vol. 23, No. 1, January 1, 2022, pp. 111–129.
- Kolodner Janet L. "An introduction to case-based reasoning." *Artificial intelligence review* 6.1 (1992): 3-34.
- LeCun Yann, Yoshua Bengio, and Geoffrey Hinton, "Deep Learning", *Nature*, Vol. 521, No. 7553, May 2015, pp. 436–444.
- Lipton Zachary C., John Berkowitz, and Charles Elkan. "A critical review of recurrent neural networks for sequence learning." *arXiv preprint arXiv:1506.00019* (2015).
- Mahesh Batta, "Machine learning algorithms-a review." *International Journal of Science and Research (IJSR)*. [Internet] 9.1 (2020): 381-386.
- Martinez Angel, "Part-of-speech-tagging", *Wiley Interdisciplinary Reviews: Computational Statistic* 4.1 (2012): 107-113.
- Muhammad Usama, Junaid Qadir, Aunn Raza, Hunain Arif, Kok-Lim Alvin Yau, Yehia Elkhatib, Amir Hussain, Ala Al-Fuqaha, *Unsupervised Machine Learning for Networking: Techniques, Applications and Research Challenges*, DOI: 10.1109/ACCESS.2019.2916648, 2019.
- Navada Arundhati, et al. "Overview of use of decision tree algorithms in machine learning." 2011 IEEE control and system graduate research colloquium. IEEE, 2011.
- Padmanabha Reddy, P. Viswanath, and B. Eswara Reddy. "Semi-supervised learning: A brief review." *Int. J. Eng. Technol* 7.1.8 (2018): 81.
- Rezaei Amin, and Fatemeh Asadi, "Systematic Review of Image Segmentation Using Complex Networks", *arXiv*, January 5, 2024. <http://arxiv.org/abs/2401.02758>.

- Sadiku Matthew N. O., Omobayode Fagbohunbe, and Sarhan M. Musa, "Artificial Intelligence in Food Industry", *International Journal of Engineering Research and Advanced Technology*, Vol. 06, 2020, pp. 12–19. <https://ijerat.com/index.php/ijerat/article/view/475/462>.
- Sarker Iqbal H., "Machine Learning: Algorithms, Real-World Applications and Research Directions", *SN Computer Science*, Vol. 2, No. 3, March 22, 2021, p. 160.
- Susheel Kumar, Deepak Laxkar, Sourav Adhikari, V Vijayarajan, *IOP Conference Series: Materials Science and Engineering*, Volume 263, Issue 4, Assessment of various supervised learning algorithms using different performance metrics, DOI: 10.1088/1757-899X/263/4/042087, 2017
- Szegedy Christian, Vincent Vanhoucke, Sergey Ioffe, Jon Shlens, and Zbigniew Wojna, "Rethinking the Inception Architecture for Computer Vision", *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016, pp. 2818–2826. <https://ieeexplore.ieee.org/document/7780677>.
- Thawani, Avijit, Saurabh Ghanekar, Xiaoyuan Zhu, and Jay Pujara, "Learn Your Tokens: Word-Pooled Tokenization for Language Modeling", *arXiv*, October 17, 2023. <http://arxiv.org/abs/2310.11628>.
- Trevor Hastie, Robert Tibshirani e Jerome H. Friedman, *The elements of statistical learning : data mining, inference, and prediction*, Second edition, p. 10, ISBN 9780387848570, OCLC 300478243, 2001
- Uddin Shahadat, Ibtisham Haque, Haohui Lu, Mohammad Ali Moni, and Ergun Gide, "Comparative Performance Analysis of K-Nearest Neighbour (KNN) Algorithm and Its Different Variants for Disease Prediction", *Scientific Reports*, Vol. 12, No. 1, April 15, 2022, p. 6256.
- Upulie Handalage and Lakshini Kuganandamurthy, "Real-Time Object Detection Using YOLO: A Review", 2021. <https://rgdoi.net/10.13140/RG.2.2.24367.66723>.
- Van Houdt Greg, Carlos Mosquera, and Gonzalo Nápoles, "A Review on the Long Short-Term Memory Model", *Artificial Intelligence Review*, Vol. 53, No. 8, December 1, 2020, pp. 5929–5955.
- Vaswani Ashish, Noam Shazeer, Niki Parmar, Jakob Uszkoreit, Llion Jones, Aidan N. Gomez, Lukasz Kaiser, and Illia Polosukhin, "Attention Is All You Need", *arXiv*, August 1, 2023. <http://arxiv.org/abs/1706.03762>.
- Webb Geoffrey I., "Naïve Bayes", in Claude Sammut and Geoffrey I. Webb (eds.), *Encyclopedia of Machine Learning*, Springer US, Boston, MA, 2010, pp. 713–714. [https://doi.org/10.1007/978-0-387-30164-8\\_576](https://doi.org/10.1007/978-0-387-30164-8_576).

Woergoetter Florentin, and Bernd Porr, "Reinforcement Learning", Scholarpedia, Vol. 3, No. 3, March 31, 2008, p. 1448.

Wolf Thomas, Lysandre Debut, Victor Sanh, Julien Chaumond, Clement Delangue, Anthony Moi, Pierric Cistac, et al., "HuggingFace's Transformers: State-of-the-Art Natural Language Processing", arXiv, July 13, 2020. <http://arxiv.org/abs/1910.03771>.

Xu Shuyuan, et al. "Computer vision techniques in construction: a critical review." Archives of Computational Methods in Engineering 28 (2021): 3383-3397.

Yadav Vikas, and Steven Bethard, "A Survey on Recent Advances in Named Entity Recognition from Deep Learning Models", in Emily M. Bender, Leon Derczynski, and Pierre Isabelle (eds.), Proceedings of the 27th International Conference on Computational Linguistics, Association for Computational Linguistics, Santa Fe, New Mexico, USA, 2018, pp. 2145–2158. <https://aclanthology.org/C18-1182>.

Yousuf Hana, Michael Lahzi, Said A. Salloum, and Khaled Shaalan, "A Systematic Review on Sequence-to-Sequence Learning with Neural Network and Its Models", International Journal of Electrical and Computer Engineering (IJECE), Vol. 11, No. 3, June 1, 2021, pp. 2315–2326.

Zhang Li, Yue Pan, and Tong Zhang. "Focused named entity recognition using machine learning." Proceedings of the 27th annual international ACM SIGIR conference on Research and development in information retrieval. 2004.

Zhao Zhong-Qiu, et al. "Object detection with deep learning: A review." IEEE transactions on neural networks and learning systems 30.11 (2019): 3212-3232.

#### **Riferimenti bibliografici per tassonomia dell'industria alimentare (capitolo 4):**

##### **Per una tassonomia dell'industria alimentare:**

Aguayo-Patrón, Sandra, and Ana Calderón De La Barca, "Old Fashioned vs. Ultra-Processed-Based Current Diets: Possible Implication in the Increased Susceptibility to Type 1 Diabetes and Celiac Disease in Childhood", Foods, Vol. 6, No. 11, November 15, 2017, p. 100.

Allegato-8-Codici-Ateco-2007.pdf

Banga, Julio R, Eva Balsa-Canto, Carmen G Moles, and Antonio A Alonso, "Improving Food Processing Using Modern Optimization Methods", Trends in Food Science & Technology, Vol. 14, No. 4, April 1, 2003, pp. 131–144.

Bender-Salazar, Rahmin, "Design Thinking as an Effective Method for Problem-Setting and Needfinding for Entrepreneurial Teams Addressing Wicked Problems", Journal of Innovation and Entrepreneurship, Vol. 12, No. 1, April 13, 2023, p. 24.

Classificazione delle attività economiche Ateco”, March 30, 2022.  
<https://www.istat.it/it/archivio/17888>.

Lab, Food Research, “Various Types and Methods Involved in Food Processing”, Guires Food Research Lab, January 6, 2021. <https://www.foodresearchlab.com/blog/new-food-product-development/various-types-and-methods-involved-in-food-processing/>.

NACE Rev. 2 - Statistical Classification of Economic Activities”, n.d.  
<https://ec.europa.eu/eurostat/web/products-manuals-and-guidelines/-/ks-ra-07-015>.

NACE Rev. 2 Introductory Guidelines- EN.Pdf”, n.d.

Roos, Yrjvð, “Phase Transitions and Transformations in Food Systems”, in Dennis Heldman and Daryl Lund (eds.), Handbook of Food Engineering, Second Edition, Vol. 20062038, Food Science and Technology, CRC Press, 2006, pp. 287–352.  
<http://www.crcnetbase.com/doi/abs/10.1201/9781420014372.ch3>.

Sadler, Christina R., Terri Grassby, Kathryn Hart, Monique Raats, Milka Sokolović, and Lada Timotijevic, “Processed Food Classification: Conceptualisation and Challenges”, Trends in Food Science & Technology, Vol. 112, June 2021, pp. 149–162.

USDA ERS - Market Segments”, n.d. <https://www.ers.usda.gov/topics/food-markets-prices/food-service-industry/market-segments/>.

Witsch, Maria, and Birgit Vogel-Heuser, Towards a Formal Specification Framework for Manufacturing Execution Systems, 2022.

## **Riferimenti bibliografici delle applicazioni dell'IA per funzione e tipologia di prodotto (capitolo 5):**

### **Tecniche e algoritmi applicati nel controllo delle materie prime:**

Ali, Maimunah Mohd, Norhashila Hashim, Ola Lasekan, and Samsuzana Abd Aziz, “Quality Prediction of Different Pineapple (Ananas Comosus) Varieties during Storage Using Infrared Thermal Imaging Technique”, Food Control, Vol. 138, August 1, 2022.  
<https://discovery.researcher.life/article/quality-prediction-of-different-pineapple-ananas-comosus-varieties-during-storage-using-infrared-thermal-imaging-technique/89ecd6dfab3036148f666135fe9287f7>.

Armstrong, Claire E. J., Jun Niimi, Paul K. Boss, Vinay Pagay, and David W. Jeffery, “Use of Machine Learning with Fused Spectral Data for Prediction of Product Sensory Characteristics: The Case of Grape to Wine”, Foods, Vol. 12, No. 4, January 2023, p. 757.

Astuti, Suryani Dyah, Achmad Ilham Fanany Al Isyrofie, Roichatun Nashichah, Muhammad Kashif, Tri Mujiwati, Yunus Susilo, Winarno, and Ardiyansyah Syahrom, “Gas Array Sensors Based on Electronic Nose for Detection of Tuna (Euthynnus Affinis)

- Contaminated by *Pseudomonas Aeruginosa*”, *Journal of Medical Signals and Sensors*, Vol. 12, No. 4, November 10, 2022, pp. 306–316.
- Barbon, Sylvio, Ana Paula Ayub da Costa Barbon, Rafael Gomes Mantovani, and Douglas Fernandes Barbin, “Machine Learning Applied to Near-Infrared Spectra for Chicken Meat Classification”, *Journal of Spectroscopy*, Vol. 2018, August 7, 2018, p. e8949741.
- Behera, Santi Kumari, Amiya Kumar Rath, and Prabira Kumar Sethy, “Maturity Status Classification of Papaya Fruits Based on Machine Learning and Transfer Learning Approach”, *Information Processing in Agriculture*, Vol. 8, No. 2, June 1, 2021, pp. 244–250.
- Castro, Wilson, Jimmy Oblitas, Miguel De-La-Torre, Carlos Cotrina, Karen Bazan, and Himer Avila-George, “Classification of Cape Gooseberry Fruit According to Its Level of Ripeness Using Machine Learning Techniques and Different Color Spaces”, *IEEE Access*, Vol. 7, 2019, pp. 27389–27400.
- Chawgien, Ketsarin, and Supaporn Kiattisin, “Machine Learning Techniques for Classifying the Sweetness of Watermelon Using Acoustic Signal and Image Processing”, *Computers and Electronics in Agriculture*, Vol. 181, February 2021, p. 105938.
- Deng, Limiao, Juan Li, and Zhongzhi Han, “Online Defect Detection and Automatic Grading of Carrots Using Computer Vision Combined with Deep Learning Methods”, *LWT*, Vol. 149, September 1, 2021, p. 111832.
- Díaz, Edenio Olivares, Haruka Iino, Kento Koyama, Shuso Kawamura, Shigenobu Koseki, and Suxing Lyu, “Non-Destructive Quality Classification of Rice Taste Properties Based on near-Infrared Spectroscopy and Machine Learning Algorithms”, *Food Chemistry*, Vol. 429, December 15, 2023, p. 136907.
- Du, Dongdong, Jun Wang, Bo Wang, Luyi Zhu, and Xuezhen Hong, “Ripeness Prediction of Postharvest Kiwifruit Using a MOS E-Nose Combined with Chemometrics”, *Sensors (Basel, Switzerland)*, Vol. 19, No. 2, January 21, 2019, p. 419.
- Fan, Shuxiang, Jiangbo Li, Yunhe Zhang, Xi Tian, Qingyan Wang, Xin He, Chi Zhang, and Wenqian Huang, “On Line Detection of Defective Apples Using Computer Vision System Combined with Deep Learning Methods”, *Journal of Food Engineering*, Vol. 286, December 1, 2020, p. 110102.
- GC, Sunil, Borhan Saidul Md, Yu Zhang, Demetris Reed, Mostofa Ahsan, Eric Berg, and Xin Sun, “Using Deep Learning Neural Network in Artificial Intelligence Technology to Classify Beef Cuts”, *Frontiers in Sensors*, Vol. 2, 2021. <https://www.frontiersin.org/articles/10.3389/fsens.2021.654357>.
- Halac, Delila, Emir Sokic, and Emir Turajlic, “Almonds Classification Using Supervised Learning Methods”, 2017 XXVI International Conference on Information, Communication and

- Automation Technologies (ICAT), 2017, pp. 1–6.  
<https://ieeexplore.ieee.org/document/8171603>.
- Hanh, Le Duc, and Danh Nguyen The Bao, “Autonomous Lemon Grading System by Using Machine Learning and Traditional Image Processing”, *International Journal on Interactive Design and Manufacturing (IJIDeM)*, Vol. 17, No. 1, February 1, 2023, pp. 445–452.
- Hong Son, Nguyen, and Nguyen Thai-Nghe, “Deep Learning for Rice Quality Classification”, 2019 International Conference on Advanced Computing and Applications (ACOMP), 2019, pp. 92–96. <https://ieeexplore.ieee.org/document/9044217>.
- Islam Monzurul, Wahid Khan, Dinh Anh “Assessment of Ripening Degree of Avocado by Electrical Impedance Spectroscopy and Support Vector Machine”, n.d. <https://www.hindawi.com/journals/jfq/2018/4706147/>.
- K, Thilagavathi, M. Mohamed Sharafath, S. Abimanyu, and K Naveen, “Disease Detection in Orange Fruit Using Machine Learning Techniques”, 2023 2nd International Conference on Advancements in Electrical, Electronics, Communication, Computing and Automation (ICAECA), 2023, pp. 1–6. <https://ieeexplore.ieee.org/document/10200184>.
- Koyama, Kento, Marin Tanaka, Byeong-Hyo Cho, Yusaku Yoshikawa, and Shige Koseki, “Predicting Sensory Evaluation of Spinach Freshness Using Machine Learning Model and Digital Images”, *PloS One*, Vol. 16, No. 3, 2021, p. e0248769.
- Lashgari, Majid, Abdullah Imanmehr, and Hamed Tavakoli, “Fusion of Acoustic Sensing and Deep Learning Techniques for Apple Mealiness Detection”, *Journal of Food Science and Technology*, Vol. 57, No. 6, June 1, 2020, pp. 2233–2240.
- Lumogdang, Christell Faith D., Marianne G. Wata, Stephone Jone S. Loyola, Randy E. Angelia, and Hanna Leah P. Angelia, “Supervised Machine Learning Approach for Pork Meat Freshness Identification”, *Proceedings of the 6th International Conference on Bioinformatics Research and Applications, ICBRA '19*, Association for Computing Machinery, New York, NY, USA, 2020, pp. 1–6. <https://doi.org/10.1145/3383783.3383784>.
- Manjubargavi, S, and J Subhashini, “Quality Analysis of Tomato for Ketchup Manufacturing Industry Using Deep Learning”, 2023 International Conference on Recent Advances in Electrical, Electronics, Ubiquitous Communication, and Computational Intelligence (RAEEUCCI), 2023, pp. 1–5. <https://ieeexplore.ieee.org/abstract/document/10134207>.
- Mia, Md Jueal, Syeda Khadizatul Maria, Shahrin Siddique Taki, and Al Amin Biswas, “Cucumber Disease Recognition Using Machine Learning and Transfer Learning”, *Bulletin of Electrical Engineering and Informatics*, Vol. 10, No. 6, December 1, 2021, pp. 3432–3443.

- Munera, Sandra, Juan Gómez-Sanchís, Nuria Aleixos, Joan Vila-Francés, Giancarlo Colelli, Sergio Cubero, Esteban Soler, and José Blasco, "Discrimination of Common Defects in Loquat Fruit Cv. 'Algerie' Using Hyperspectral Imaging and Machine Learning Techniques", *Postharvest Biology and Technology*, Vol. 171, January 1, 2021, p. 111356.
- Nandi, Chandra Sekhar, Bipan Tudu, and Chiranjib Koley, "A Machine Vision-Based Maturity Prediction System for Sorting of Harvested Mangoes", *IEEE Transactions on Instrumentation and Measurement*, Vol. 63, No. 7, July 2014, pp. 1722–1730.
- Ni, Jiangong, Jiyue Gao, Juan Li, Haoyan Yang, Zheng Hao, and Zhongzhi Han, "E-AlexNet: Quality Evaluation of Strawberry Based on Machine Learning", *Journal of Food Measurement and Characterization*, Vol. 15, No. 5, October 2021, pp. 4530–4541.
- Pacheco, Wolfgang D. Nino, and Fabian R. Jimenez Lopez, "Tomato Classification According to Organoleptic Maturity (Coloration) Using Machine Learning Algorithms K-NN, MLP, and K-Means Clustering", 2019 XXII Symposium on Image, Signal Processing and Artificial Vision (STSIVA), IEEE, Bucaramanga, Colombia, 2019, pp. 1–5. <https://ieeexplore.ieee.org/document/8730232/>.
- Park, Hajun, and Muhammad Umer Khan, "Convolution Neural Network (CNN) Based Automatic Sorting of Cherries", 2021 IEEE International Conference on Robotics, Automation and Artificial Intelligence (RAAI), 2021, pp. 1–5. <https://ieeexplore.ieee.org/abstract/document/9508009>.
- Penning, Bryan W., Warren M. Snelling, and M. Jennifer Woodward-Greene, "Machine Learning in the Assessment of Meat Quality", *IT Professional*, Vol. 22, No. 3, May 2020, pp. 39–41.
- Pise, Dnyaneshwari, and G. D. Upadhye, "Grading of Harvested Mangoes Quality and Maturity Based on Machine Learning Techniques", 2018 International Conference on Smart City and Emerging Technology (ICSCET), IEEE, Mumbai, 2018, pp. 1–6. <https://ieeexplore.ieee.org/document/8537342/>.
- Rajbongshi, Aditya, Md Ezharul Islam, Md Jueal Mia, Tahsin Islam Sakif, and Anup Majumder, "A Comprehensive Investigation to Cauliflower Diseases Recognition: An Automated Machine Learning Approach", *International Journal on Advanced Science, Engineering and Information Technology*, Vol. 12, No. 1, January 21, 2022, p. 32.
- Ribeiro, Michele N, Iago A Carvalho, Gabriel A Fonseca, Rafael C Lago, Lenízy CR Rocha, Danton D Ferreira, Eduardo VB Vilas Boas, and Ana CM Pinheiro, "Quality Control of Fresh Strawberries by a Random Forest Model", *Journal of the Science of Food and Agriculture*, Vol. 101, No. 11, 2021, pp. 4514–4522.
- Ropelewska, Ewa, Ahmed M. Rady, and Nicholas J. Watson, "Apricot Stone Classification Using Image Analysis and Machine Learning", *Sustainability*, Vol. 15, No. 12, January 2023, p. 9259.

- Sabilla, Irzal Ahmad, Cahyaningtyas Sekar Wahyuni, Chastine Fatichah, and Darlis Herumurti, “Determining Banana Types and Ripeness from Image Using Machine Learning Methods”, 2019 International Conference of Artificial Intelligence and Information Technology (ICAIIIT), 2019, pp. 407–412. <https://ieeexplore.ieee.org/document/8834490>.
- Sánchez, M. G., Veronica Miramontes-Varo, J. Abel Chocoteco, and V. Vidal, “Identification and Classification of Botrytis Disease in Pomegranate with Machine Learning”, in Kohei Arai, Supriya Kapoor, and Rahul Bhatia (eds.), *Intelligent Computing, Advances in Intelligent Systems and Computing*, Springer International Publishing, Cham, 2020, pp. 582–598.
- Sharma, Richa, Arpit Agarwal, and Hr Mamatha, “Classification of Carrots Based on Shape Analysis Using Machine Learning Techniques”, 2021 Third International Conference on Intelligent Communication Technologies and Virtual Mobile Networks (ICICV), IEEE, Tirunelveli, India, 2021, pp. 1407–1411. <https://ieeexplore.ieee.org/document/9388520/>.
- Sharmin, Israt, Nuzhat Farzana Islam, Israt Jahan, Tasnem Ahmed Joye, Md. Riazur Rahman, and Md. Tarek Habib, “Machine Vision Based Local Fish Recognition”, *SN Applied Sciences*, Vol. 1, No. 12, November 1, 2019, p. 1529.
- Smeesters, L., I. Magnus, M. Virte, H. Thienpont, and W. Meulebroeck, “Potato Quality Assessment by Monitoring the Acrylamide Precursors Using Reflection Spectroscopy and Machine Learning”, *Journal of Food Engineering*, Vol. 311, December 1, 2021, p. 110699.
- Su, Qinghua, Naoshi Kondo, Dimas Firmanda Al Riza, and Harshana Habaragamuwa, “Potato Quality Grading Based on Depth Imaging and Convolutional Neural Network”, *Journal of Food Quality*, Vol. 2020, November 23, 2020, p. e8815896.
- Sun, Xin, Jennifer Young, Jeng-Hung Liu, and David Newman, “Prediction of Pork Loin Quality Using Online Computer Vision System and Artificial Intelligence Model”, *Meat Science*, Vol. 140, June 1, 2018, pp. 72–77.
- Taheri-Garavand, Amin, Amin Nasiri, Ashkan Banan, and Yu-Dong Zhang, “Smart Deep Learning-Based Approach for Non-Destructive Freshness Diagnosis of Common Carp Fish”, *Journal of Food Engineering*, Vol. 278, August 2020, p. 109930.
- Truong Minh Long, Nguyen, and Nguyen Truong Thinh, “Using Machine Learning to Grade the Mango’s Quality Based on External Features Captured by Vision System”, *Applied Sciences*, Vol. 10, No. 17, August 20, 2020, p. 5775.
- Van De Looverbosch, Tim, Md. Hafizur Rahman Bhuiyan, Pieter Verboven, Manuel Dierick, Denis Van Loo, Jan De Beenbouwer, Jan Sijbers, and Bart Nicolai, “Nondestructive Internal Quality Inspection of Pear Fruit by X-Ray CT Using Machine Learning”, *Food Control*, Vol. 113, July 1, 2020, p. 107170.

Wang, Aojie, and Jiangming Zhao, "Moldy Garlic Recognition Based on Machine Vision", 2021 3rd International Academic Exchange Conference on Science and Technology Innovation (IAECST), 2021, pp. 772–776. <https://ieeexplore.ieee.org/document/9695700>.

Yudhana, Anton, Rusydi Umar, and Sabarudin Saputra, "Fish Freshness Identification Using Machine Learning: Performance Comparison of k-NN and Naïve Bayes Classifier", *Journal of Computing Science and Engineering*, Vol. 16, No. 3, September 30, 2022, pp. 153–164.

### **Tecniche e algoritmi applicati nei processi di trasformazione:**

Aghbashlo, Mortaza, Mohammad Hossein Kianmehr, Tayyeb Nazghelichi, and Shahin Rafiee, "Optimization of an Artificial Neural Network Topology for Predicting Drying Kinetics of Carrot Cubes Using Combined Response Surface and Genetic Algorithm", *Drying Technology*, Vol. 29, No. 7, June 1, 2011, pp. 770–779.

Aguilera Puerto, Daniel, Óscar Cáceres Moreno, Diego Manuel Martínez Gila, Juan Gómez Ortega, and Javier Gámez García, "Online System for the Identification and Classification of Olive Fruits for the Olive Oil Production Process", *Journal of Food Measurement and Characterization*, Vol. 13, No. 1, March 1, 2019, pp. 716–727.

Azarmdel, Hossein, Seyed Saeid Mohtasebi, Ali Jafari, and Alfredo Rosado Muñoz, "Developing an Orientation and Cutting Point Determination Algorithm for a Trout Fish Processing System Using Machine Vision", *Computers and Electronics in Agriculture*, Vol. 162, July 1, 2019, pp. 613–629.

Bakhshipour, Adel, Alireza Sanaeifar, Sayed Hossein Payman, and Miguel de la Guardia, "Evaluation of Data Mining Strategies for Classification of Black Tea Based on Image-Based Features", *Food Analytical Methods*, Vol. 11, No. 4, April 1, 2018, pp. 1041–1050.

Bowler Alexander, Escrig Josep, Pound Micael "Fermentation | Free Full-Text | Predicting Alcohol Concentration during Beer Fermentation Using Ultrasonic Measurements and Machine Learning", n.d. <https://www.mdpi.com/2311-5637/7/1/34>.

Giovenzana Valentina, Roberto Beghi, Roberto Romaniello, Antonia Tamborrino, Riccardo Guidetti, and Alessandro Leone, "Use of Visible and near Infrared Spectroscopy with a View to On-Line Evaluation of Oil Content during Olive Processing", *Biosystems Engineering*, Vol. 172, August 1, 2018, pp. 102–109.

Gonzalez Viejo Claudia, Fuentes Sigfredo "Chemosensors | Free Full-Text | Digital Detection of Olive Oil Rancidity Levels and Aroma Profiles Using Near-Infrared Spectroscopy, a Low-Cost Electronic Nose and Machine Learning Modelling", n.d. <https://www.mdpi.com/2227-9040/10/5/159>.

- Hendrawan, Y., L. C. Hawa, and R. Damayanti, "Fish Swarm Intelligent to Optimize Real Time Monitoring of Chips Drying Using Machine Vision", IOP Conference Series: Earth and Environmental Science, Vol. 131, No. 1, March 2018, p. 012020.
- Huang Xiao, Yongbin Li, Xiang Zhou, Jun Wang, Qian Zhang, Xuhai Yang, Lichun Zhu, and Zhihua Geng, "Prediction of Apple Slices Drying Kinetic during Infrared-Assisted-Hot Air Drying by Deep Neural Networks", Foods, Vol. 11, No. 21, January 2022, p. 3486.
- Jin Ge, Yujie Wang, Luqing Li, Shanshan Shen, Wei-Wei Deng, Zhengzhu Zhang, and Jingming Ning, "Intelligent Evaluation of Black Tea Fermentation Degree by FT-NIR and Computer Vision Based on Data Fusion Strategy", LWT, Vol. 125, May 1, 2020, p. 109216.
- Kimutai Gibson, Alexander Ngenzi, Rutabayiro Ngoga Said, Ambrose Kiprop, and Anna Förster, "An Optimum Tea Fermentation Detection Model Based on Deep Convolutional Neural Networks", Data, Vol. 5, No. 2, June 2020, p. 44.
- Liang Gaozhen, Chunwang Dong, Bin Hu, Hongkai Zhu, Haibo Yuan, Yongwen Jiang, and Guoshuang Hao, "Prediction of Moisture Content for Congou Black Tea Withering Leaves Using Image Features and Nonlinear Method", Scientific Reports, Vol. 8, No. 1, May 18, 2018, p. 7854.
- Loddo Andrea, Cecilia Di Ruberto, Giuliano Armano, and Andrea Manconi, "Automatic Monitoring Cheese Ripeness Using Computer Vision and Artificial Intelligence", IEEE Access, Vol. 10, 2022, pp. 122612–122626.
- Martínez Gila, Diego M., Elisabet Estévez Estévez, Juan Gómez Ortega, and Javier Gámez García, "Application of a Lab-Made Voltammetric Electronic Tongue to Identify Musty and Vinegary Defects in Olive Oils", Journal of Food Measurement and Characterization, Vol. 17, No. 2, April 1, 2023, pp. 1402–1412.
- Misimi Ekrem, Elling Ruud Øye, Øystein Sture, and John Reidar Mathiassen, "Robust Classification Approach for Segmentation of Blood Defects in Cod Fillets Based on Deep Convolutional Neural Networks and Support Vector Machines and Calculation of Gripper Vectors for Robotic Processing", Computers and Electronics in Agriculture, Vol. 139, June 15, 2017, pp. 138–152.
- Morelle Eric, Alexander Rudolph, Christopher McHardy, and Cornelia Rauh, "Detection and Prediction of Foam Evolution during the Bottling of Noncarbonated Beverages Using Artificial Neural Networks", Food and Bioprocess Processing, Vol. 128, July 1, 2021, pp. 63–76.
- Nazghelichi Tayyeb, Mohammad Hossein Kianmehr, and Mortaza Aghbashlo, "Prediction of Carrot Cubes Drying Kinetics during Fluidized Bed Drying by Artificial Neural Network", Journal of Food Science and Technology, Vol. 48, No. 5, October 1, 2011, pp. 542–550.

- Nirere Adria, Jun Sun, Vincent Akolbire Atindana, Ahmad Hussain, Xin Zhou, and Kunshan Yao, "A Comparative Analysis of Hybrid SVM and LS-SVM Classification Algorithms to Identify Dried Wolfberry Fruits Quality Based on Hyperspectral Imaging Technology", *Journal of Food Processing and Preservation*, Vol. 46, No. 3, 2022, p. e16320.
- Ozturk Samet, Alexander Bowler, Ahmed Rady, and Nicholas J. Watson, "Near-Infrared Spectroscopy and Machine Learning for Classification of Food Powders during a Continuous Process", *Journal of Food Engineering*, Vol. 341, March 1, 2023, p. 111339.
- Rahman Md Towfiqur, Sabiha Ferdous, Mariya Sultana Jenin, Tanjina Rahman Mim, Masud Alam, and Muhammad Rashed Al Mamun, "Characterization of Tea (*Camellia Sinensis*) Granules for Quality Grading Using Computer Vision System", *Journal of Agriculture and Food Research*, Vol. 6, December 1, 2021, p. 100210.
- Ren Yuqiao, and Da-Wen Sun, "Monitoring of Moisture Contents and Rehydration Rates of Microwave Vacuum and Hot Air Dehydrated Beef Slices and Splits Using Hyperspectral Imaging", *Food Chemistry*, Vol. 382, July 15, 2022, p. 132346.
- Sabzevari Masumeh, Nasser Behroozi-Khazaei, and Hosain Darvishi, "Real-Time Evaluation of Artificial Neural Network-Developed Model of Banana Slice Kinetics in Microwave-Hot Air Dryer", *Journal of Food Process Engineering*, Vol. 44, No. 9, 2021, p. e13796.
- Teimouri Nima, Mahmoud Omid, Kaveh Mollazade, Hossein Mousazadeh, Reza Alimardani, and Henrik Karstoft, "On-Line Separation and Sorting of Chicken Portions Using a Robust Vision-Based Intelligent Modelling Approach", *Biosystems Engineering*, Vol. 167, March 1, 2018, pp. 8–20.
- Xie Tianhua, Xinxing Li, Xiaoshuan Zhang, Jinyou Hu, and Yao Fang, "Detection of Atlantic Salmon Bone Residues Using Machine Vision Technology", *Food Control*, Vol. 123, May 1, 2021, p. 107787.
- Xu Jun-Li, and Da-Wen Sun, "Computer Vision Detection of Salmon Muscle Gaping Using Convolutional Neural Network Features", *Food Analytical Methods*, Vol. 11, No. 1, January 1, 2018, pp. 34–47.
- Zhu Hongkai, Fei Liu, Yang Ye, Lin Chen, Jingyuan Liu, Anhui Gui, Jianqiang Zhang, and Chunwang Dong, "Application of Machine Learning Algorithms in Quality Assurance of Fermentation Process of Black Tea-- Based on Electrical Properties", *Journal of Food Engineering*, Vol. 263, December 1, 2019, pp. 165–172.

#### **Tecniche e algoritmi applicati nei controlli sul prodotto finito:**

- Abu-Khalaf, Nawaf, "Identification and Quantification of Olive Oil Quality Parameters Using an Electronic Nose", 2021. <https://www.mdpi.com/2077-0472/11/7/674>.

- Feng, Chao-Hui, Yoshio Makino, Masatoshi Yoshimura, and Francisco J. Rodríguez-Pulido, "Estimation of Adenosine Triphosphate Content in Ready-to-Eat Sausages with Different Storage Days, Using Hyperspectral Imaging Coupled with R Statistics", *Food Chemistry*, Vol. 264, October 30, 2018, pp. 419–426.
- Metri-Ojeda, Jorge, Gabriel Solana-Lavalle, Roberto Rosas-Romero, Enrique Palou, Milena-Ramírez-Rodrigues, and Diana Baigts-Allende, "Rapid Screening of Mayonnaise Quality Using Computer Vision and Machine Learning", *Journal of Food Measurement and Characterization*, Vol. 17, No. 3, June 1, 2023, pp. 2792–2804.
- Ordukaya, Emre, and Bekir Karlik, "Quality Control of Olive Oils Using Machine Learning and Electronic Nose", *Journal of Food Quality*, Vol. 2017, October 17, 2017, p. e9272404.
- Pawlak Tomasz, Agnieszka A. Pilarska, Krzysztof Przybył, Jerzy Stangierski, Antoni Ryniecki, Dorota Cais-Sokolińska, Krzysztof Pilarski, and Barbara Peplińska, "Application of Machine Learning Using Color and Texture Analysis to Recognize Microwave Vacuum Puffed Pork Snacks", *Applied Sciences*, Vol. 12, No. 10, January 2022, p. 5071.
- Rasekh, Mansour, and Hamed Karami, "Application of Electronic Nose with Chemometrics Methods to the Detection of Juices Fraud", *Journal of Food Processing and Preservation*, Vol. 45, No. 5, 2021, p. e15432.
- Yu, Xinjie, Xin Yu, Shiting Wen, Jinqiu Yang, and Jianping Wang, "Using Deep Learning and Hyperspectral Imaging to Predict Total Viable Count (TVC) in Peeled Pacific White Shrimp", *Journal of Food Measurement and Characterization*, Vol. 13, No. 3, September 1, 2019, pp. 2082–2094.
- Zhang, Jingjing, Guishan Liu, Yan Li, Mei Guo, Fangning Pu, and Han Wang, "Rapid Identification of Lamb Freshness Grades Using Visible and Near-Infrared Spectroscopy (Vis-NIR)", *Journal of Food Composition and Analysis*, Vol. 111, August 1, 2022, p. 104590.

#### **Tecniche e algoritmi applicati nei controlli sul packaging e stoccaggio:**

- Abdulhamid, Muhammad M., Oluwaseun O. Martins, and Mariam O. Lawal, "Development of a Sequential Neural Network Model for Bottle-Fill Level Detection and Classification | FUOYE Journal of Engineering and Technology", *FUOYE Journal of Engineering and Technology*, Vol. 8, No. 3, September 30, 2023. <https://journal.engineering.fuoye.edu.ng/index.php/engineer/article/view/1077>.
- Anush, Ch, K. Yashwanth, S. Shashank, M. Venkat Reddy, and Ashwani Kumar, "Bottle Line Detection Using Digital Image Processing with Machine Learning", *Journal of Physics: Conference Series*, Vol. 1998, No. 1, August 2021, p. 012033.

- Banús, Núria, Imma Boada, Anton Bardera, and Pol Toldrà, "A Deep-Learning Based Solution to Automatically Control Closure and Seal of Pizza Packages", *IEEE Access*, Vol. 9, 2021, pp. 167267–167281.
- Dalai, Radhamadhab, and Kishore Kumar Senapati, "A Vision Based Smart Multihead Weighing Machine for Automated Food Packager System", 2019 IEEE R10 Humanitarian Technology Conference (R10-HTC)(47129), 2019, pp. 132–137. <https://ieeexplore.ieee.org/document/9042430>.
- Davies, Tazman, Jimmy Chun Yu Louie, Tailane Scapin, Simone Pettigrew, Jason HY Wu, Matti Marklund, and Daisy H. Coyle, "An Innovative Machine Learning Approach to Predict the Dietary Fiber Content of Packaged Foods", *Nutrients*, Vol. 13, No. 9, September 2021, p. 3195.
- Deshmukh, Pramod B., Vishakha A. Metre, and Rahul Y. Pawar, "Calorimeter: Food Calorie Estimation Using Machine Learning", 2021 International Conference on Emerging Smart Computing and Informatics (ESCI), 2021, pp. 418–422. <https://ieeexplore.ieee.org/document/9397023>.
- Kerry, J. P., M. N. O'Grady, and S. A. Hogan, "Past, Current and Potential Utilisation of Active and Intelligent Packaging Systems for Meat and Muscle-Based Products: A Review", *Meat Science*, Vol. 74, No. 1, September 2006, pp. 113–130.
- Li, Luqing, Jing Huang, Yujie Wang, Shanshan Jin, Menghui Li, Yemei Sun, Jingming Ning, Quansheng Chen, and Zhengzhu Zhang, "Intelligent Evaluation of Storage Period of Green Tea Based on VNIR Hyperspectral Imaging Combined with Chemometric Analysis", *Infrared Physics & Technology*, Vol. 110, November 1, 2020, p. 103450.
- Ma, Peihua, An Li, Ning Yu, Ying Li, Rahul Bahadur, Qin Wang, and Jaspreet K. Ahuja, "Application of Machine Learning for Estimating Label Nutrients Using USDA Global Branded Food Products Database, (BFPD)", *Journal of Food Composition and Analysis*, Vol. 100, July 1, 2021, p. 103857.
- Razavi, Rouzbeh, and Guisen Xue, "Predicting Unreported Micronutrients From Food Labels: Machine Learning Approach", *Journal of Medical Internet Research*, Vol. 25, No. 1, April 12, 2023, p. e45332.
- Sanaeifar, Alireza, Abdolabbas Jafari, and Mohammad-Taghi Golmakani, "Fusion of Dielectric Spectroscopy and Computer Vision for Quality Characterization of Olive Oil during Storage", *Computers and Electronics in Agriculture*, Vol. 145, February 1, 2018, pp. 142–152.
- Shi, Ce, Jianping Qian, Wenying Zhu, Huan Liu, Shuai Han, and Xinting Yang, "Nondestructive Determination of Freshness Indicators for Tilapia Fillets Stored at Various Temperatures by Hyperspectral Imaging Coupled with RBF Neural Networks", *Food Chemistry*, Vol. 275, March 1, 2019, pp. 497–503.

Siripatrawan, Ubonrat, and Yoshio Makino, "Simultaneous Assessment of Various Quality Attributes and Shelf Life of Packaged Bratwurst Using Hyperspectral Imaging", *Meat Science*, Vol. 146, December 1, 2018, pp. 26–33.

Yang, Dong, Dandan He, Anxiang Lu, Dong Ren, and Jihua Wang, "Detection of the Freshness State of Cooked Beef During Storage Using Hyperspectral Imaging", *Applied Spectroscopy*, Vol. 71, No. 10, October 1, 2017, pp. 2286–2301.

Zheng, Xiaochun, Yankun Peng, and Wenxiu Wang, "A Nondestructive Real-Time Detection Method of Total Viable Count in Pork by Hyperspectral Imaging Technique", *Applied Sciences*, Vol. 7, No. 3, March 2017, p. 213.

#### **Altri riferimenti bibliografici citati nel testo:**

Aggarwal, Alankrita, Mamta Mittal, and Gopi Battineni, "Generative Adversarial Network: An Overview of Theory and Applications", *International Journal of Information Management Data Insights*, Vol. 1, No. 1, April 1, 2021, p. 100004.

AI Index Report 2023 – Artificial Intelligence Index", n.d. <https://aiindex.stanford.edu/report/>.

Alfayoumi, Shereen, Neamat Eltazi, and Amal Elgammal, "AI-Driven Optimization Approach Based on Genetic Algorithm in Mass Customization Supplying and Manufacturing", *International Journal of Advanced Computer Science and Applications (IJACSA)*, Vol. 14, No. 11, 2023. <https://thesai.org/Publications/ViewPaper?Volume=14&Issue=11&Code=IJACSA&SerialNo=106>.

Applied Artificial Intelligence Aims and Scope, Taylor & Francis, <https://www.tandfonline.com/action/journalInformation?show=aimsScope&journalCode=uaai20>.

Chhetri Krishna Bahadur. "Applications of Artificial Intelligence and Machine Learning in Food Quality Control and Safety Assessment." *Food Engineering Reviews* (2023): 1-21.

DeepMind's Protein-Folding AI Has Solved a 50-Year-Old Grand Challenge of Biology | MIT Technology Review", n.d. <https://www.technologyreview.com/2020/11/30/1012712/deepmind-protein-folding-ai-solved-biology-science-drugs-disease/>.

Doherty, Aoife, Audrey Wall, Nora Khaldi, and Martin Kussmann, "Artificial Intelligence in Functional Food Ingredient Discovery and Characterisation: A Focus on Bioactive Plant and Food Peptides", *Frontiers in Genetics*, Vol. 12, November 19, 2021, p. 768979.

- Domingo Mery, Franco Pedreschi, and Alvaro Soto. "Automated design of a computer vision system for visual food quality evaluation." *Food and Bioprocess Technology* 6 (2013): 2093-2108.
- European Commission Coordinated Plan on Artificial Intelligence 2021 Review. Available online: <https://digital-strategy.ec.europa.eu/en/library/coordinated-plan-artificial-intelligence-2021-review> (accessed on 27 April 2021).
- European Commission. Directorate-General for Research, Functional Foods, Publications Office, LU, 2010. <https://data.europa.eu/doi/10.2777/82512>.
- Faisal Karim Shaikh , Mohsin Ali Memon, and Naeem Ahmed Mahoto, Sherali Zeadally, Jamel Nebhen, Artificial Intelligence Best Practices in Smart Agriculture," in *IEEE Micro*, vol. 42, no. 1, pp. 17-24, 1 Jan.-Feb. 2022, doi: 10.1109/MM.2021.3121279
- Godfray, H.C.J.; Beddington, J.R.; Crute, I.R.; Haddad, L.; Lawrence, D.; Muir, J.F.; Pretty, J.; Robinson, S.; Thomas, S.M.; Toulmin, C. Food security: The challenge of feeding 9 billion people. *Science* 2010, 327, 812–818
- Gonzalez Fischer, C., and T. Garnett, *Plates, Pyramids, Planet: Developments in National Healthy and Sustainable Dietary Guidelines: A State of Play Assessment*, FAO, Rome, Italy, 2016. <https://www.fao.org/documents/card/en/c/d8dfeaf1-f859-4191-954f-%20e8e1388cd0b7/>.
- Gutiérrez P, Godoy SE, Torres S, Oyarzún P, Sanhueza I, DíazGarcía V, Contreras-Trigo B, Coelho P (2020) Improved antibiotic detection in raw milk using machine learning tools over the absorption spectra of a problem-specific nanobiosensor. *Sensors (Switzerland)* 20(16):1–13. <https://doi.org/10.3390/s20164552>
- Hassan Mohammad, Nor Aida Binti Abdul Wahab, and Rahman Bin Mohd Nor. "The role of artificial intelligence in waste reduction in the beverage industry: a comprehensive strategy for enhanced sustainability and efficiency." *AI, IoT and the Fourth Industrial Revolution Review* 13.11 (2023): 1-8.
- Institute for Prospective Technological Studies (Joint Research Centre), Alexander J. Stein, and Emilio Rodríguez-Cerezo, *Functional Food in the European Union*, Publications Office of the European Union, LU, 2008. <https://data.europa.eu/doi/10.2791/21607>.
- Kollia Ilianna, Jack Stevenson, and Stefanos Kollias. "Ai-enabled efficient and safe food supply chain." *Electronics* 10.11 (2021): 1223.
- Lila Manish Kumar, "Integration of Artificial Intelligence Techniques in Mechatronic Systems for Smart Manufacturing", *Mathematical Statistician and Engineering Applications*, Vol. 70, No. 1, January 31, 2021, pp. 432–439.
- McKinsey, 2019, "How AI can unlock a \$127B opportunity by reducing food waste"

- Mihai Mutascu. Artificial intelligence and unemployment: New insights. *Economic Analysis and Policy*, 2021, 69, pp.653-667
- Neilenko Sergii and Rusavska Valentyna, "Implementation of Artificial Intelligence in Restaurants", *Restaurant and Hotel Consulting. Innovations*, Vol. 4, No. 1, June 22, 2021, pp. 73–86.
- Nethani Shivakumar, Lingala Sivaranjani, Marrapu Aswini Kumar, Bechoo Lal, and Mohit Tiwari, "Recognition and Integration of AI with IoT for Innovative Decision Making Techniques in Cyber Physical Systems", 2023 Second International Conference on Augmented Intelligence and Sustainable Systems (ICAISS), August 23, 2023, pp. 190–195.
- Nutrition and Health. The Issue Is Not Food, nor Nutrients, so Much as Processing | Public Health Nutrition|Cambridge Core", n.d. <https://www.cambridge.org/core/journals/public-healthnutrition/article/nutrition-and-health-the-issue-is-not-food-nor-nutrients-so-much-as-processing/0C514FC9DB264538F83D5D34A81BB10A>.
- Olayah Fekry, Ebrahim Mohammed Senan, Ibrahim Abdulrab Ahmed, and Bakri Awaji, "AI Techniques of Dermoscopy Image Analysis for the Early Detection of Skin Lesions Based on Combined CNN Features", *Diagnostics*, Vol. 13, No. 7, January 2023, p. 1314.
- Pérez-Gomariz, Mario, Antonio López-Gómez, and Fernando Cerdán-Cartagena. "Artificial neural networks as artificial intelligence technique for energy saving in refrigeration systems—A review." *Clean Technologies* 5.1 (2023): 116-136.
- Plathottam Siby Jose, Arin Rzonca, Rishi Lakhnori, and Chukwunwike O. Iloeje, "A Review of Artificial Intelligence Applications in Manufacturing Operations", *Journal of Advanced Manufacturing and Processing*, Vol. 5, No. 3, 2023, p. e10159.
- Schwartz, Reva, Apostol Vassilev, Kristen Greene, Lori Perine, Andrew Burt, and Patrick Hall, *Towards a Standard for Identifying and Managing Bias in Artificial Intelligence*, National Institute of Standards and Technology (U.S.), Gaithersburg, MD, March 15, 2022. <https://nvlpubs.nist.gov/nistpubs/SpecialPublications/NIST.SP.1270.pdf>.
- Sharma Sanjay, and Sanjaysingh Vijaysingh Patil. "Key indicators of rice production and consumption, correlation between them and supply-demand prediction." *International Journal of Productivity and Performance Management* 64.8 (2015): 1113-1137.
- Solomonoff Ray J. "The time scale of artificial intelligence: Reflections on social effects." *Human Systems Management* 5.2 (1985): 149-153.
- Svanberg Maja S, Wensu Li, Martin Fleming, Brian C Goehring, and Neil C Thompson, "Beyond AI Exposure: Which Tasks Are Cost-Effective to Automate with Computer Vision?", 2023
- Swati Dilip Kale, Shailaja C. Patil, "Quality Estimation of Perishebles in Cold Chain Network using Machine Learning: A New Approach", ISSN No:-2456-2165

Tomas Norton, and Brijesh K. Tiwari. "Sustainable cleaning and sanitation in the food industry." *Sustainable Food Processing* (2013): 363-376.

Vaswani, Ashish, et al. "Attention is all you need." *Advances in neural information processing systems* 30 (2017).

Xiaoxuan Li et al. "Recent Advance of Intelligent Packaging Aided by Artificial Intelligence for Monitoring Food Freshness." *Foods* 12.15 (2023): 2976.

Zhu Lili, et al. "Deep learning and machine vision for food processing: A survey." *Current Research in Food Science* 4 (2021): 233-249.

Zhuk A., "Artificial Intelligence Impact on the Environment: Hidden Ecological Costs and Ethical Legal Issues" *Journal of Digital Technologies and Law*, Vol 1, No. 4, December 15, 2023, pp. 932-954

