UNIVERSITÀ DEGLI STUDI DI PADOVA

Dip. Territorio e Sistemi Agro-Forestali

Corso di laurea in

Scienze e Tecnologie Alimentari

Sviluppo di un sistema di visione artificiale per il controllo qualità nel processo di essiccazione delle mele

Relatore:
Prof. Lorenzo Guerrini

Correlatore:
Dr. Alessandro Zanchin

Laureando:
Juan Ignacio Carullo
Matricola n° 2073344

Anno Accademico 2024 - 2025

SOMMARIO

RIASSUNTO 4
ABSTRACT 5
CAPITOLO 1: INTRODUZIONE 6
1.0 INTRODUZIONE 6
1.1 IL PRESENTE LAVORO 7
CAPITOLO 2: ESSICCAZIONE DEI PRODOTTI ALIMENTARI 8
2.0 PROCESSO DI ESSICCAZIONE 8
2.1 BASI FISICHE ED IMPIANTISTICHE 8
2.2 QUALITÀ ED ANALISI DELLE MELE ESSICCATE 9
2.2.1 Analisi microbiologiche 9
2.2.2 Analisi fisico-chimiche 9
2.2.3 Analisi sensoriali 10
2.3 DESCRIZIONE DEL PRESENTE LAVORO 10
CAPITOLO 3: SENSORISTICA NEI PROCESSI ALIMENTARI 11
3.0 TECNICHE DI MONITORAGGIO 11
3.1 IMPORTANZA DEL CONTROLLO DEL PROCESSO DI ESSICCAZIONE 1011
3.2 SENSORI PER MONITORARE L'ESSICCAZIONE 12
3.2.1 Telecamere a colori ad alta risoluzione 12
3.2.2 Telecamere multispettrali 13
3.2.3 Telecamere iperspettrali 13
3.2.4 Sensori 3D su tecnologia laser scanner o fotogrammetria stereoscopica 13
3.2.5 Sensori a ultrasuoni 14
3.3 TECNICHE DI MONITORAGGIO 14
3.3.1 Monitoraggio visivo e analisi di immagine 14
3.3.2 Termografia 15
3.3.3 Sistemi laser 3D 15
3.3.4 Spettroscopia NIR 15
3.3.5 Tecniche fotoacustiche 16
CAPITOLO 4: DIGITALIZZAZIONE E INTELLIGENZA ARTIFICIALE 17
4.0 SOFTWARE 17
4.1 APPLICAZIONI DIGITALI 17
4.1.1 Analisi dell'immagine 18
4.1.2 Intelligenza artificiale per l'analisi della forma 19

4.2 DIFFERENZA TRA SEGMENTAZIONE ED IDENTIFICAZIONE DEGLI OGGETTI 19
4.3 INDICI MORFOLOGICI ESTRAIBILI GRAZIE ALL'ANALISI DI IMMAGINE 20
CAPITOLO 5: MATERIALI E METODI 21
5.0 MATERIALI E METODI 21
5.1 DESCRIZIONE ESSICCAZIONE MELINDA 21
5.2 CAMPIONAMENTO DI FETTE DI MELA 22
5.3 ALLENAMENTO DEL MODELLO DI IA 23
5.4 VALUTAZIONE DEL MODELLO DI IA 26
CAPITOLO 6: RISULTATI E DISCUSSIONI 27
6.0 RISULTATI 27
6.1 I MODELLI ALLENATI 29
6.2 IDENTIFICAZIONE DELLE ROTTURE DI FETTE DI MELA 33
6.3 ALTRI PARAMETRI ANALIZZATI 36
6.4 MAL FUNZIONAMENTO DELLE MACCHINE E CRITICITÀ DELL'IMPIANTO 38
6.5 SOLUZIONI 39
CAPITOLO 7: CONCLUSIONI 40
BIBLIOGRAFIA 42
SITOGRAFIA 44

RIASSUNTO

Nel cuore di una linea produttiva, ogni millimetro e ogni secondo, significano efficienza, qualità e convenienza. Questa tesi ha affrontato una delle sfide più delicate della trasformazione agroalimentare: riconoscere ed identificare attraverso la visione artificiale, il momento e la percentuale di non conformità del prodotto durante un processo di essiccazione di fette di mela. Non si tratta solo di qualità visiva, ma di comprendere, attraverso dati oggettivi, le dinamiche ignote che portano alla rottura delle mele, compromettendo la qualità del prodotto finale. Il lavoro è stato svolto all'interno dell'azienda Melinda Lab Società Agricola A R.L. (Cles, TN), dove è stato testato un sistema di intelligenza artificiale in grado di analizzare immagini reali scattate in sette punti strategici della linea di essiccazione. Ogni scatto è stato etichettato con cura, ogni elemento classificato in base alla sua forma, struttura e condizione. Il modello, addestrato su questo dataset, è stato poi utilizzato per riconoscere fette rotte e deformate, fornendo in tempo reale una valutazione dell'idoneità del prodotto. L'analisi statistica dei risultati ha messo in luce punti critici della linea, in particolare i passaggi tra alcune sezioni dell'impianto e il momento dello scarico finale, evidenziando il legame diretto tra l'architettura meccanica e il tasso di rottura osservato. L'integrazione del sistema ha dimostrato non solo la fattibilità tecnica dell'approccio, ma anche il suo potenziale nel rivelare ciò che sfugge allo sguardo umano: pattern nascosti, fragilità ricorrenti, effetto dovuto alla varietà e lotto di mela, se compresi, possono guidare miglioramenti concreti. Questa tesi non propone una soluzione definitiva, ma apre una finestra su un modo diverso di osservare la produzione: più consapevole, più preciso, più intelligente.

ABSTRACT

At the heart of a production line, every millimetre and every second stands for efficiency, quality, and economic value. This thesis addresses one of the most delicate challenges in agri-food processing: detecting and identifying, through machine vision, the timing and rate of product non-conformity during the drying process of apple slices. This is not merely about visual quality, but about understanding, through objective data, the hidden dynamics that lead to product breakage, ultimately compromising the final quality. The work was carried out within the company Melinda Lab Società Agricola A.R.L. (Cles, TN), where an artificial intelligence system was tested to analyse real images taken at seven strategic points along the apple drying line. Each image was carefully labelled, and every element was classified according to its shape, structure, and condition. The model, trained on this dataset, was then used to detect broken or deformed slices, providing real-time evaluations of product conformity. Statistical analysis of the results highlighted critical points within the production flow, particularly at the transitions between certain sections of the machinery and the final discharge stage, revealing a direct correlation between mechanical design and the observed breakage rate. The integration of the system demonstrated not only the technical feasibility of the approach, but also its potential to uncover what often escapes the human eye: hidden patterns, recurring weaknesses, and effects related to variety and batch of apples, which, when properly understood, can guide concrete improvements. This thesis does not claim to offer a definitive solution, but rather opens a window onto a new way of observing production: more conscious, more precise, more intelligent.

CAPITOLO 1

INTRODUZIONE

1.0 INTRODUZIONE

La mela (Malus domestica) è uno dei frutti più coltivati e consumati a livello globale, simbolo di tradizione agricola ma anche di innovazione nella trasformazione alimentare. In Italia, la produzione melicola rappresenta un comparto strategico del settore ortofrutticolo, con aree vocate come la Val di Non e la Val di Sole, dove operano realtà cooperative altamente specializzate, tra cui il consorzio Melinda. Le mele raccolte possono essere destinate al consumo fresco o trasformate in una molteplicità di prodotti: succhi, puree, composte, barrette, snack e frutta essiccata. Proprio l'essiccazione rappresenta una tecnica di conservazione antica ma oggi largamente ottimizzata, in grado di prolungare la shelf-life del prodotto riducendo il contenuto di acqua libera, responsabile dello sviluppo microbico e dell'instabilità chimica.

Il prodotto finale dell'essiccazione, comunemente in forma di rondelle o cubetti, mantiene in buona parte le caratteristiche nutrizionali della mela fresca, risultando leggero, stabile, ricco di fibre e privo di additivi. Per garantire la qualità di questi prodotti, è però necessario un controllo accurato durante le fasi di lavorazione, specialmente in quelle più critiche come la fase termica. Difetti strutturali o cromatici, quali rotture, annerimenti o deformazioni, possono compromettere l'integrità e la commerciabilità del prodotto finito, rendendo essenziale l'impiego di strumenti di monitoraggio avanzato.

Negli ultimi anni, l'evoluzione tecnologica ha favorito la diffusione di sistemi digitali ad alta efficienza anche in ambito agroindustriale. L'incremento della potenza computazionale, la riduzione dei costi di GPU e CPU, e la disponibilità sempre maggiore di algoritmi open-source per l'analisi delle immagini, hanno reso l'intelligenza artificiale (IA) uno strumento accessibile per molte aziende. L'introduzione di tecnologie come la visione artificiale, il machine learning e le reti neurali convoluzionali ha rivoluzionato le modalità di ispezione, selezione e controllo qualità, permettendo analisi in tempo reale con livelli di precisione sempre più elevati.

È in questo scenario che si inserisce il presente elaborato, il quale approfondisce il ruolo dell'intelligenza artificiale applicata al monitoraggio morfologico delle fette di mela durante il processo di essiccazione, con l'obiettivo di supportare l'industria nella transizione verso un controllo qualità sempre più automatizzato, affidabile e intelligente.

1.1 IL PRESENTE LAVORO

È proprio sul monitoraggio della conformità delle fette di mela che si concentra il presente lavoro: il momento esatto in cui si spezzano, si frantumano, ed il prodotto finale si allontana dagli standard. Il tasso di rottura, fino ad oggi sottovalutato o trattato solo empiricamente, si rivela, attraverso un'analisi rigorosa, una chiave interpretativa fondamentale per comprendere le criticità del processo di essiccazione.

Il progetto ha previsto l'implementazione di un sistema avanzato di riconoscimento automatizzato del prodotto, basato su tecniche di segmentazione delle istanze mediante intelligenza artificiale (IA), integrato in un software sviluppato appositamente per l'impianto produttivo dell'azienda Melinda. Questo sistema è stato progettato per operare lungo il nastro trasportatore nella fase immediatamente successiva all'essiccazione, analizzando in tempo reale le immagini acquisite dai prodotti in uscita per determinare la loro idoneità rispetto agli standard aziendali.

Il modello di IA è stato addestrato utilizzando un dataset specificamente strutturato, composto da oltre 200 immagini reali del processo produttivo di mele essiccate fornite dall'azienda. Ogni immagine è stata etichettata manualmente, pixel per pixel, classificando visivamente ogni elemento in base alla forma, alle dimensioni del foro centrale, alla presenza di rotture e all'intensità cromatica. Il sistema, una volta addestrato, è stato impiegato per distinguere tra fette integre e difettose, facilitando una classificazione automatizzata e in tempo reale, con la possibilità di scartare automaticamente i pezzi non conformi.

L'attività di ricerca si è articolata attorno a tre principali obiettivi:

- quantificare l'entità delle rotture durante il processo di essiccazione;
- identificare punti critici dell'impianto per eventuali correzioni o modifiche lungo la linea produttiva;
- valutare i potenziali benefici in termini di efficienza operativa e ottimizzazione logistica derivanti dall'adozione di tale tecnologia.

CAPITOLO 2

ESSICCAZIONE DEI PRODOTTI ALIMENTARI

2.0 PROCESSO DI ESSICCAZIONE

Il processo di essiccazione dei frutti freschi è una tecnica di conservazione che riduce l'umidità interna, prevenendo la crescita microbica e il deterioramento. Oltre a prolungare la shelf-life, preserva nutrienti e caratteristiche organolettiche, sebbene con leggere alterazioni. In generale, la procedura inizia dopo la selezione e la pulizia, dove i frutti vengono privati del torsolo e tagliati in sottili fette per favorire un'essiccazione uniforme. Successivamente, subiscono pretrattamenti, come sbollentatura con getto di vapore o immersione in soluzioni antiossidanti, per mantenere colore e qualità nutrizionale. L'essiccazione avviene in essiccatoi di varia tipologia, tra cui quelli a convezione forzata, a tunnel o solari, operando a temperature tra 40 e 120 °C per favorire l'evaporazione dell'umidità. Una volta raggiunto un livello di umidità tra il 4-6%, i frutti vengono raffreddati, confezionati in atmosfera controllata e stoccati in ambienti freschi e asciutti per garantire la conservazione ottimale.

2.1 BASI FISICHE ED IMPIANTISTICHE

Il processo di essiccazione industriale della frutta si basa su fondamentali principi fisici di trasferimento di calore e di massa, ed è finalizzato alla progressiva riduzione del contenuto di umidità libera nei prodotti vegetali, elemento chiave per garantire la stabilità microbiologica e chimica durante la conservazione. L'umidità viene rimossa attraverso l'applicazione controllata di calore e la ventilazione dell'aria, la quale consente l'evaporazione dell'acqua superficiale e, successivamente, di quella interna, con una ridistribuzione graduale all'interno del tessuto vegetale. Questo processo di evaporazione è fortemente influenzato dall'umidità relativa dell'aria e dalla cosiddetta temperatura a bulbo umido, che rappresenta il limite termodinamico massimo a cui l'acqua può evaporare in presenza di umidità ambientale. Nel pre-essiccatore è possibile operare a temperature più elevate grazie all'aria più secca e al maggiore gradiente termo-igrometrico, il quale favorisce una rapida evaporazione dell'umidità superficiale. Al contrario, nella fase successiva di essiccazione finale, dove il contenuto di umidità del prodotto è già ridotto e il rischio di imbrunimento non enzimatico, causato dalle elevate temperature, è maggiore, si adottano temperature più basse per garantire una disidratazione uniforme e controllata, rispettando al contempo le caratteristiche

sensoriali e strutturali delle fette di mela. Nel caso specifico dell'azienda Melinda, il processo si realizza attraverso un impianto suddiviso in due moduli principali: un pre-essiccatore, dove le temperature operative variano indicativamente tra 110 e 150 °C, e un essiccatore vero e proprio, articolato in camere multiple, nel quale le temperature si mantengono tra i 70 e i 90 °C. Ciascun modulo è dotato di nastri trasportatori che regolano con precisione il tempo di permanenza delle fette di mela, assicurando un trattamento omogeneo lungo tutta la linea. Il riscaldamento dell'aria viene ottenuto mediante l'impiego di olio diatermico mantenuto tra i 170°C e i 180°C, mentre la circolazione dell'aria calda, essenziale per l'efficienza del processo, è garantita da ventole ad alta potenza posizionate strategicamente. Il sistema è inoltre equipaggiato con sonde PT100 per la rilevazione continua di temperatura e umidità in ciascuna camera, nonché con un'interfaccia automatizzata che permette agli operatori di gestire e ottimizzare i parametri termici e temporali di ogni fase del processo.

2.2 QUALITÀ ED ANALISI DELLE MELE ESSICCATE

Nel contesto del controllo qualità delle mele essiccate, vengono eseguite diverse tipologie di analisi al fine di garantire la sicurezza alimentare e la conformità agli standard commerciali. Tra queste, rivestono particolare importanza le analisi microbiologiche, fisico-chimiche e sensoriali.

2.2.1 Analisi microbiologiche

Queste analisi mirano a verificare la presenza di microrganismi potenzialmente dannosi, come muffe e lieviti, che possono svilupparsi durante il processo di disidratazione. Uno studio condotto su campioni di mele essiccate a diverse temperature e tempi di trattamento ha evidenziato l'assenza di tali microrganismi, indicando che il processo termico è efficace nel garantire un prodotto microbiologicamente sicuro (*Ciencia Digital*).

2.2.2 Analisi fisico-chimiche

Le valutazioni fisico-chimiche comprendono la determinazione del contenuto di umidità, dell'attività dell'acqua (Aw) e dei solidi solubili, parametri essenziali per valutare la conservabilità, la texture e la stabilità del prodotto. È noto inoltre che il metodo di essiccazione influisce sul colore delle fette di mela, a causa sia di reazioni enzimatiche iniziali sia di reazioni non enzimatiche (Maillard), responsabili

dell'imbrunimento del tessuto durante il trattamento termico (Hubáčková & Banout, 2017).

2.2.3 Analisi sensoriali

Le prove sensoriali valutano l'accettabilità del prodotto in termini di colore, consistenza e sapore. Uno studio pubblicato su *Polish Journal of Food and Nutrition Sciences* ha dimostrato che l'applicazione di pretrattamenti, come la disidratazione osmotica, il blanching a vapore o l'uso di ultrasuoni, prima dell'essiccazione in microonde-vuoto può migliorare significativamente la qualità sensoriale delle fette di mela. In particolare, tali pretrattamenti favoriscono un colore più gradevole, una dolcezza percepita maggiore e una texture più morbida, risultando più apprezzati dai consumatori rispetto alle fette non trattate (Wang et al., 2019). I consumatori hanno valutato positivamente le fette con colorazione chiara attenuata dall'imbrunimento, moderata succosità e croccantezza contenuta.

2.3 DESCRIZIONE DEL PRESENTE LAVORO

Nel presente progetto, è stata svolta un'attività iniziale di etichettatura manuale degli elementi presenti nelle immagini, fase fondamentale per l'addestramento del modello di intelligenza artificiale. Successivamente, una volta verificato il corretto funzionamento del sistema, sono stati analizzati i dati restituiti dal modello attraverso un foglio di calcolo in cui sono stati elaborati parametri statistici rilevanti rispetto agli obiettivi della ricerca. In particolare, sono state calcolate la frequenza di rottura delle fette di mela, l'individuazione dei punti della filiera in cui si verifica il maggior numero di fratture, i giorni con incidenza più elevata di rotture, la varietà maggiormente soggetta a danneggiamenti, nonché il grado di regolarità geometrica dei fori centrali generati dalla macchina detorsolatrice, tra altri indicatori significativi.

CAPITOLO 3
SENSORISTICA NEI PROCESSI ALIMENTARI

3.0 TECNICHE DI MONITORAGGIO

Il monitoraggio del processo di essiccazione delle mele è un aspetto cruciale per garantire l'efficienza del processo, la qualità del prodotto finale e l'ottimizzazione del consumo energetico, data la complessità dei fenomeni fisici e chimici coinvolti. Tra i principali parametri da monitorare riguardo ai macchinari vi sono la temperatura dell'aria di essiccazione, l'umidità relativa, la velocità del flusso d'aria, la pressione parziale del vapore acqueo e il contenuto di umidità residua del prodotto, tutti elementi che incidono direttamente sulla velocità di evaporazione dell'acqua contenuta nelle matrici cellulari del frutto. Studi sperimentali hanno dimostrato come la riduzione dell'umidità relativa e l'aumento della velocità del flusso d'aria migliorino significativamente l'efficienza del processo e la qualità delle fette essiccate (Djebali et al., 2019). Inoltre, in prove con aria deumidificata e ultrasuoni, è stato osservato che l'aumento della temperatura dell'aria riduce i tempi di essiccazione rendendo il processo più rapido e uniforme (Matys et al., 2021).

Per quanto riguarda le caratteristiche riscontrate nel prodotto, è possibile valutare se mantenere i valori prefissati dei macchinari oppure apportare eventuali modifiche al processo, al fine di rientrare nei parametri qualitativi stabiliti dall'azienda. Appunto in base a tutte queste variabili, esiste il bisogno di controllare le condizioni fisiche desiderate del prodotto una volta finito ogni step della filiera.

3.1 IMPORTANZA DEL CONTROLLO DEL PROCESSO DI ESSICCAZIONE

Il controllo accurato e costante del processo di essiccazione riveste un'importanza fondamentale per garantire l'uniformità e la standardizzazione del prodotto finale, sia tra diversi lotti produttivi che all'interno della stessa confezione. Assicurare che ogni fetta di mela presenti caratteristiche visive e strutturali coerenti, come colore, consistenza, forma e grado di disidratazione, è essenziale non solo per soddisfare i criteri qualitativi richiesti dal mercato, ma anche per rafforzare l'affidabilità del marchio agli occhi del consumatore finale. In particolare, il colore rappresenta un indicatore visivo importante: una tonalità chiara è indice di una buona essiccazione, mentre una colorazione marrone scuro può indicare un'eccessiva ossidazione o un trattamento termico troppo spinto, che compromette la qualità percepita del prodotto.

L’obiettivo principale del processo è quello di raggiungere un contenuto di umidità finale costante e sufficientemente basso, che decreta la fine dell’essiccazione. Nel caso dell’azienda Melinda, ad esempio, il valore target è pari all’1%.

Inoltre, un sistema di controllo in tempo reale consente di intervenire prontamente sull’impianto produttivo in caso di deviazioni rispetto agli standard prefissati. Se i parametri rilevati dopo l’essiccazione risultano non conformi, è possibile regolare tempestivamente le condizioni operative della linea, modificando ad esempio la temperatura, l’umidità, la durata del processo o la velocità del trasporto del prodotto. Questo approccio dinamico permette di correggere gli errori in corso d’opera, evitando sprechi, riducendo gli scarti e migliorando l’efficienza energetica e produttiva dell’intero sistema. Di conseguenza, il processo risulta più affidabile, sostenibile e in grado di produrre risultati qualitativamente omogenei, contribuendo in modo significativo all’ottimizzazione della filiera produttiva.

3.2 SENSORI PER MONITORARE L’ESSICCAZIONE

Nell'industria dell’essiccazione delle mele, l'impiego di sensori avanzati è essenziale per il monitoraggio in tempo reale delle variabili critiche del processo, consentendo di ottimizzare la qualità del prodotto, ridurre gli sprechi energetici e prevenire difetti strutturali o alterazioni indesiderate. L’integrazione di queste tecnologie avanzate nei moderni impianti di essiccazione consente di sviluppare sistemi di controllo adattivo e predittivo basati su intelligenza artificiale e machine learning, in grado di regolare automaticamente i parametri operativi in base ai dati acquisiti. Ciò consente di migliorare la sostenibilità del processo e aumentare l'affidabilità dell'impianto, riducendo la necessità di interventi manuali e di manutenzione non programmata.

3.2.1 Telecamere a colori ad alta risoluzione

Le telecamere a colori ad alta risoluzione sono dispositivi ottici avanzati progettati per acquisire immagini dettagliate con un’elevata fedeltà cromatica, consentendo una rappresentazione accurata delle scene osservate. Grazie a sensori CCD o CMOS di ultima generazione, possono catturare immagini in alta definizione, spesso superiori a 1080p, garantendo qualità e precisione. Alcuni modelli includono ottiche varifocali e illuminatori LED per la visione notturna a colori, aumentando la loro versatilità applicativa. Nelle fasi di selezione e cernita, tali telecamere risultano particolarmente efficaci nell’individuare difetti superficiali, variazioni cromatiche o discrepanze dimensionali, contribuendo così all’automazione e al miglioramento dell’efficienza produttiva. Le immagini elaborate ad alta velocità forniscono informazioni

fondamentali su materiali, forme, geometria e anomalie, ottimizzando il controllo qualità (*Industrial Meeting*).

3.2.2 Telecamere multispettrali

Le telecamere multispettrali sono dispositivi avanzati capaci di acquisire immagini in diverse bande dello spettro elettromagnetico, oltre il visibile, come l'infrarosso e l'ultravioletto, permettendo di ottenere informazioni dettagliate sulla composizione e lo stato degli oggetti osservati. Nel processo produttivo delle mele essiccate, l'impiego di tali telecamere consente di monitorare parametri qualitativi fondamentali, quali il contenuto di umidità, la presenza di difetti superficiali o alterazioni non visibili a occhio nudo, garantendo un controllo qualità più accurato e l'ottimizzazione delle condizioni di essiccazione (*Savgood Technology*).

3.2.3 Telecamere iperspettrali

Le telecamere iperspettrali sono dispositivi avanzati capaci di acquisire immagini in numerose bande spettrali contigue, coprendo un ampio intervallo dello spettro elettromagnetico. Ogni pixel dell'immagine contiene informazioni dettagliate sulla distribuzione spettrale della luce riflessa o emessa dall'oggetto osservato, permettendo di identificare e analizzare le sue caratteristiche chimico-fisiche.

Questi dispositivi consentono il monitoraggio in tempo reale di parametri qualitativi essenziali, quali il contenuto di umidità residua, la presenza di difetti interni non visibili a occhio nudo e l'individuazione precoce di patologie o disturbi fisiologici post-raccolta. L'integrazione di telecamere iperspettrali nelle linee di produzione permette una selezione più accurata dei frutti destinati all'essiccazione, assicurando che solo quelli conformi agli standard qualitativi proseguano nel processo (*CORDIS*).

3.2.4 Sensori 3D su tecnologia laser scanner o fotogrammetria stereoscopica

I sensori 3D basati su laser scanner e fotogrammetria stereoscopica rappresentano strumenti altamente sofisticati per l'acquisizione tridimensionale di oggetti con elevata precisione. I laser scanner 3D, sfruttando la tecnologia LiDAR (Light Detection and Ranging), emettono impulsi laser e calcolano il tempo di ritorno della luce riflessa per determinare posizione e distanza nello spazio, generando una densa nuvola di punti che rappresenta la superficie dell'oggetto con notevole accuratezza. Tale metodo risulta

particolarmente efficace per la ricostruzione dettagliata e per il monitoraggio di variazioni dimensionali (*GP-Radar*).

Parallelamente, la fotogrammetria stereoscopica si basa sull'analisi della parallasse tra immagini acquisite da angolazioni differenti, consentendo di ottenere modelli tridimensionali precisi anche in assenza di emissioni attive. Questa tecnica si dimostra vantaggiosa in contesti in cui è preferibile limitare l'interazione diretta con l'oggetto, come nel caso dell'analisi visiva non invasiva (*GP-Radar*). Rispetto alle camere 2D a colori, i sensori 3D forniscono informazioni aggiuntive fondamentali sulla morfologia e sul volume degli oggetti, consentendo una valutazione più precisa delle deformazioni, delle rotture o delle variazioni dimensionali durante il processo di essiccazione. Questi dati tridimensionali, quindi, arricchiscono l'analisi visiva con parametri quantitativi che non sarebbero rilevabili con la sola acquisizione bidimensionale.

3.2.5 Sensori a ultrasuoni

I sensori a ultrasuoni sono dispositivi che utilizzano onde sonore ad alta frequenza per rilevare la presenza, misurare la distanza o monitorare le caratteristiche di un oggetto senza contatto fisico. Il loro funzionamento si basa sull'emissione di impulsi ultrasonici che, una volta riflessi da un oggetto, vengono rilevati dal sensore stesso; misurando il tempo intercorso tra l'emissione e la ricezione dell'eco, è possibile determinare la distanza dell'oggetto (*Autosen*).

3.3 TECNICHE DI MONITORAGGIO

Nell'industria dell'essiccazione delle mele, l'adozione di tecniche di monitoraggio avanzate è fondamentale per garantire la qualità del prodotto finale e l'efficienza del processo produttivo. Tra queste, spiccano il monitoraggio visivo, la termografia, l'analisi di immagine, i sistemi laser 3D, la spettroscopia nel vicino infrarosso (NIR) e le tecniche fotoacustiche.

3.3.1 Monitoraggio visivo e analisi di immagine

Il monitoraggio visivo delle mele durante il processo di essiccazione, supportato da telecamere ad alta risoluzione, consente di osservare variazioni cromatiche indicative di processi non uniformi o segni di degradazione. La misurazione del colore si è rivelata un metodo efficace per valutare la qualità dei frutti, mentre la termografia ha avuto applicazioni più limitate in questo contesto. Questa tecnologia potrebbe essere integrata nel nostro sistema di controllo: analizzando le immagini scattate subito dopo l'uscita

dall’essiccatoio, il programma confronterà i valori cromatici con i limiti accettabili stabiliti. Qualora i risultati non siano conformi, i prodotti verrebbero scartati e non proseguirebbero lungo la filiera produttiva (Saldaña et al., 2013).

3.3.2 Termografia

La termografia rileva la distribuzione della temperatura di un oggetto attraverso la captazione delle radiazioni infrarosse emesse dalla sua superficie. Gli oggetti più caldi emettono radiazioni a lunghezze d'onda più corte, mentre quelli più freddi a lunghezze d'onda più lunghe. La termocamera raccoglie queste radiazioni e le converte in segnali elettrici, creando un'immagine termica che mostra la temperatura sulla superficie dell'oggetto. Le immagini termiche sono composte da pixel colorati in base alla temperatura, permettendo di visualizzare aree più calde o fredde. La tecnica è non invasiva e non richiede contatto fisico, fornendo informazioni dettagliate sulla temperatura superficiale per identificare anomalie termiche, come ad esempio bruciature, surriscaldamenti localizzati o raffreddamenti anomali che possono indicare malfunzionamenti o condizioni non ottimali nel processo di essiccazione (*Wikipedia*).

3.3.3 Sistemi laser 3D

I sistemi laser 3D sono tecnologie avanzate utilizzate per acquisire la geometria tridimensionale di oggetti o superfici. Funzionano emettendo impulsi di luce laser che colpiscono l'oggetto da rilevare; il sistema calcola il tempo impiegato dal laser per tornare al sensore dopo essere stato riflesso dalla superficie. Questo processo consente di determinare con grande precisione la distanza tra il sensore e i vari punti dell'oggetto, creando una "nuvola di punti" che rappresenta la forma tridimensionale dell'oggetto stesso. I sistemi laser 3D sono utilizzati in una vasta gamma di applicazioni, tra cui la misurazione delle distanze, il controllo qualità, la creazione di modelli 3D per la progettazione, la realtà aumentata e l’ispezione di superfici, oltre alla rilevazione accurata del volume e della morfologia degli oggetti (*CORDIS*).

3.3.4 Spettroscopia NIR

La spettroscopia nel vicino infrarosso (NIR) è una tecnica analitica non distruttiva che sfrutta l'assorbimento specifico della radiazione elettromagnetica nella regione del vicino infrarosso da parte dei legami molecolari presenti in un campione, consentendo la determinazione della sua composizione chimica e di alcune proprietà fisiche.

L'applicazione della spettroscopia NIR permette di monitorare in tempo reale parametri qualitativi fondamentali, quali il contenuto di umidità residua e il grado Brix, che indica la concentrazione di zuccheri solubili (*IRIS Engineering*).

3.3.5 Tecniche fotoacustiche

Le tecniche fotoacustiche rappresentano un metodo analitico avanzato che combina l'assorbimento di radiazione luminosa e la generazione di segnali acustici per l'analisi di composti chimici. Il campione da analizzare viene illuminato con una sorgente luminosa modulata, che assorbe l'energia fornita dalla luce. Questo assorbimento provoca un riscaldamento localizzato all'interno del campione, causando una rapida espansione termica. Tale espansione genera onde acustiche che si propagano attraverso il materiale e che vengono rilevate da sensori specializzati. Il segnale acustico risultante fornisce informazioni dettagliate sulla composizione chimica e sulla concentrazione delle sostanze presenti nel campione, grazie alla relazione tra le proprietà termiche e acustiche del materiale. La tecnica è altamente sensibile e selettiva, consentendo la rilevazione anche di tracce minime di composti bioattivi, come clorofille o carotenoidi, con un'elevata precisione (Hernández-Aguilar et al., 2019).

CAPITOLO 4
DIGITALIZZAZIONE E INTELLIGENZA ARTIFICIALE

4.0 SOFTWARE

Attraverso l'utilizzo della piattaforma online denominata "APEER" e grazie alle immagini acquisite durante il processo produttivo reale, è stato possibile effettuare l'etichettatura manuale delle fotografie e, mediante tecniche di segmentazione degli oggetti, costruire un dataset finalizzato all'addestramento di un sistema di intelligenza artificiale. In particolare, sono stati selezionati ed etichettati i pixel corrispondenti alle diverse categorie rilevanti per l'analisi, tra cui fette di mela intere, fette danneggiate, foro centrale delle fette, frammenti di piccole dimensioni, sfondo, nonché imperfezioni relative alla colorazione e alla geometria del foro.

Durante la fase di addestramento, il modello elabora queste immagini tramite una rete neurale, tipicamente una rete neurale convoluzionale (CNN) nel caso della visione artificiale, e genera delle previsioni. Le CNN sono una tipologia di rete neurale artificiale progettata per analizzare dati strutturati in griglie, come le immagini. Operano attraverso una sequenza di livelli convoluzionali che consentono l'estrazione automatica di caratteristiche rilevanti, permettendo al sistema di riconoscere pattern visivi e di distinguere con elevata accuratezza le diverse classi presenti nei dati visivi non ancora mascherati. Queste previsioni vengono confrontate con le etichette reali attraverso una funzione di perdita (loss function), che quantifica l'errore. Tale errore viene poi minimizzato attraverso un algoritmo di ottimizzazione, solitamente la discesa del gradiente, che aggiorna i pesi dei neuroni nella rete tramite il metodo di backpropagation, come spiegato da *API4AI*.

4.1 APPLICAZIONI DIGITALI

La segmentazione delle immagini, abilitata da tecnologie di intelligenza artificiale e deep learning, rappresenta uno strumento strategico per la digitalizzazione e l'ottimizzazione dei processi nell'industria agroalimentare. Essa trova applicazione, in primo luogo, nel controllo qualità automatizzato: attraverso l'elaborazione visiva avanzata, è possibile rilevare in tempo reale difetti quali ammaccature, alterazioni cromatiche o la presenza di muffe su frutta e verdura, migliorando la precisione e l'uniformità rispetto all'ispezione manuale (Mokhtar et al., 2023).

Un secondo ambito applicativo è la selezione automatica dei prodotti, dove la segmentazione consente di distinguere tra diverse varietà e calibrare la classificazione secondo parametri visivi come dimensione, forma e colore. Ciò assicura confezioni omogenee e migliora la percezione qualitativa da parte del consumatore (*AI4Business*)

Dal punto di vista della tracciabilità e della sicurezza alimentare, la segmentazione contribuisce alla digitalizzazione della filiera produttiva, permettendo il monitoraggio visivo di ciascuna fase della lavorazione e facilitando l'individuazione tempestiva di non conformità o contaminazioni, in linea con le normative vigenti (*EconomyUp*).

Infine, nella cosiddetta agricoltura di precisione, la segmentazione supporta l'automazione robotica in operazioni come la raccolta selettiva, dove è necessario individuare i frutti maturi in modo preciso e rapido, riducendo così i costi operativi e ottimizzando l'impiego delle risorse (*ESG360*).

4.1.1 Analisi dell'immagine

L'analisi dell'immagine è una branca della visione artificiale che si occupa dell'elaborazione e interpretazione automatica di immagini digitali al fine di estrarre informazioni significative. Essa trova applicazione in numerosi settori, dall'industria manifatturiera al controllo qualità, dalla medicina all'agricoltura di precisione, permettendo l'identificazione di oggetti, difetti, forme o cambiamenti in modo sistematico, rapido e ripetibile. Recenti review sottolineano come le tecniche di image segmentation e feature extraction siano ormai consolidate per valutazioni automatizzate su prodotti agricoli (Wasnik et al., 2017).

Nel contesto agroalimentare, l'analisi automatizzata delle immagini rappresenta uno strumento particolarmente efficace per valutare parametri visivi come il colore, la forma, l'integrità strutturale e la presenza di anomalie nei prodotti alimentari, riducendo al minimo l'intervento umano e garantendo una maggiore oggettività nel controllo qualità. In uno studio recente, l'uso di deep learning in combinazione con segmentazione semantica ha permesso accurata rilevazione di difetti su mele, con accuratezze superiori al 90% (Gao et al., 2024).

Nel progetto, l'analisi dell'immagine è stata applicata a diverse varietà di mela, tra cui Golden Delicious e Renetta, per monitorare e valutare le caratteristiche visive e strutturali dei prodotti lungo le fasi del processo produttivo. L'adozione di tecniche di segmentazione avanzate e l'uso di dataset accuratamente annotati hanno permesso di sviluppare modelli in grado di riconoscere in modo automatico e oggettivo elementi chiave quali fette integre, frammenti e imperfezioni, contribuendo così a un controllo

qualità più efficace e standardizzato. Questo approccio fornisce una base solida per l'implementazione di sistemi di monitoraggio in tempo reale e per la successiva ottimizzazione del processo produttivo.

4.1.2 Intelligenza artificiale per l'analisi della forma

La determinazione della forma di un oggetto si basa tipicamente su tecniche avanzate di visione artificiale e apprendimento profondo (deep learning), in particolare tramite l'uso di reti neurali convoluzionali (Convolutional Neural Networks, CNN). Queste reti analizzano le immagini in input scomponendole in livelli gerarchici di caratteristiche: dai bordi e contorni semplici fino a strutture complesse, come la forma complessiva. Durante la fase di addestramento, l'IA viene esposta a un ampio insieme di dati etichettati, in cui le diverse forme sono associate a specifiche classi o caratteristiche. Una volta addestrata, la rete è in grado di riconoscere e classificare automaticamente la forma di nuovi oggetti analizzando la disposizione spaziale dei pixel, le simmetrie, le proporzioni e la topologia dell'immagine. Alcuni algoritmi possono anche calcolare metriche geometriche (come area, perimetro o rapporto tra lunghezza e larghezza) per affinare il processo decisionale. Inoltre, tecniche come la segmentazione semantica o istanziata permettono all'IA di isolare l'oggetto dallo sfondo, facilitando un'analisi più accurata della forma. Questo approccio è essenziale, ad esempio, per distinguere tra un oggetto integro e uno danneggiato, o per rilevare deformazioni strutturali in ambito industriale (Ma et al., 2025).

4.2 DIFFERENZA TRA SEGMENTAZIONE ED IDENTIFICAZIONE DEGLI OGGETTI

La segmentazione e l'identificazione degli oggetti rappresentano due processi fondamentali e distinti nell'ambito dell'elaborazione delle immagini e della visione artificiale, con applicazioni di rilievo in settori quali l'industria agroalimentare, la robotica e il controllo qualità. La segmentazione consiste nella suddivisione di un'immagine in regioni omogenee, ottenuta tramite algoritmi che analizzano caratteristiche come colore, intensità, texture o profondità, allo scopo di isolare le porzioni rilevanti per successive elaborazioni (*ScienceDirect*; Montaño-Campos et al., 2023). Questo processo è essenziale per identificare in modo preciso le aree di interesse, facilitando analisi dettagliate e operazioni automatiche come il controllo qualità nel settore alimentare (*AI4Business* ed *EconomyUp*).

L’identificazione degli oggetti, invece, avviene dopo la segmentazione e consiste nell’assegnazione di una previsione o classe specifica a ciascun oggetto segmentato, utilizzando modelli di apprendimento automatico o reti neurali convoluzionali (CNN) che confrontano le caratteristiche estratte con database di riferimento. Questo passaggio permette di riconoscere la natura degli oggetti, distinguendo, ad esempio, tra prodotti integri o difettosi, e di classificare in modo accurato variabili qualitative come il colore o la qualità (*Ultralytics*).

La distinzione tra segmentazione e identificazione è quindi cruciale: la segmentazione prepara e organizza l’immagine in regioni significative, mentre l’identificazione attribuisce un significato e una categoria agli oggetti isolati, consentendo così una gestione più efficiente e automatizzata dei processi produttivi (*ESG360*).

4.3 INDICI MORFOLOGICI ESTRAIBILI GRAZIE ALL’ANALISI DI IMMAGINE

Come precedentemente menzionato, il software è in grado di analizzare principalmente la forma e le rotture, che sono i parametri fondamentali per determinare l'idoneità del prodotto secondo i criteri stabiliti dall'azienda. Un'analisi cromatografica standardizzata consente di verificare se il prodotto rientra nei limiti definiti come accettabili. Inoltre, attraverso la misurazione della dimensione del foro centrale, del perimetro e dell’area degli elementi, è possibile valutare con maggiore precisione la correttezza e la regolarità della forma del prodotto. Se vengono riscontrati pezzi mancanti, dimensioni anomale o irregolarità geometriche, il sistema è in grado di identificarli, permettendo così di scartare i pezzi non conformi.

CAPITOLO 5
MATERIALI E METODI

5.0 MATERIALI E METODI

Per la realizzazione di questo lavoro di tesi, è stato utilizzato un programma denominato APEER, disponibile online, che ha consentito la previsione delle immagini seguendo la tecnica avanzata di segmentazione. Le immagini utilizzate sono state fornite da uno studente tirocinante del corso STAL, il quale ha collaborato al progetto. Il lavoro è stato condotto principalmente tramite strumenti informatici, in quanto gran parte della ricerca delle basi teoriche e delle metodologie applicative è stata svolta consultando fonti scientifiche e siti web autorevoli e affidabili, garantendo così la solidità e la validità delle informazioni utilizzate nel processo di analisi.

5.1 DESCRIZIONE ESSICCAZIONE MELINDA

Il processo produttivo osservato presso l'azienda si apre con l'approvvigionamento di mele conservate a bassa temperatura (circa 4 °C), provenienti da celle frigorifere dove vengono mantenute in condizioni ottimali dopo la raccolta. Tali mele, generalmente selezionate tra quelle che non rientrano nei requisiti per la vendita diretta, vengono sottoposte a una prima fase di cernita mediante un sistema automatico che le classifica in base alla idoneità delle stesse, garantendo una prima uniformità nel materiale da lavorare.

Figura 1: nastro trasportatore con le mele idonee

Una volta selezionati i frutti idonei per la trasformazione, questi vengono trasferiti a una linea dedicata in cui avviene il detorsolamento e il taglio in fette circolari mediante

attrezzature automatizzate ad alta produttività. Le fette ottenute vengono avviate verso la sezione di essiccazione, che rappresenta il cuore del processo. Essa è composta da due impianti principali di essiccazione termica continua del marchio Hans Binder Maschinenbau, collegati tra loro da un sistema di nastri trasportatori.

Gli impianti, suddivisi in camere successive (una da 5 e l'altra da 10 moduli), sono dotati di sensori di temperatura e umidità (sonde PT100) e di ventilatori ad alta potenza che assicurano una circolazione dell'aria calda omogenea e controllata. Il riscaldamento dell'aria viene effettuato mediante un circuito ad olio diatermico, garantendo la stabilità termica necessaria per un'essiccazione uniforme e graduale. Il processo si articola in due fasi: una pre-essiccazione rapida ad alta temperatura (90–110 °C per circa 20–30 minuti), seguita da un'essiccazione più prolungata e delicata (75–95 °C per oltre tre ore), che consente di ridurre il contenuto di umidità delle fette dal 85% iniziale a valori vicini al 1%.

Il risultato è un prodotto stabile, con un'attività dell'acqua inferiore a 0,4, parametro fondamentale per la conservazione, poiché impedisce lo sviluppo microbico e prolunga la shelf-life senza necessità di conservanti. Al termine del processo, le fette essiccate vengono raffreddate, selezionate e infine confezionate. L'intero sistema è dotato di impianti di lavaggio e sanificazione automatica, che garantiscono l'igiene continua delle linee.

5.2 CAMPIONAMENTO DI FETTE DI MELA

In diverse fasi della produzione, viene prelevato un campione mediante una piccola paletta, al fine di effettuare le analisi corrispondenti e le fotografie per la documentazione del processo, indispensabile per lo svolgimento di questo progetto. Sono stati individuati sette punti di prelievo strategici lungo la linea produttiva dell'azienda Melinda.

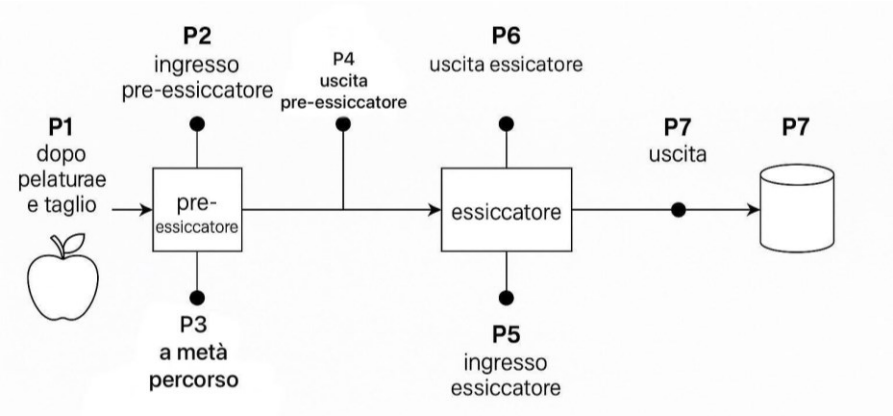

Figura 2: Diagramma di flusso della filiera del processo con i rispettivi punti di prelievo

Il primo punto (P1) è stato collocato immediatamente dopo la fase di pelatura e taglio, quando le fette si presentano ancora fresche, non trattate termicamente e con elevato contenuto di umidità. I successivi punti (P2, P3 e P4) sono stati distribuiti all'interno del pre-essiccatore, rispettivamente all'ingresso, a metà percorso e in uscita, per monitorare gli effetti delle prime fasi di trattamento termico ad alta temperatura e ventilazione forzata. I punti successivi (P5 e P6) sono stati situati lungo il percorso nell'essiccatore vero e proprio, consentendo di osservare le modifiche strutturali progressive durante la fase di essiccazione più prolungata e delicata. Infine, il settimo punto (P7) è stato posizionato alla fine della linea, all'uscita del prodotto essiccato prima dello scarico nel contenitore finale, rappresentando così la condizione del prodotto completato e pronto per il confezionamento. Questa distribuzione dei punti di prelievo ha permesso di documentare con precisione l'evoluzione fisica delle fette in relazione allo stadio del processo e di individuare eventuali criticità meccaniche o termiche associate a ciascuna fase.

Figura 3: fette accumulate alla fine del processo produttivo

5.3 ALLENAMENTO DEL MODELLO DI IA

L'addestramento di un modello di intelligenza artificiale, specialmente nel contesto del riconoscimento di immagini tramite tecniche di apprendimento automatico e deep learning, è un processo articolato che si fonda su una serie di passaggi fondamentali. La base del metodo consiste nell'apprendere una relazione tra input e output attraverso

esempi annotati in un dataset rappresentativo e diversificato, contenente immagini etichettate con precisione (Mitchell, 1997) .

La qualità e l'efficacia del modello dipendono dalla disponibilità di dati puliti, bilanciati e diversificati. Per prevenire l'overfitting, ovvero la tendenza del modello a memorizzare anziché generalizzare i pattern, si utilizza un set di validazione separato dal training, che consente di monitorare la capacità del modello di adattarsi a dati nuovi. Una volta concluso l'addestramento, le performance vengono testate su un set di dati non ancora visto, utilizzando metriche standard come accuratezza, precisione, richiamo (recall) e F1-score (Boesch, 2023) .

È importante sottolineare che «the design of a robust model depends not only on the neural network architecture, but also on the data collection and annotation process, image preprocessing, and the selection of evaluation metrics» (*viso.ai*) .

L'addestramento di un modello IA è un processo iterativo, scientifico e metodico, che richiede una sinergia tra dati di qualità, algoritmi efficienti e costante validazione empirica.

Figura 4: fette di mela tipo Golden delicious fresche

L'immagine 1 raffigura fette di mela della varietà *Golden Delicious* in stato fresco, ovvero non ancora sottoposte al processo di essiccazione. A partire da questa immagine, i diversi elementi verranno etichettati manualmente per l'elaborazione del dataset.

Figura 5: stessa immagine ma etichettata manualmente

L'immagine riportata sopra rappresenta uno degli esempi di etichettatura manuale effettuata tramite il software APEER, con un livello di dettaglio pixel per pixel. In essa, è possibile distinguere visivamente, grazie all'uso di differenti colori, i seguenti elementi:

- **Viola**: fette intere prive di difetti strutturali
- **Celeste**: fori centrali presenti nelle fette intere
- **Rosso**: frammenti o porzioni rotte
- **Arancione**: sfondo dell'immagine

Complessivamente, sono state etichettate manualmente oltre 200 immagini con questa metodologia, al fine di costruire un dataset di riferimento sul quale il modello di intelligenza artificiale potesse essere addestrato e sviluppato per eseguire le sue funzioni di riconoscimento e valutazione automatica.

Esempi dello stesso lavoro fatto con fette di mela Golden delicious già essiccate:

Figura 6

Figura 7

5.4 VALUTAZIONE DEL MODELLO DI IA

La valutazione dei modelli di intelligenza artificiale, soprattutto nel campo della visione artificiale, è essenziale per verificarne l'efficacia e l'affidabilità in scenari reali. Dopo l'addestramento, il modello viene testato su un dataset separato, non visto in fase di training, per misurarne la capacità di generalizzazione (Boesch, 2023).

Le prestazioni si misurano tramite diverse metriche, scelte in base al compito specifico:

- Accuracy: proporzione di previsioni corrette.
- Precision e Recall: qualità e completezza delle predizioni.
- F1-score: bilanciamento tra precision e recall.
- IoU (Intersection over Union) e mAP: fondamentali per il riconoscimento e la localizzazione di oggetti.

Il confronto sistematico tra i risultati ottenuti sul training set e quelli sul validation set rappresenta una fase cruciale per individuare fenomeni di overfitting, ovvero situazioni in cui il modello ha memorizzato eccessivamente i dati di addestramento, perdendo la capacità di generalizzare correttamente su dati nuovi e non visti. Questo comportamento compromette l'efficacia del modello in applicazioni reali e viene monitorato attraverso le curve di apprendimento, che mostrano l'evoluzione dell'errore nel tempo e permettono di identificare con precisione il punto in cui il modello inizia a perdere generalizzazione.

A complemento dell'analisi quantitativa, risulta particolarmente utile condurre anche un'analisi qualitativa delle predizioni errate, la quale consente di individuare specifici contesti in cui il modello presenta difficoltà, come ad esempio in presenza di variazioni di luce, oggetti parzialmente visibili, sovrapposti o deformati, che possono compromettere la coerenza delle previsioni (*API4AI*).

Inoltre, sebbene la validazione incrociata rappresenti uno strumento statistico consolidato per stimare l'affidabilità generale del modello su diversi sottoinsiemi dei dati, nei contesti applicativi reali è imprescindibile procedere con una validazione operativa sul campo, integrando il modello nel processo produttivo per verificarne il comportamento in condizioni dinamiche e variabili, valutandone in tal modo la robustezza, adattabilità e affidabilità nel lungo termine.

CAPITOLO 6
RISULTATI E DISCUSSIONI

6.0 RISULTATI

Di seguito è riportata un'immagine composta a sua volta da 4 fotografie differenti, ciascuna identificata con una lettera.

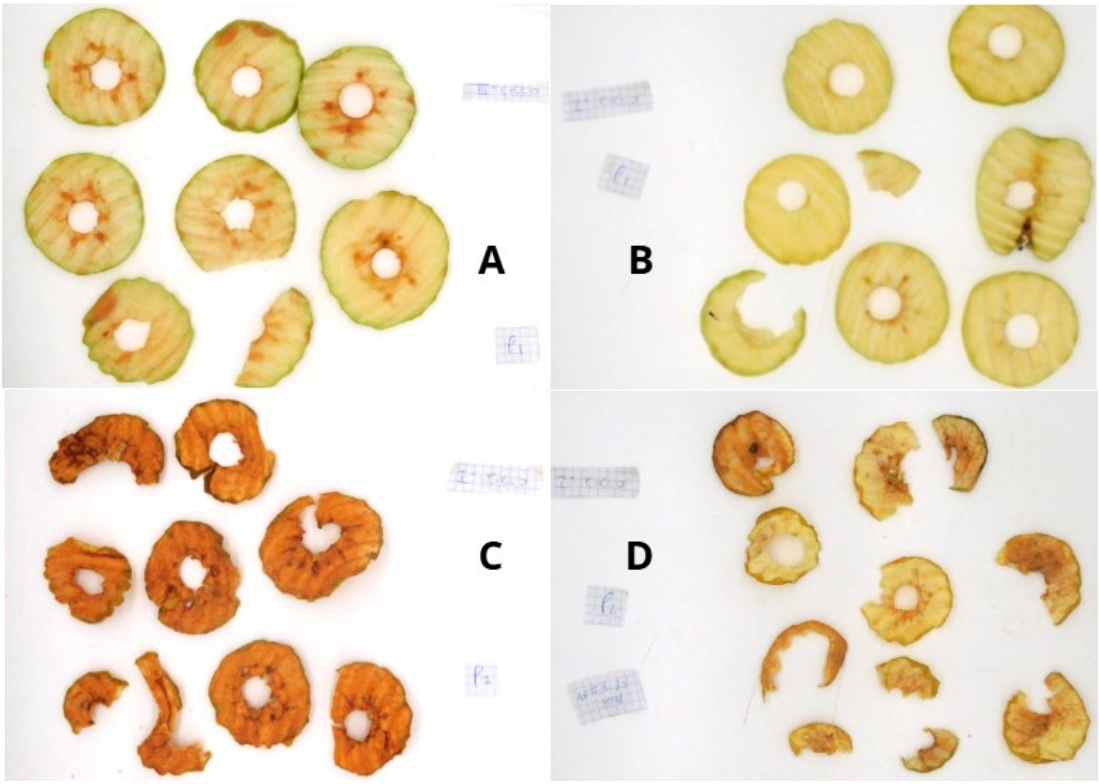

Figura 8: Foto originali delle fette di mela, prima di essere mascherate dal modello.

A: fette fresche di varietà Renetta
B: fette fresche di varietà Golden Delicious
C: fette essiccate di varietà Renetta
D: fette essiccate di varietà Golden Delicious

Come è possibile osservare da un semplice confronto visivo, le varietà Golden Delicious e Renetta presentano una differenza cromatica evidente sia allo stato fresco che dopo l'essiccazione. Si tratta di un aspetto degno di nota, in quanto, nel contesto dell'accettabilità da parte del consumatore, la percezione del colore può influenzare il giudizio sul prodotto: una colorazione più scura, ad esempio, può essere associata a una

qualità organolettica inferiore o a un trattamento eccessivo, con possibili ripercussioni negative sulle vendite e, di conseguenza, sull'economia aziendale.

Successivamente viene presentata un'altra figura, contenente le stesse fotografie ma già mascherate dal modello.

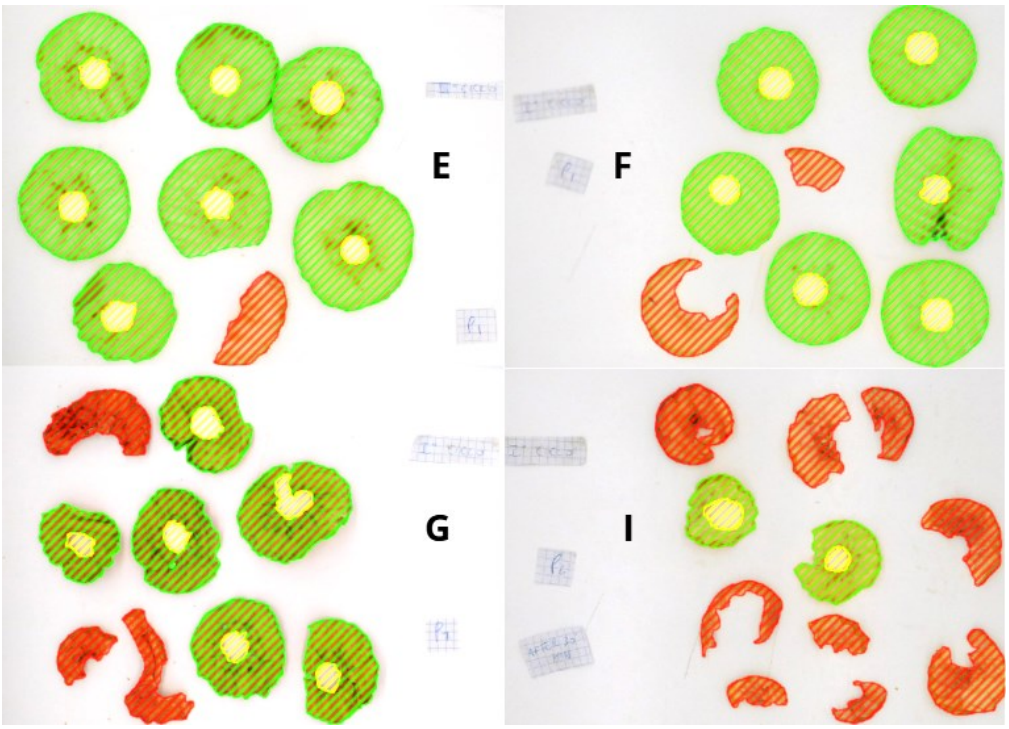

Figura 9: Immagini mascherate dal modello

E: fette fresche di Renetta mascherate dal modello
F: fette fresche di Golden Delicious mascherate dal modello
G: fette essiccate di Renetta mascherate dal modello
I: fette essiccate di Golden Delicious mascherate dal modello

La figura 9 rappresenta la previsione generata automaticamente a partire dalle immagini originali, elaborata dal modello di intelligenza artificiale mediante il software APEER. Quest'ultimo è in grado di identificare con precisione le diverse componenti delle fette, inclusi eventuali frammenti o porzioni danneggiate. Anche in presenza di fette fresche o essiccate, o appartenenti a varietà differenti, il modello svolge il proprio compito in maniera efficace.

È possibile distinguere visivamente, grazie all'uso di differenti colori, i seguenti elementi:

- **Verde**: fette intere prive di difetti strutturali
- **Giallo**: fori centrali presenti nelle fette intere

- **Rosso**: frammenti o porzioni rotte

6.1 I MODELLI ALLENATI

Il modello, in sintesi, opera secondo la seguente modalità: analizza l'immagine originale e attribuisce un valore numerico a ciascun elemento in base alla sua colorazione. Più precisamente, l'immagine viene scomposta in tre livelli distinti. Nel primo, il sistema rileva esclusivamente i frammenti rotti; nel secondo, vengono individuati i fori centrali delle fette; infine, nel terzo livello, si identificano unicamente le fette intere, assegnando a ciascuno un valore specifico secondo la tonalità corrispondente in ogni livello. A seguire, sarà presentato un esempio di tale analisi mediante l'utilizzo del software ImageJ, che consente di visualizzare i valori assegnati a ogni singolo elemento dell'immagine.

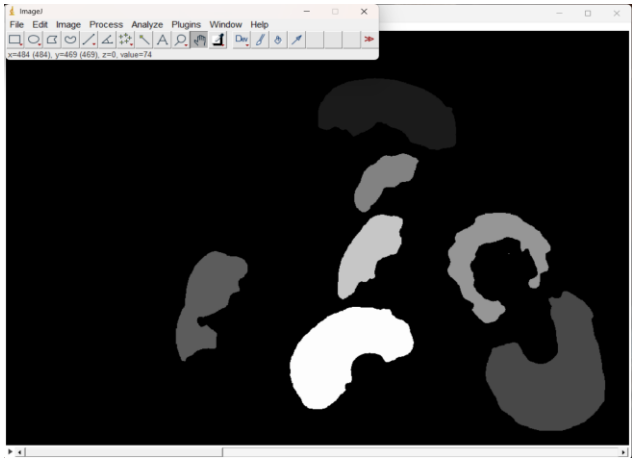

Figura 10: primo livello di analisi, rilevati unicamente i frammenti rotti

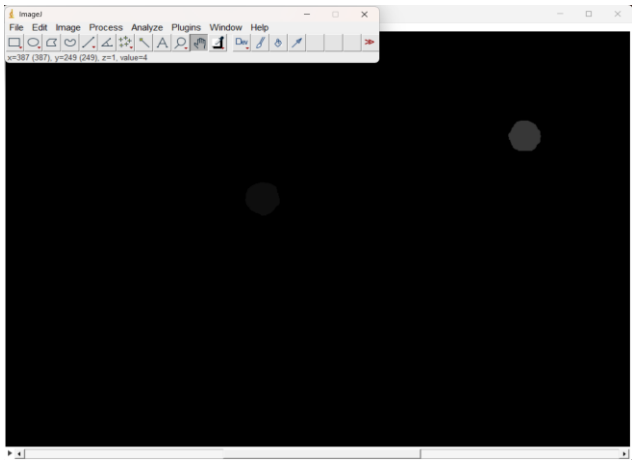

Figura 11: secondo livello di analisi, rilevati unicamente i fori centrali. In questo caso 2.

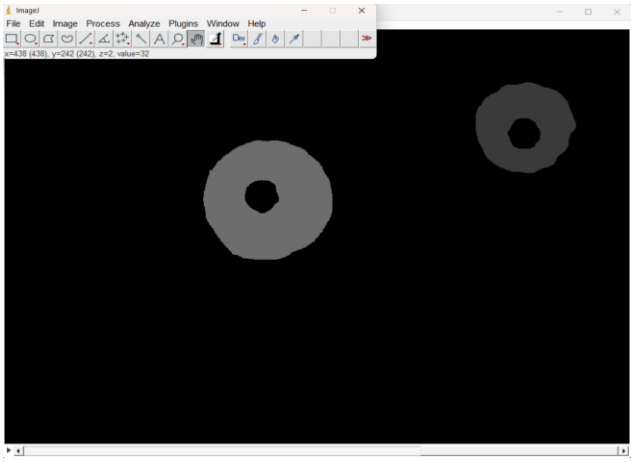

Figura 12: terzo livello di analisi, rilevati esclusivamente le fette intere. 2 in questo caso, la stessa quantità di fori centrali logicamente.

Nelle figure 11, 12 e 13 è possibile osservare in modo chiaro il funzionamento del modello, nonché la variabilità dei valori assegnati a due elementi appartenenti alla medesima categoria, ma differenti nella tonalità cromatica. Prestando attenzione al riquadro in alto a sinistra, si nota la dicitura "value" (valore), che indica il valore attribuito a ciascun elemento; tale informazione viene resa visibile posizionando il cursore del mouse sopra l'area corrispondente.

Grazie a questi file, il modello è in grado di analizzare ulteriori caratteristiche degli elementi una volta che sono stati opportunamente semplificati. Tra queste vi sono l'area, il perimetro, il colore e altri parametri utili, che consentono di estrarre dati statistici rilevanti ai fini dell'analisi e del controllo qualità del processo produttivo.

In modo più preciso, oltre alle immagini "semplificate" in scala di bianco, nero e grigio, è stato generato un file Excel contenente tutte le informazioni rilevanti per ciascun elemento identificato dal sistema in ogni immagine. Il dataset complessivo comprende 5518 elementi distinti, tra cui fette intere, pezzi rotti e fori centrali delle 300 foto approssimativamente analizzate; ciascuno descritto attraverso 38 variabili o categorie numeriche. Sebbene alcune di queste categorie non siano direttamente pertinenti ai fini della nostra analisi, altre risultano invece fondamentali, e su di esse si baserà l'elaborazione dei dati statistici ritenuti più significativi per il nostro obiettivo.

Oltre a tutte queste funzionalità, il software APEER consente di valutare con precisione il livello di accuratezza del modello nella mascheratura automatica delle immagini, confrontandolo con l'etichettatura manuale realizzata pixel per pixel mediante un grafico. In altri termini, permette di misurare quanto le previsioni del modello si avvicinino all'etichettatura di riferimento, fornendo così un importante indicatore della sua affidabilità.

A questo scopo, APEER, come ogni architettura di deep learning, suddivide automaticamente il dataset etichettato in due gruppi distinti: l'80% delle immagini viene utilizzato per l'addestramento del modello ("training set"), mentre il restante 20% è riservato alla fase di test ("test set"). Il modello apprende a riconoscere pattern e caratteristiche dai dati del training set, e successivamente applica le conoscenze acquisite per effettuare previsioni sul test set. In questa fase, il software calcola l'errore di previsione confrontando i risultati generati con le etichette reali, e procede ad ottimizzare i parametri interni finché l'errore non risulta sufficientemente basso. Questo approccio consente di monitorare l'efficacia dell'apprendimento e di visualizzare graficamente l'accuratezza raggiunta, come mostrato nelle figure 13 e 14.

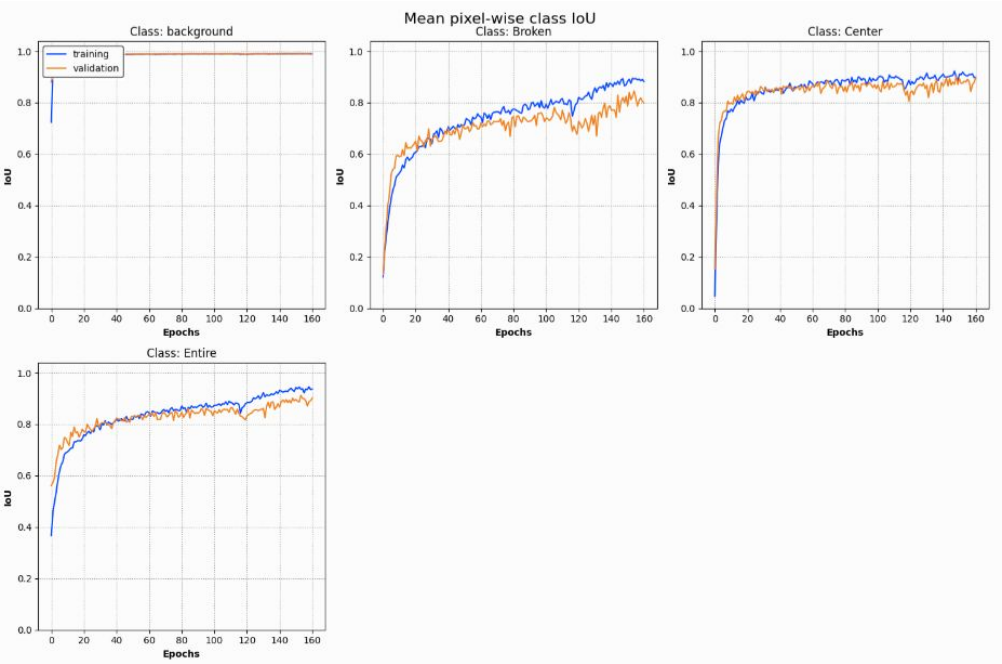

Figura 13: grafici che rappresentano la corrispondenza tra le previsioni del modello (giallo) e le etichette manuali (blu) per sfondo, fette rotte, intere e fori.

L'immagine presentata mostra una serie di grafici che illustrano l'andamento della metrica **IoU** (**Intersection over Union**, menzionato nel punto 5.4) per ciascuna delle quattro classi oggetto di segmentazione nel modello di intelligenza artificiale sviluppato: *sfondo (background)*, *pezzi rotti (broken)*, *centro della fetta (center)* e *fetta intera (entire)*. La metrica IoU rappresenta il grado di sovrapposizione tra la segmentazione prevista dal modello e l'etichettatura di riferimento (manuale), e costituisce un indicatore standard della precisione nei modelli di segmentazione semantica.

Nel primo grafico in alto a sinistra, relativo alla **classe "sfondo"**, si osserva un valore di IoU costantemente prossimo a 1, sia per i dati di addestramento che di validazione, segno di una perfetta distinzione dello sfondo rispetto agli altri elementi, anche fin dalle

prime epoche. Questo risultato era atteso, data la semplicità della classe e il suo elevato contrasto rispetto agli oggetti di interesse.

Nel grafico in alto al centro, riferito alla **classe "pezzi rotti"**, si nota un miglioramento progressivo e regolare delle prestazioni, con valori che partono da livelli medio-bassi e raggiungono IoU superiori a 0,85 nelle ultime epoche. Questa curva conferma che il modello ha impiegato un tempo maggiore per apprendere correttamente i contorni e la variabilità morfologica di questa classe, generalmente più complessa da segmentare.

Il grafico in alto a destra mostra l'IoU per la **classe "centro della fetta"**, con una crescita rapida della precisione già nelle prime epoche, stabilizzandosi poi su valori elevati (oltre 0,9). Questo comportamento indica che la struttura regolare e ricorrente del centro delle fette è stata facilmente appresa dal modello.

Infine, nel grafico in basso, relativo alla **classe "fetta intera"**, si osserva un miglioramento continuo della metrica fino a raggiungere valori prossimi a 0,95. La curva è simile a quella della classe "centro", ma con una leggera maggiore variabilità, probabilmente dovuta alla maggiore diversità in forma e dimensione delle fette intere.

A seguire, l'immagine successiva riprende i concetti già trattati nel punto 5.4, ed è anch'essa estratta dall'insieme dei risultati generati dal modello al fine di valutarne le prestazioni.

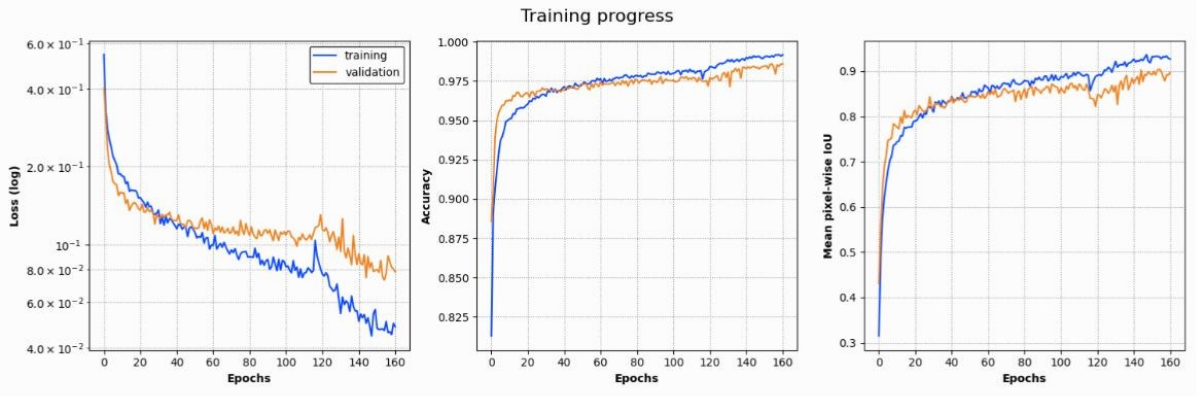

Figura 14: grafici di log, accuracy e IoU.

L'immagine presentata illustra l'andamento delle prestazioni del modello. Il primo grafico a sinistra rappresenta l'evoluzione della funzione di perdita (*funzione di errore logaritmica*) nel corso delle epoche di addestramento, sia per i dati di addestramento (curva gialla) sia per quelli di validazione (curva blu). Si osserva una costante diminuzione del valore di perdita, che riflette un apprendimento efficace e una progressiva riduzione degli errori di previsione da parte del modello. Inoltre, l'assenza di aumenti significativi nella curva di validazione suggerisce che il modello non sta sovradattando (*overfitting*) i dati, mantenendo quindi una buona capacità di generalizzazione.

Il grafico centrale mostra l'accuratezza del modello, intesa come la percentuale di classificazioni corrette a livello di singolo pixel. Le due curve, relative rispettivamente all'addestramento e alla validazione, convergono verso valori prossimi al 98%, a indicare un'alta precisione nel riconoscimento delle diverse componenti dell'immagine.

Il terzo grafico, infine, presenta l'evoluzione dell'indice medio di sovrapposizione (*Indice di Intersezione su Unione*, in inglese *Mean IoU*), una metrica chiave nella segmentazione semantica che misura la sovrapposizione tra le aree previste dal modello e quelle effettivamente etichettate. I valori ottenuti, superiori a 0,9 per entrambe le curve, confermano un'elevata coerenza tra le previsioni automatiche e le annotazioni manuali di riferimento. Questo dimostra la capacità del modello non solo di classificare correttamente, ma anche di delimitare con precisione i contorni e le forme degli oggetti presenti nelle immagini.

6.2 IDENTIFICAZIONE DELLE ROTTURE DI FETTE DI MELA

Dopo un ulteriore lavoro con excel, sono state create tabelle che hanno servito a costruire dei grafici per spiegare ed identificare alcune particolarità del processo, individuate tramite dati statistici.

I seguenti grafici evidenziano quanto frequentemente si trovavano fette intere e rotte nei diversi punti di prelievi (P, che vanno dal 1 al 7) con il loro corrispondente errore standard.

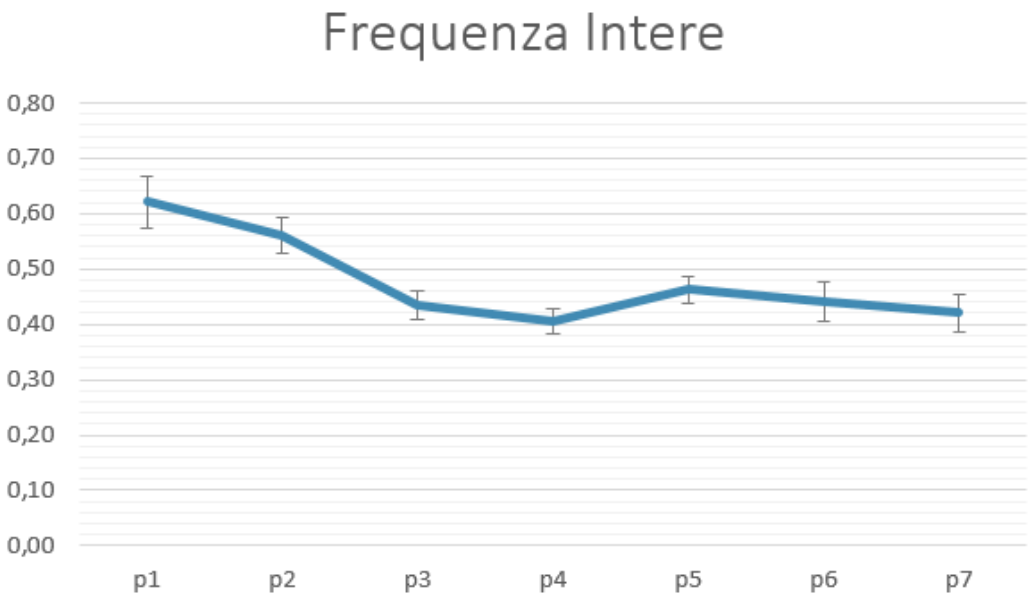

Figura 15: grafico di frequenza di fette intere prelevate nei diversi P.

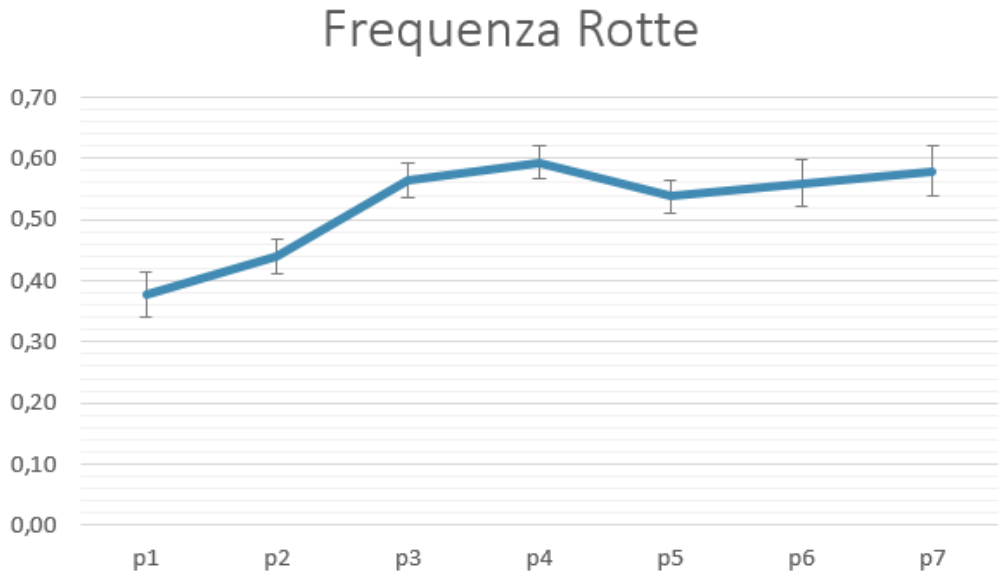

Figura 16: grafico di frequenza di fette rotte prelevate nei diversi P

L'immagine 15 illustra in modo chiaro come le fette intere si trovino con maggior frequenza nei primi due punti di prelievo, mentre con il progredire del processo di essiccazione si registra una riduzione delle stesse. In modo complementare, il grafico seguente evidenzia come la probabilità di riscontrare fette danneggiate aumenti significativamente verso le fasi finali dell'essiccazione. A seguito di questo studio, sorge spontanea la domanda: "Perché?". La risposta risiede nel contenuto di umidità delle fette di mela. All'inizio del processo, il contenuto di umidità è elevato (di solito tra 80-85%) e diminuisce progressivamente lungo la filiera, raggiungendo valori intorno al 15% in fase finale. La riduzione dell'acqua rende le fette notevolmente più fragili e, a causa degli attriti e dei movimenti a cui sono sottoposte, si frammentano con maggiore facilità.

In più, sono stati elaborati altri 3 grafici che esprimono la quantità media di fette rotte trovate in base a diverse variabilità.

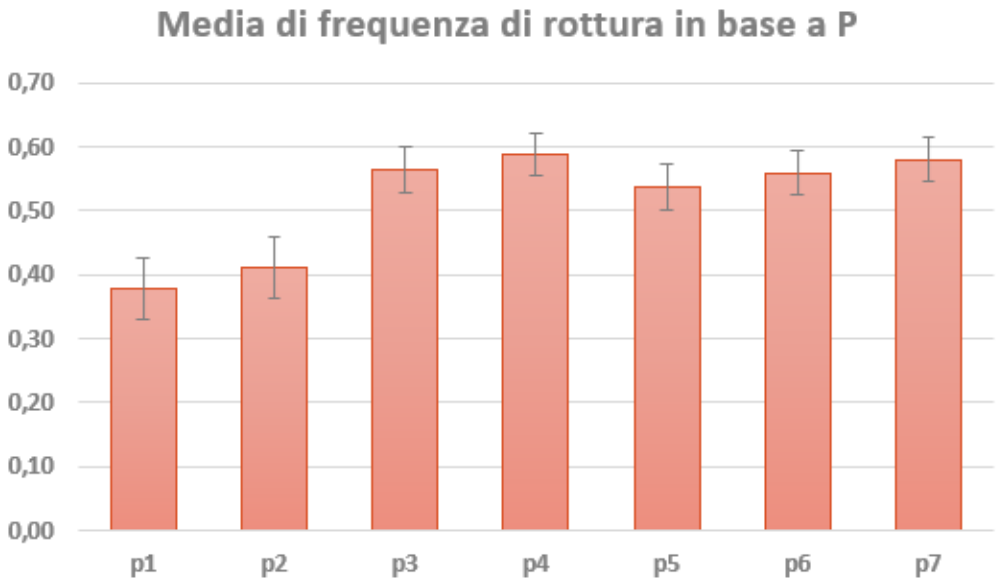

Figura 17: grafico di rotture in base al punto di prelievo (P)

Con questo grafico, rafforziamo il punto menzionato prima, anche se non è lineare è evidente che nei primi 2 punti di prelievo è meno probabile trovarne una fetta rotta che dal punto 3 in avanti. Specificamente, nel punto di prelievo numero 4 si sono riscontrate più fette rotte con quasi un 59% del totale.

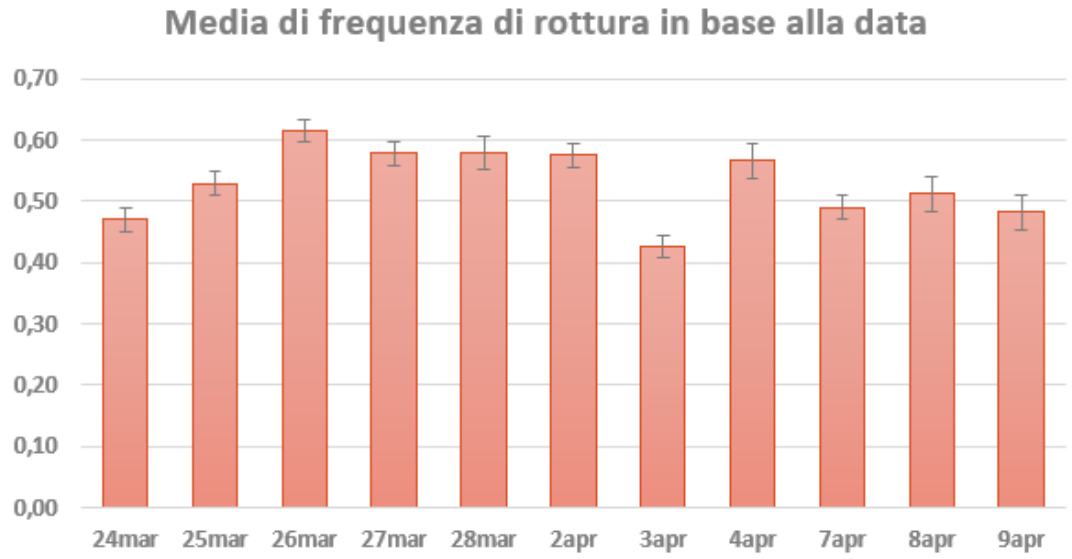

Figura 18: grafico di rotture in base alle date dei campioni

Nel presente grafico è stata analizzata la media delle fette rotte riscontrate nelle diverse date di prelievo dei campioni, con l'obiettivo di individuare eventuali variazioni dovute a difetti tecnici o manuali specifici di quei giorni. In particolare, il 26 marzo è stato registrato il valore più elevato di fette rotte in media, pari a quasi il 62%, mentre il 3 aprile si è rilevato il valore più basso, con circa il 43% di fette rotte mediamente riscontrate.

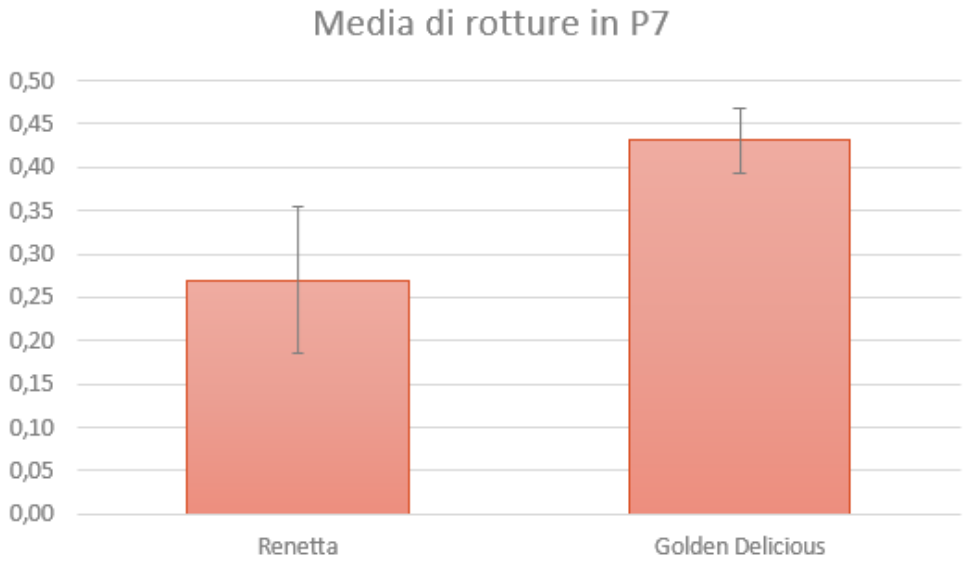

Figura 19: grafico di rotture in base alla varietà di mela nel punto di prelievo finale ovvero p7.

Infine, è stata analizzata l'eventuale differenza nella frequenza di rottura in funzione della varietà di mela. Come si può osservare, la varietà Golden Delicious presenta una media di fette rotte superiore rispetto alla Renetta, con percentuali rispettivamente pari al 54,48% e al 47,66%.

Considerando congiuntamente questi dati, si può presumere che un lotto di mele Golden Delicious prodotto il 26 marzo presenti, al termine del processo, un numero maggiore di fette rotte rispetto a un lotto di mele Renetta lavorato il 3 aprile.

6.3 ALTRI PARAMETRI ANALIZZATI

Un altro parametro analizzato a partire dai dati estratti dal modello è stato la rotondità. Grazie alle informazioni ottenute, è stato possibile costruire un grafico in grado di rappresentare il grado di circolarità delle fette di mela e la frequenza con cui tali valori si manifestano all'interno del campione analizzato.

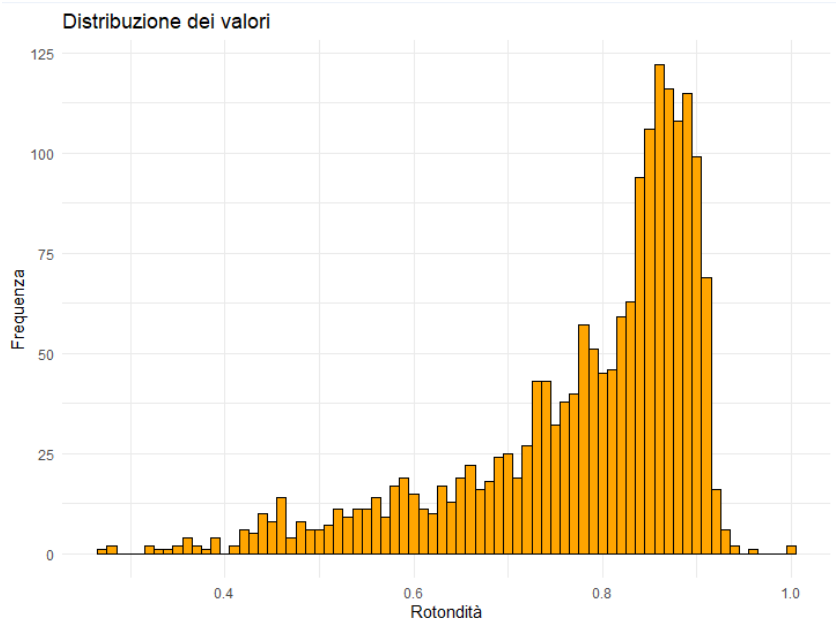

Figura 20: grafico di circolarità

Si osserva una marcata incidenza di valori elevati di rotondità, il che suggerisce che una porzione significativa delle fette ha mantenuto una forma pressoché intatta durante il processo produttivo, oppure che alcuni frammenti rotti presentano comunque una geometria sufficientemente regolare.

Inoltre, è stato analizzato anche il parametro relativo all'area centrale delle fette, espressa in numero di pixel. Tale misura risulta particolarmente interessante, in quanto può offrire indicazioni sul grado di precisione operativa della macchina detorsolatrice nella fase iniziale della linea produttiva, permettendo eventualmente di individuare e correggere imperfezioni meccaniche o disallineamenti funzionali.

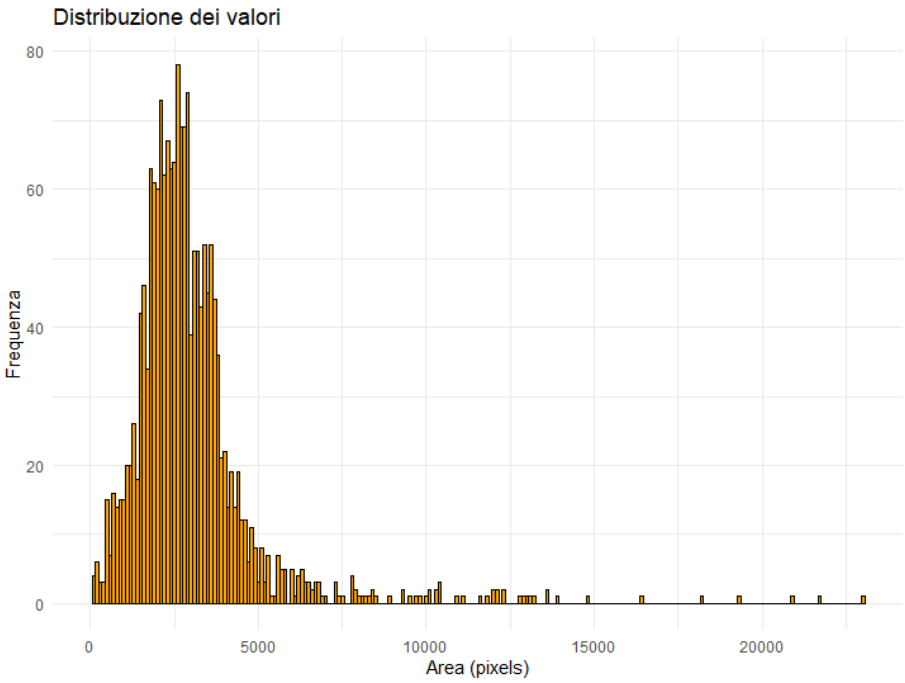

Figura 21: grafico di area dei centri

Come si può osservare, l'area dei centri delle fette risulta complessivamente uniforme, con alcune eccezioni rappresentate da valori anomali che, tuttavia, hanno un'influenza trascurabile dal punto di vista statistico.

6.4 MAL FUNZIONAMENTO DELLE MACCHINE E CRITICITÀ DELL'IMPIANTO

A seguito dell'analisi statistica condotta, sono stati identificati con chiarezza i punti della linea produttiva in cui si verificano con maggiore frequenza le rotture delle fette, e si è cercato di comprenderne le cause. Oltre al fattore dell'umidità, che cala in maniera significativa rendendo le fette più fragili, è stato adottato un approccio orientato allo studio della componentistica meccanica, al fine di individuare eventuali ulteriori elementi determinanti. In un primo momento si è ipotizzato che i parametri impostati nei singoli essiccatoi potessero non essere ottimali, incidendo così negativamente sull'indice di frammentazione delle fette; tuttavia, successivamente sono stati riconosciuti i veri responsabili delle anomalie riscontrate.

In particolare, nel passaggio dal punto di prelievo 3 al punto di prelievo 4 è presente un nastro trasportatore che scarica le fette su un altro nastro, provocando un piccolo salto. Questa differenza di altezza, apparentemente poco significativa, si è rivelata essere la causa principale del maggiore tasso di rottura osservato nel punto 4 rispetto agli altri punti. Inoltre, si è rilevato che al punto finale, ovvero il punto 7, le fette che hanno

completato l'intero processo vengono scaricate in un ampio contenitore dove si accumulano l'una sull'altra; il peso generato dalla sovrapposizione e il movimento dovuto al passaggio dal nastro al contenitore determinano un ulteriore momento critico in cui avvengono rotture.

Inoltre, così come è stato possibile ottenere i dati necessari per analizzare le aree dei centri, tali informazioni potrebbero essere utilizzate a favore di un controllo e una calibrazione più precisi del funzionamento della macchina detorsolatrice, migliorando ulteriormente la standardizzazione del prodotto.

Questa scoperta è stata comunicata all'azienda, che pur conoscendo nel dettaglio la struttura dell'impianto, non disponeva finora di dati statistici e oggettivi in grado di quantificare l'impatto di tali dinamiche sul processo produttivo. Da questo momento in avanti sarà compito dei responsabili aziendali individuare una soluzione tecnica idonea per ridurre le rotture, intervenendo sull'organizzazione delle macchine e sulle modalità di raccolta del prodotto finito.

6.5 SOLUZIONI

Come precedentemente illustrato, il sistema sviluppato ha dimostrato un'elevata precisione nell'individuazione dei risultati, consentendo non solo un'analisi oggettiva delle condizioni delle fette di mela, ma anche l'identificazione dei punti critici del processo produttivo. L'interpretazione dei dati ottenuti ha infatti permesso di individuare le principali cause delle rotture, localizzate in corrispondenza di due momenti specifici della linea: il passaggio tra il punto di prelievo 3 e il punto 4, e la fase conclusiva del processo, ovvero il punto 7. Tali evidenze suggeriscono la necessità di un intervento strutturale o organizzativo sull'impianto per ridurre l'indice di frammentazione nei tratti più delicati della filiera. Al contempo, risulta evidente l'utilità operativa del sistema di intelligenza artificiale proposto in questo elaborato, il quale si conferma come uno strumento valido per facilitare il monitoraggio in tempo reale, segnalare anomalie e supportare le decisioni correttive in maniera più tempestiva. Si ritiene pertanto opportuno promuoverne l'integrazione stabile all'interno del processo produttivo, potenziando il dataset utilizzato con un numero maggiore e più diversificato di immagini, al fine di migliorarne ulteriormente l'accuratezza. L'implementazione ottimale prevederebbe il posizionamento del sistema in punti strategici della linea, ricalcando la logica adottata nella selezione dei punti di prelievo definiti all'inizio del progetto.

CAPITOLO 7
CONCLUSIONI

Al termine di questo percorso progettuale e sperimentale, si può affermare con convinzione che il sistema di intelligenza artificiale sviluppato si è rivelato non solo funzionante, ma estremamente utile nell'ottimizzazione del processo di essiccazione delle mele; pertanto, il giorno in cui l'azienda deciderà di integrarlo nella propria linea produttiva, si potrà registrare un miglioramento concreto delle performance complessive del processo, con un contributo tangibile al rafforzamento del controllo qualità e alla riduzione delle non conformità lungo l'intera filiera. I risultati ottenuti dimostrano che, attraverso una corretta etichettatura dei dati e un addestramento mirato del modello, è possibile monitorare in tempo reale parametri morfologici e difetti strutturali delle fette, individuando con precisione i punti critici della filiera, come emerso chiaramente nei punti di prelievo 3, 4 e 7. Questo lavoro rappresenta solo una piccola, ma concreta, manifestazione del potenziale che le tecnologie digitali e l'intelligenza artificiale possono offrire al settore agroalimentare. In un contesto in cui efficienza, tracciabilità e sostenibilità sono sempre più centrali, strumenti come quello qui proposto aprono la strada a una nuova modalità di gestione dei processi: più intelligente, più reattiva, più consapevole.

Come ulteriori sviluppi futuri si propone l'analisi contemporanea del colore delle fette, integrando tecniche di visione artificiale per una valutazione cromatica precisa e automatizzata, che andrebbe ad arricchire il sistema con un nuovo parametro di controllo qualità. Inoltre, si potrebbe progettare e implementare un sensore dedicato da posizionare direttamente in linea di produzione, capace di acquisire dati in tempo reale senza interrompere il flusso produttivo, migliorando ulteriormente l'efficienza e la reattività del monitoraggio. Altri possibili ampliamenti includono l'integrazione di algoritmi predittivi basati su dati storici per anticipare e prevenire difetti, nonché lo sviluppo di un'interfaccia utente intuitiva per facilitare l'uso e l'interpretazione dei dati da parte degli operatori. Questi potenziali miglioramenti sottolineano come il sistema possa evolvere verso una soluzione sempre più completa, in grado di rispondere alle crescenti esigenze di precisione, sostenibilità e automazione nel settore agroalimentare.

Il sistema descritto non è una soluzione definitiva, ma un punto di partenza: un esempio di come la tecnologia, se guidata da competenza e visione, possa affiancare il lavoro umano, trasformare la quotidianità industriale e contribuire a costruire un futuro produttivo più preciso, automatizzato e, soprattutto, migliorabile. In quest'ottica, si suggerisce anche come possibile evoluzione futura l'integrazione di una funzione di valutazione cromatica del prodotto, che permetterebbe di aggiungere un ulteriore

parametro di controllo e ottenere così un'analisi ancora più completa e affidabile della qualità finale.

È in questa prospettiva che il presente elaborato si colloca, come un piccolo tassello di innovazione in un mondo agricolo che cambia, ma che resta profondamente legato alla qualità, alla cura e alla conoscenza del prodotto.

BIBLIOGRAFIA

Hubáčková, A., & Banout, J. (2017). Clean Foods: *The Inhibitory Effect of Five Natural Juices on the Browning of Apple Slices during Drying*. *Horticulturae*, 3(1), 19. https://doi.org/10.3390/horticulturae3010019 . Consultato nell'aprile 2025.

Wang, Y.Q., Zhao, H.X., Deng, H.W., Song, X., Zhang, W.J., Wu, S.R., & Wang, J. (2019). *Influence of pretreatments on microwave vacuum drying kinetics, physicochemical properties and sensory quality of apple slices*. Polish Journal of Food and Nutrition Sciences, 69(3), 297–306. https://doi.org/10.31883/pjfns/110734 . Consultato nell'aprile 2025.

Djebali, R., Nasri, W., Goodarzi, M., Abbassi, M. A., & Abboudi, S. (2019). *Apple Convective Drying – Part II: Scrutinization of Monitoring Parameters Levels via Taguchi Optimization Approach*. **CFD Letters**, 11(3),42–54. https://www.akademiabaru.com/index.php/archives/article/view/212 Consultato ad aprile 2025.

Matys, A., Wiktor, A., Dadan, M., & Witrowa-Rajchert, D. (2021). *Influence of ultrasound and the conditions of convective drying with dehumidified air on the course of the process and selected properties of apple tissue*. **Foods, 10(8)**, 1840. https://doi.org/10.3390/foods10081840 Consultato a maggio 2025.

Saldaña, E., Quevedo, R., Mendoza, F., Aguilera, J., & Chanona, J. (2013). *Review: Computer vision applied to the inspection and quality control of fruits and vegetables*. Brazilian Journal of Food Technology, 16(4), 254–272. https://doi.org/10.1590/S1981-67232013005000031. Consultato nel maggio 2025.

Hernández-Aguilar, C., Domínguez-Pacheco, A., Cruz-Orea, A., & Tsonchev, R. (2019). *Photoacoustic Spectroscopy in the Optical Characterization of Foodstuff: A Review*. Journal of Spectroscopy, 2019, 1–34. https://doi.org/10.1155/2019/5920948. Consultato nel maggio 2025.

Mokhtar, R. A., et al. (2023). Crop-saving with AI: latest trends in deep learning techniques for plant disease detection. *Frontiers in Plant Science*, 14, 1161835. https://www.ncbi.nlm.nih.gov/pmc/articles/PMC10433211/. Consultato nel maggio 2025.

Wasnik, P. G., Menon, R. R., & Meshram, B. D. (2017). *Digital Image Analysis: Tool for Food Quality Evaluation*. En *Processing Technologies for Milk and Milk Products* (Cap. 2). Apple Academic Press. https://www.taylorfrancis.com/chapters/edit/10.1201/9781315207407-2/digital-image-analysis-tool-food-quality-evaluation-prashant-wasnik-rekha-ravindra-menon-bhushan-meshram Consultato a maggio 2025.

Gao, X., Li, S., Su, X., Li, Y., Huang, L., Tang, W., Zhang, Y., & Dong, M. (2024). *Application of Advanced Deep Learning Models for Efficient Apple Defect Detection and Quality Grading in Agricultural Production*. *Agriculture*, 14(7), 1098. https://doi.org/10.3390/agriculture14071098 Consultato a maggio 2025.

Ma, X., Zhang, Y., & Li, Z. (2025). Deep learning for object recognition: A comprehensive review of models and algorithms. *International Journal of Cognitive Computing in Engineering*, 6, 298–312. https://doi.org/10.1016/j.ijcce.2024.12.010. Consultato nel maggio 2025.

Montaño-Campos, A., et al. (2023). *Image Segmentation in Biomedical Applications: Advances and Challenges*. *Frontiers in Bioengineering and Biotechnology, 11*, Article 9860575. https://doi.org/10.3389/fbioe.2023.9860575. Consultato nel maggio 2025.

Mitchell, T. M. (1997). *Machine Learning*. McGraw-Hill. https://www.cs.cmu.edu/~tom/mlbook.html. Consultato nel maggio 2025

Boesch, G. (2023). *Computer Vision Model Performance Evaluation*. Viso Suite, Viso.ai. https://viso.ai/computer-vision/model-performance. Consultato nel maggio 2025.

SITOGRAFIA

- Industrial Meeting, sezione "Macchine selezionatrici alimentari: Sensori innovativi per la cernita", disponibile su: https://it.industrialmeeting.club/macchine-selezionatrici-alimentari-sensori-innovativi-per-la-cernita

  Consultato ad aprile 2025 (pubblicata il 12 luglio 2022)

- Savgood Technology, sezione "What Does a Multispectral Camera Do?", disponibile su: https://www.savgoodtech.com/it/news/what-does-a-multispectral-camera-do-/

  Consultato ad aprile 2025 (pubblicato nel gennaio 2025).

- European Union, sezione "Revolutionary camera to transform vertical farming and more", disponibile su: https://cordis.europa.eu/article/id/455780-revolutionary-camera-to-transform-vertical-farming-and-more/it

  Consultato ad aprile 2025 (ultimo aggiornamento: 16 gennaio 2025)

- GP-Radar, sezione "3D Laser Scanning Explained", disponibile su: https://www.gp-radar.com/article/3d-laser-scanning-explained

  Consultato a maggio 2025 (pagina pubblicata a inizio 2025, risalente al 2025)

- Autosen GmbH, sezione "Sensori a ultrasuoni", disponibile su: https://autosen.com/it/Sensori-di-Posizione/Sensori-a-ultrasuoni

  Consultato a maggio 2025

- Wikipedia, voce "Termografia", disponibile su: https://it.wikipedia.org/wiki/Termografia

  Consultato a maggio 2025 (ultima modifica: 19 marzo 2025)

- CORDIS, sezione "News e articoli", disponibile su: https://cordis.europa.eu/article/id/428634-laser-focus-on-nutrition-and-efficiency/it

  Consultato a maggio 2025 (ultimo aggiornamento nel dicembre 2020).
- IRIS Engineering, sezione "Analisi gradi Brix delle mele", disponibile su: https://www.iris-eng.com/it/analisi-gradi-brix-delle-mele/

  Consultato a maggio 2025 (pubblicato nel ottobre 2024).

- API4AI, sezione "Deep Learning Basics for Image Processing", disponibile su: https://api4.ai/blog/deep-learning-basics-for-image-processing

  Consultato a maggio 2025 (pubblicato nel 2024).

- AI4Business, sezione "AI e robotica sempre più essenziali per il settore alimentare", disponibile su: https://www.ai4business.it/intelligenza-artificiale/ai-e-robotica-alimentare/

  Consultato a maggio 2025 (pubblicato nel settembre 2022)

- EconomyUp, sezione "Assolombarda e la Bussola 4.0: come trovare la rotta per la trasformazione digitale", disponibile su: https://www.economyup.it/innovazione/assolombarda-e-la-bussola-4-0-come-trovare-la-rotta-per-la-trasformazione-digitale/

  Consultato a maggio 2025 (pubblicato nel febbraio 2023)

- ESG360, sezione "Smart agriculture & Deep Learning", disponibile su: https://www.esg360.it/agrifood/smart-agriculture-deep-learning/

  Consultato a maggio 2025 (pubblicato nel settembre 2020)

- ScienceDirect. (s.d.). *Image segmentation*. Recuperato da: https://www.sciencedirect.com/topics/computer-science/image-segmentation

  Consultato a maggio 2025.

- Ultralytics. *Everything You Need to Know About Computer Vision in 2025*. Recuperato da: https://www.ultralytics.com/es/blog/everything-you-need-to-know-about-computer-vision-in-2025

  Consultato a maggio 2025 (pubblicato nel gennaio 2025)

- Viso.ai, sezione "Model Performance". Disponibile su: https://viso.ai/computer-vision/model-performance

  Consultato a maggio 2025 (pubblicato nel dicembre 2023)