



UNIVERSITÀ
DI PAVIA

Dipartimento di Biologia e Biotecnologie “L. Spallanzani”

Laurea Magistrale in Biotecnologie Avanzate

Tecnologie innovative e sensoristica avanzata per la stima
della *shelf-life* e la riduzione dello spreco alimentare

Relatore:

Dott. Gianni Guidetti

Tutor Aziendale:

Dott. Francesco Merlino

Tesi di
Chiara Di Benedetto

Anno Accademico 2024/2025

Abstract

Lo spreco di alimenti freschi e deperibili rappresenta una delle principali criticità della filiera agroalimentare contemporanea, con impatti significativi sul piano economico, ambientale e sociale. Una quota rilevante di tali perdite si verifica nella fase di consumo domestico, dove la gestione della *shelf-life*, ovvero della durata di conservazione degli alimenti, è spesso affidata a modelli statici e poco rappresentativi delle reali condizioni di conservazione. In questo contesto, l'adozione di tecnologie intelligenti per il monitoraggio dinamico dello stato di maturazione e deterioramento degli alimenti costituisce una prospettiva promettente per migliorare la qualità della conservazione e contribuire alla riduzione dello spreco alimentare.

La presente tesi si inserisce in questo scenario attraverso un'analisi tecnico-scientifica delle tecnologie sensoriali che compongono la Food Monitoring Board (FMB), l'unità hardware inserita all'interno della porzione superiore di un dispositivo domestico multimodale, concepito per contenere alimenti freschi (frutta e verdura) e raccogliere informazioni visive, chimiche e ambientali utili alla stima della *shelf-life*. L'architettura del dispositivo prevede una fotocamera da 2 megapixel per l'acquisizione delle immagini all'interno del contenitore porta-alimenti, un sensore per la rilevazione di gas e composti organici volatili (VOC), un modulo per la misura di temperatura e umidità con risoluzione migliore del 5%, e un sensore di luminosità utilizzato anche per riconoscere l'apertura della scatola. Il lavoro di tesi non riguarda la progettazione diretta del dispositivo *embedded* avanzato, cioè un'architettura hardware/software, bensì la valutazione critica delle componenti selezionate, supportata da un'ampia ricerca bibliografica e da un'analisi di mercato finalizzata a giustificare le scelte tecnologiche in relazione ai processi fisiologici e biochimici che regolano la maturazione dei prodotti vegetali.

Il lavoro si colloca all'interno delle attività di ricerca e sviluppo portate avanti da Vegea s.r.l., azienda impegnata nello sviluppo di soluzioni tecnologiche innovative basate sull'integrazione tra sensoristica avanzata e sistemi intelligenti. La tesi rappresenta un contributo specifico all'interno di questo percorso più ampio, attualmente in evoluzione e destinato a proseguire con ulteriori fasi di sperimentazione e prototipazione.

Un'attenzione particolare è dedicata ai VOC, molecole chiave rilasciate durante i processi di maturazione e deterioramento, che rappresentano marcatori sensibili dello stato fisiologico dei frutti. La loro integrazione con le informazioni visive e con i parametri ambientali rilevati dal dispositivo costituisce la base per sistemi predittivi più accurati rispetto ai metodi tradizionali, evidenziando il potenziale della multimodalità per la stima dinamica della *shelf-life*.

Poiché il progetto aziendale dedicato allo sviluppo della FMB ha una durata complessiva di 30 mesi e, al momento della stesura della tesi, si trovava ancora nelle fasi iniziali di prototipazione,

non è stato possibile accedere a una fase di testing né disporre di dati sperimentali direttamente associati al dispositivo.

Per colmare questa mancanza e garantire comunque una valutazione fondata su risultati reali, la tesi integra i dati di un secondo progetto aziendale sviluppato da Vegea s.r.l. nel contesto dell'agricoltura 4.0. Questo progetto ha portato alla realizzazione di un cobot, ovvero un braccio robotico collaborativo con applicazione in ambito agricolo, progettato per smistare automaticamente mango e banane in base al loro stadio di maturazione e deterioramento. L'unità che alimenta il cobot è un sistema *embedded* avanzato, in cui sensori, capacità di elaborazione e algoritmi di intelligenza artificiale sono integrati per svolgere una funzione specifica in modo autonomo. In questo caso, il sistema è composto da una telecamera OAK Lite, dotata di capacità di inferenza *edge*, e dal modello di deep learning YOLOv8, una delle architetture di visione artificiale più recenti e performanti per il riconoscimento di oggetti in tempo reale. Il funzionamento del sistema si fonda su una *pipeline* visiva strutturata, che trasforma un'immagine grezza in un'informazione utile attraverso fasi di acquisizione, *pre-processing*, inferenza e interpretazione del risultato.

Le prestazioni ottenute da YOLOv8, caratterizzate da elevata accuratezza anche in condizioni operative variabili, costituiscono una validazione preliminare della scelta di includere una componente visiva nella FMB. Pur operando in un contesto applicativo diverso, il sistema sviluppato in ambito agricolo dimostra infatti che modelli di visione artificiale possono riconoscere in modo affidabile gli stadi di maturazione dei frutti, fornendo un riferimento concreto per prevedere le potenzialità della FMB una volta completata.

L'analisi comparativa ha evidenziato che alcune soluzioni sviluppate nel progetto agricolo, in particolare la *pipeline* YOLOv8 e la struttura modulare del flusso di elaborazione, possono essere applicate anche alla FMB. La *pipeline* YOLOv8 consiste nella sequenza completa di operazioni che trasformano un'immagine grezza in un'informazione utile, comprendendo fasi di acquisizione, *pre-processing*, inferenza e interpretazione del risultato. La sua organizzazione modulare permette di separare questi passaggi e di eseguirli su unità hardware diverse. Nel sistema agricolo, l'intera *pipeline* viene eseguita a bordo grazie alla telecamera OAK Lite, mentre nella FMB, che utilizza una fotocamera più semplice (OV2640), è possibile mantenere in locale la sola acquisizione dell'immagine e delegare a un server esterno le fasi di elaborazione più complesse. Questo approccio consente al dispositivo domestico di beneficiare di modelli avanzati pur mantenendo un hardware leggero, dimostrando la trasferibilità concettuale delle soluzioni sviluppate in ambito agricolo e rafforzando la coerenza delle scelte progettuali alla base della FMB.

Nel complesso, la tesi propone un approccio integrato che combina conoscenze biotecnologiche, sensoristica avanzata e tecniche di intelligenza artificiale per affrontare il problema della gestione della *shelf-life* in ambito domestico.

La convergenza tra analisi teorica, valutazione hardware e validazione tramite un caso applicativo reale rafforza la solidità dell'approccio proposto, evidenziando come sistemi multimodali come la FMB possano contribuire in modo significativo alla riduzione dello spreco alimentare e promuovere modelli di consumo più sostenibili e consapevoli.

Sommario

Acronimi.....	1
Introduzione.....	3
Analisi del contesto: spreco alimentare domestico	3
Il progetto di tesi	7
Obiettivo Realizzativo 1 – Ingegnerizzazione e sviluppo dell’hardware (M1–M6)	10
Obiettivo Realizzativo 2 – Sistema di riconoscimento degli alimenti (M7–M15)	11
Obiettivo Realizzativo 3 – Riconoscimento del grado di maturazione (M7–M15)	11
Riferimento al secondo Progetto aziendale	12
Caratteristiche e fisiologia post-raccolta di frutta e verdura	14
Cambiamenti fisici durante la maturazione	14
Colore	14
Consistenza	14
Cambiamenti biochimici durante la maturazione	15
Amido	15
Acidi organici	15
Composti caratterizzanti l’aroma e il sapore	15
Minerali e vitamine	16
Fenoli e flavonoidi	16
Cambiamenti fisiologici durante la maturazione	16
Etilene: funzioni, effetti e implicazioni nella qualità post-raccolta	17
Classificazione di frutti e ortaggi in base al comportamento di maturazione	18
Rilevazione del deterioramento	21
Tecniche analitiche e modelli di microbiologia predittiva	21
Deep learning per la previsione della <i>shelf-life</i>	22
Visione artificiale e imaging iperspettrale	23
Nasi elettronici	24
Scopo del lavoro.....	26
Materiali e metodi.....	28
1. Ricerca nella letteratura scientifica e analisi dei composti organici volatili	28
2. Food Monitoring Board	29
Sezioni funzionali	29
Alimentazione e regolazione	29
Unità di controllo	30
Sensori ambientali	30
Interfacce e connettori	30
Switch e pulsanti	30

Test Point	30
Componenti passivi	30
Circuiti integrati secondari	31
Considerazioni progettuali	31
Sensore di luminosità – OPT3001	33
Caratteristiche principali	33
Vantaggi applicativi	33
Integrazione nel sistema FMB	33
Sensore ambientale multifunzione – BME680	34
Caratteristiche generali	34
Gamma operativa	34
Prestazioni specifiche per ciascun sensore	35
Sensore di gas (VOC)	35
Sensore di umidità relativa	35
Sensore di pressione atmosferica	35
Sensore di temperatura	36
Applicazioni tipiche	36
Integrazione nel sistema FMB	36
Modulo microcontrollore ESP32-CAM	36
Caratteristiche principali	37
Funzionalità operative	38
Integrazione nel sistema FMB	38
Panoramica tecnica della fotocamera OV2640	38
3. Sistema di visione artificiale per la classificazione della frutta	40
Ambiente di addestramento e parametri	40
Risultati	42
1. Risultati dell'analisi bibliografica sui composti organici volatili	42
Studio sulla variabilità dei composti volatili nel mango durante la conservazione	42
Studio sulla variabilità dei composti volatili nella banana durante la conservazione	43
2. Analisi di mercato dei sensori ambientali	45
Bosch BME688	46
Sensirion SGP30 + SHT31	46
Sensirion SHTC3 + SGP40	46
CCS811 + DHT22	47
Panoramica tecnica sulle alternative commerciali alla fotocamera OV2640	48
Dalla valutazione dei sensori alla validazione sperimentale	51
3. Output sperimentali del sistema di rilevamento e classificazione dei frutti	52

Risultati dell'addestramento del modello YOLOv8	55
Analisi qualitativa delle predizioni del modello	58
Architettura funzionale del sistema <i>embedded</i> per il rilevamento e la classificazione dei frutti	63
Discussione	65
Robustezza del modello	66
Discussione dei risultati ottenuti dal sistema <i>embedded</i>	67
Trasferibilità dell'approccio di visione artificiale: dal sistema OAK-Lite alla FMB	67
Trasferibilità metodologica tra il sistema OAK-Lite e la Food Monitoring Board	69
Confronto con la letteratura: lo studio di Zhao <i>et al.</i>	70
Conclusioni.....	72
Prospettive future del progetto: sviluppo dei modelli predittivi, applicazione mobile e prototipazione finale	73
Bibliografia.....	76

Acronimi

WP= Work Package: Pacchetto di lavoro
OR= Obiettivo Realizzativo
RI= Ricerca Industriale
FMB = Food Monitoring Board
VOC= Volatile Organic Compounds: Composti organici volatili
ATP= Adenosine Triphosphate: Adenosintrifosfato
RQ= Respiratory Quotient: Quoziente respiratorio
CO₂= Carbon Dioxide: Anidride carbonica
O₂= Oxygen: Ossigeno
ER= Endoplasmic Reticulum: Reticolo endoplasmatico
IAQ= Indoor Air Quality: Qualità dell'aria indoor
bVOC= breath/total Volatile Organic Compounds: VOC totali
SAM= S-adenosyl methionine: S-adenosil metionina
ACC= 1-aminocyclopropane-1-carboxylic acid: Acido 1-amminociclopropano-1-carbossilico
ACS= ACC Synthase: ACC sintasi
ACO= ACC Oxidase: ACC ossidasi
HCN= Hydrogen Cyanide: Acido cianidrico
GC= Gas Chromatography: Gascromatografia
HPLC= High-Performance Liquid Chromatography: Cromatografia liquida ad alte prestazioni
GC-MS= Gas Chromatography–Mass Spectrometry: Gascromatografia–spettrometria di massa
HS-SPME= Headspace Solid-Phase Microextraction: Microestrazione in fase solida dello spazio di testa
SPME-GC/MS= Solid-Phase Microextraction Gas Chromatography–Mass Spectrometry: Microestrazione in fase solida accoppiata a GC-MS
MLP= Multi-Layer Perceptron: Percettrone multistrato
RNN= Recurrent Neural Network: Rete neurale ricorrente
CNN= Convolutional Neural Network: Rete neurale convoluzionale
LSTM= Long Short-Term Memory: Memoria a lungo breve termine
GRU= Gated Recurrent Unit: Unità ricorrente con porte
PCA= Principal Component Analysis: Analisi delle componenti principali
LDA= Linear Discriminant Analysis: Analisi discriminante lineare
K-NN= K-Nearest Neighbors: Algoritmo dei k-vicini più prossimi
ANN= Artificial Neural Networks: Reti neurali artificiali
PLS-DA= Partial Least Squares Discriminant Analysis: Analisi discriminante PLS
SGD= Stochastic Gradient Descent: Discesa del gradiente stocastica
YOLO / YOLOv8 / YOLOv8s / YOLOv9= You Only Look Once: Modello di rilevamento oggetti in tempo reale
RGB= Red Green Blue: Spazio colore rosso-verde-blu
cv= cultivar: Varietà coltivata
CSPDarknet= Cross Stage Partial Darknet: Backbone convoluzionale YOLO
OAK-Lite / OAK-D= OpenCV AI Kit – Lite / Depth: Telecamere AI con inferenza *edge*

PCB= Printed Circuit Board: Scheda a circuito stampato
Li-Ion= Lithium-Ion: Batteria agli ioni di litio
ESP32-CAM= Microcontrollore con Wi-Fi e fotocamera
GPIO= General Purpose Input/Output: Pin di input/output generici
UART= Universal Asynchronous Receiver-Transmitter: Interfaccia seriale asincrona
I²C= Inter-Integrated Circuit: Bus di comunicazione a due fili
SPI= Serial Peripheral Interface: Interfaccia seriale sincrona
USB= Universal Serial Bus: Porta di comunicazione universale
TP= Test Point: Punto di test
IC= Integrated Circuit: Circuito integrato
IR= Infrared: Infrarosso
SMBus= System Management Bus: Bus di gestione di sistema
LGA= Land Grid Array: Package a matrice di contatti
RH%= Relative Humidity: Umidità relativa
hPa= hectopascal: Etopascal
μA / mA= Microampere / milliampere
GPS= Global Positioning System: Sistema di posizionamento globale
IoT= Internet of Things: Internet delle cose
MEMS= Micro-Electro-Mechanical Systems: Sistemi microelettromeccanici
MOX= Metal-Oxide Semiconductor: Sensore a ossido metallico
CO₂eq= Carbon Dioxide Equivalent: Equivalente di CO₂
TVOC= Total Volatile Organic Compounds: VOC totali
ppb= parts per billion: Parti per miliardo
ppm= parts per million: Parti per milione
ONNX= Open Neural Network Exchange: Formato aperto per modelli di deep learning
OpenVINO= Open Visual Inference and Neural Network Optimization: Toolkit per ottimizzazione inferenza
TensorRT= Tensor Runtime: Motore di inferenza NVIDIA
CoreML= Core Machine Learning: Framework ML per Apple
CUDA= Compute Unified Device Architecture: Architettura di calcolo parallelo NVIDIA
LTS= Long-Term Support: Supporto a lungo termine
HSV= Hue Saturation Value: Tonalità–Saturazione–Valore

Introduzione

Analisi del contesto: spreco alimentare domestico

Lo spreco alimentare rappresenta una delle principali sfide ambientali, economiche e sociali della filiera agroalimentare contemporanea. Secondo i dati pubblicati da Eurostat nel 2023, nell'Unione Europea sono stati generati circa 58.2 milioni di tonnellate di rifiuti alimentari, equivalenti a 130 kg di cibo sprecato pro capite. Di questi, oltre la metà (53%) proviene dal consumo domestico, con una media di 69 kg di rifiuti alimentari per abitante all'anno. Questo fenomeno comporta perdite economiche stimate in circa 132 miliardi di euro e contribuisce al 16% delle emissioni totali di gas serra legate al sistema alimentare.

In Italia, la situazione appare altrettanto critica: l'ultimo Rapporto 2025 dell'Osservatorio Waste Watcher International evidenzia che ogni cittadino getta in media oltre 617 grammi di cibo a settimana, con picchi superiori al Sud (713.8 g) e una maggiore incidenza nei piccoli centri e tra le fasce socialmente svantaggiate. Frutta fresca, pane e verdure guidano la classifica degli alimenti più sprecati, spesso a causa di confezioni sovradimensionate, cattiva conservazione o semplice dimenticanza. Lo spreco domestico rappresenta il 58.5% del costo totale dello spreco di filiera, che in Italia ammonta a oltre 14 miliardi di euro l'anno, di cui più di 8 imputabili al solo spreco casalingo.



Figura 1.1 Lo spreco domestico rappresenta una parte rilevante dello spreco alimentare totale.

Nonostante il 94% degli italiani si dichiarino sensibile al tema dello spreco alimentare, le pratiche virtuose adottate durante le stagioni pandemiche, ovvero i mesi della pandemia da Covid-19, in particolare tra il 2020 e il 2021, quando le restrizioni e la maggiore permanenza in casa avevano favorito una gestione più attenta delle risorse domestiche; sembrano oggi in declino. I dati mostrano come solo il 6% della popolazione scelga di donare il cibo cucinato in eccesso, mentre meno di un terzo adotta strategie preventive quali la pianificazione della spesa o la gestione consapevole del frigorifero. Questo calo di attenzione riflette un ritorno a comportamenti meno sostenibili, legati sia alla riduzione della percezione di emergenza che aveva caratterizzato il periodo pandemico, sia alla difficoltà di mantenere nel lungo periodo abitudini organizzative più rigorose (Waste Watcher, 2024).

La dimensione domestica dello spreco alimentare in Italia rimane quindi significativa e si concentra soprattutto nella fase di consumo, dove la mancanza di pianificazione e l'acquisto impulsivo portano a un surplus di prodotti che non vengono utilizzati entro la loro scadenza. A ciò si aggiunge una scarsa diffusione di pratiche di recupero e redistribuzione, che potrebbero invece contribuire a ridurre l'impatto sociale ed economico dello spreco. Il quadro che emerge è quello di una sensibilità diffusa ma non sempre tradotta in comportamenti concreti, con un divario tra dichiarazioni di principio e pratiche quotidiane che rende necessario un rafforzamento delle politiche di educazione alimentare e di promozione di buone pratiche domestiche. Le cause dello spreco sono molteplici: dalla scarsa qualità dei prodotti acquistati, alla disorganizzazione domestica, fino alla percezione che il contributo individuale sia irrilevante.

La frutta e la verdura fresca, per la loro elevata deperibilità, risultano particolarmente vulnerabili e rappresentano una quota consistente dello spreco totale. In Italia, lo spreco settimanale pro capite di frutta fresca è pari a 22.9 g, seguito da 21.5 g di verdura, 18.4 g di insalata, 19.5 g di pane e 16.9 g di cipolle e tuberi. L'insalata, pur essendo una verdura a foglia, viene spesso trattata come categoria a sé nelle analisi sullo spreco alimentare, poiché presenta una deperibilità particolarmente elevata e dinamiche di deterioramento più rapide rispetto ad altri ortaggi. Questi dati evidenziano la necessità di sviluppare strategie efficaci per la prevenzione dello spreco, in linea con gli obiettivi dell'Agenda 2030 delle Nazioni Unite e con la nuova Direttiva europea per la riduzione dei rifiuti alimentari, che mira a dimezzare lo spreco lungo tutte le fasi della filiera: dalla produzione alla distribuzione, fino al consumo domestico (Waste Watcher, 2024).

In questo scenario, l'adozione di tecnologie smart per la gestione della qualità e della conservazione degli alimenti rappresenta una leva strategica per contrastare lo spreco e ridurre l'impatto ambientale della filiera. Sensori ambientali, sistemi di monitoraggio, algoritmi predittivi e dispositivi intelligenti possono supportare il consumatore e gli operatori del settore nella valutazione dinamica della *shelf-life*, nella prevenzione del deterioramento e nell'ottimizzazione delle risorse. La digitalizzazione della filiera agroalimentare, se integrata con modelli di consumo consapevole, può contribuire in modo significativo alla transizione verso un sistema alimentare più sostenibile, resiliente e inclusivo.



Figura 1.2 Spreco alimentare in Europa: oltre 58 milioni di tonnellate di cibo gettato ogni anno, pari a 130 kg pro capite.

La *shelf-life* di un alimento, comunemente tradotta come “durata di conservazione”, rappresenta il periodo in cui un prodotto mantiene caratteristiche sensoriali, nutrizionali e igienico-sanitarie accettabili, senza costituire un rischio per la salute del consumatore. Questo intervallo, che si estende dalla produzione al consumo, è soggetto a modificazioni biochimiche e microbiologiche che possono alterare progressivamente la qualità del prodotto, pur non compromettendone la sicurezza. La determinazione della *shelf-life* è un processo complesso, influenzato da molteplici fattori, tra cui la composizione chimica dell'alimento, le sue proprietà fisiche, il tipo di lavorazione e confezionamento, i trattamenti di conservazione applicati e le condizioni ambientali in cui il prodotto viene stoccato (Moschopoulou *et al.*, 2019).

Tradizionalmente, la *shelf-life* viene definita in modo statico, attraverso test condotti in condizioni standard e riportata come data di scadenza o termine minimo di conservazione. Questo approccio, tuttavia, non tiene conto delle reali condizioni di conservazione che il

prodotto affronta lungo la filiera e nel contesto domestico, risultando spesso impreciso o eccessivamente cautelativo. In risposta a queste limitazioni, si sta affermando il concetto di *shelf-life* dinamica, che considera l'evoluzione del prodotto in funzione delle condizioni ambientali effettive e dei parametri metabolici misurabili. Questo approccio consente di adattare la durata di conservazione in tempo reale, migliorando la gestione della qualità, riducendo lo spreco alimentare e aumentando la sicurezza del consumatore. La *shelf-life* dinamica si basa su una comprensione approfondita del comportamento post-raccolta dell'alimento, sull'identificazione di marcatori di deterioramento e sull'integrazione di tecnologie analitiche e digitali per il monitoraggio continuo (Bianchi *et al.*, 2025).

In questo contesto si inserisce il presente lavoro di tesi, che si articola in due progetti, sviluppati in azienda, distinti ma complementari. Il primo, più ampio e strutturato, riguarda la progettazione, la prototipazione e le fasi preliminari di sviluppo di un dispositivo domestico concepito per contribuire alla riduzione dello spreco di frutta e verdura fresche attraverso il monitoraggio intelligente della loro *shelf-life*. Il secondo progetto, anch'esso di interesse aziendale, fornisce una base sperimentale concreta grazie all'analisi di un sistema di visione artificiale applicato all'ambito dell'agricoltura 4.0. L'integrazione di questi due percorsi consente di unire aspetti progettuali e risultati sperimentali, offrendo una visione più completa delle potenzialità delle tecnologie adottate.

Il progetto di tesi

L'obiettivo di sviluppo aziendale si colloca nella realizzazione di un dispositivo domestico concepito per ridurre lo spreco di alimenti vegetali deperibili, oggi riconosciuto come una delle principali criticità e fonti di inefficienza lungo la filiera agroalimentare. Il progetto propone un sistema integrato hardware/software in grado di monitorare in tempo reale lo stato di conservazione degli alimenti freschi. Il cuore tecnologico del prodotto è la componente hardware denominata Food Monitoring Board (FMB), una piattaforma sensoriale avanzata che combina una fotocamera integrata, un naso elettronico, sensori di temperatura e umidità.

Questi sensori raccolgono dati metabolici e visivi sull'alimento rilevato, che vengono elaborati da algoritmi di intelligenza artificiale per stimare la *shelf-life* residua e tracciare il consumo degli alimenti a livello domestico.

Il dispositivo sarà integrato in un contenitore alimentare lavabile e atossico, progettato per un uso quotidiano e accessibile. A completamento del sistema, è prevista una app mobile dedicata, che offrirà statistiche personalizzate e strumenti di supporto per una gestione consapevole del cibo. L'approccio adottato per il progetto si distingue per il suo carattere dinamico e adattivo, capace di superare le limitazioni dei modelli statici e di promuovere una cultura del consumo responsabile, con impatti positivi sia sul piano ambientale che economico. Grazie al processo di deep learning, il sistema affina progressivamente la precisione delle previsioni sulla *shelf-life*, fornendo al consumatore informazioni utili per ridurre gli sprechi alimentari e ottimizzare la conservazione domestica.

La scheda FMB è un prototipo progettato per l'utilizzo in laboratorio, finalizzato alla misura dei parametri ambientali all'interno di un contenitore chiuso contenente alimenti, essa integra sensori dedicati al monitoraggio delle condizioni interne e rappresenta la base hardware del sistema di rilevazione. L'alimentazione della FMB può essere garantita tramite batteria esterna rimovibile oppure mediante alimentatore in corrente continua. La durata operativa in modalità a batteria dipende dalla capacità del microprocessore di entrare in modalità *low-power* e dalla frequenza con cui i dati devono essere acquisiti e trasmessi. In alternativa, l'alimentazione esterna può essere fornita attraverso un comune caricatore USB, rendendo il dispositivo facilmente utilizzabile anche in contesti non specialistici.

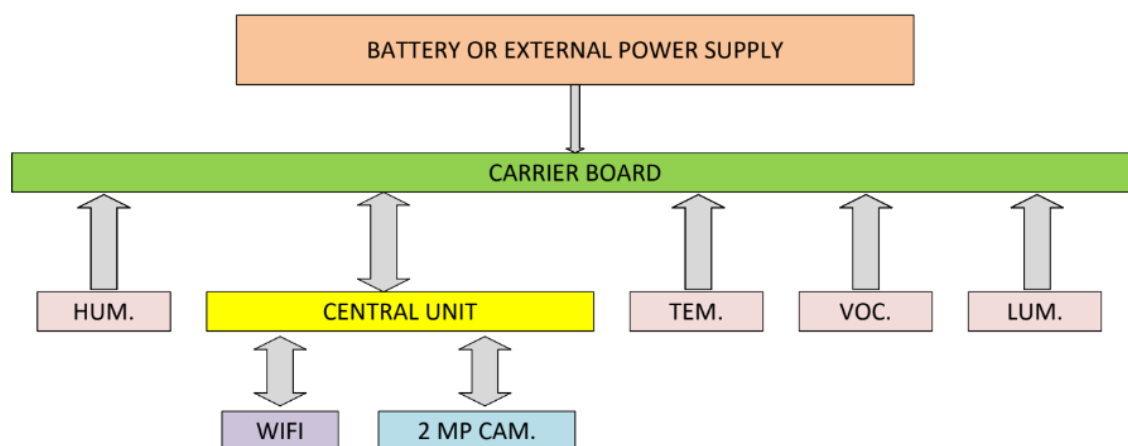


Figura 1.3 Lo schema mostra l'architettura a blocchi della scheda FMB.

L'architettura di base della scheda FMB consiste in una *carrier board* che consente l'acquisizione delle seguenti grandezze:

- Temperatura con risoluzione migliore del 5%
- Umidità relativa con risoluzione migliore del 5%
- Presenza di gas e sostanze volatili
- Luminosità per il riconoscimento dell'apertura scatola.
- Immagini con risoluzione 2 MP (megapixel).

Il *core* della FMB si occupa dell'acquisizione dei segnali provenienti dai sensori integrati e della loro trasmissione a un server esterno tramite connessione Wi-Fi. La capacità di calcolo della scheda non consente l'elaborazione locale delle immagini, che vengono quindi acquisite esclusivamente per il riconoscimento e la classificazione della tipologia di alimento presente all'interno del contenitore. A tale scopo, una risoluzione pari a 2 MP risulta adeguata, in quanto sufficiente a garantire la qualità necessaria per distinguere in modo affidabile le diverse categorie di alimenti senza introdurre un carico computazionale eccessivo.

La solidità di questo approccio trova conferma nella letteratura scientifica recente. Lo studio di Zhao *et al.* (2024) "*Integrated Fruit Ripeness Assessment System Based on an Artificial Olfactory Sensor and Deep Learning*", pubblicato su Foods, descrive infatti un sistema integrato per la valutazione della maturazione dei frutti basato sull'impiego di un naso

elettronico combinato con algoritmi di deep learning. La ricerca dimostra come l'integrazione tra sensori olfattivi artificiali e modelli di intelligenza artificiale consenta di ottenere classificazioni accurate e non distruttive dello stato di maturazione, aprendo prospettive concrete per l'ottimizzazione della *shelf-life*.

Sebbene le tipologie di dispositivi di rilevazione possano differire per architettura, componentistica e finalità applicative, il confronto con la piattaforma sensoriale FMB risulta comunque significativo. Entrambi gli approcci condividono l'obiettivo di raccogliere dati metabolici e visivi per stimare la *shelf-life* residua, seppur attraverso soluzioni tecnologiche differenti. Questa comparazione permette di evidenziare analogie metodologiche e di trarre indicazioni utili per l'analisi critica dei dati, rafforzando la validità scientifica e applicativa dello sviluppo aziendale.

Il fatto che sistemi analoghi siano oggetto di pubblicazioni scientifiche internazionali testimonia che lo sviluppo di dispositivi domestici per il monitoraggio della conservazione degli alimenti non rappresenta un'idea isolata, ma si colloca all'interno di un filone di ricerca attuale e riconosciuto, rafforzando la legittimità e la rilevanza dell'obiettivo aziendale.

L'obiettivo aziendale si svilupperà nell'arco temporale di 30 mesi, a partire dal mese 1 (M1) fino al mese 30 (M30). La pianificazione delle attività è stata strutturata secondo una logica modulare, basata sull'organizzazione in Work Packages (WP), ciascuno dei quali rappresenta un obiettivo realizzativo (OR) di natura riconducibile alla ricerca industriale (RI). I Work Packages costituiscono le macro-attività del progetto e sono suddivisi internamente in task, ovvero sotto-attività operative e specifiche, finalizzate al raggiungimento degli obiettivi scientifici e tecnologici prefissati.

Complessivamente, il progetto prevede sei OR, distribuiti in modo da coprire le diverse fasi di sviluppo, sperimentazione e validazione del sistema, con un approccio interdisciplinare e orientato all'innovazione.

Sebbene il progetto presenti una durata complessiva più estesa, la mia partecipazione si è limitata ai primi dodici mesi (M1–M12), durante i quali ho affiancato le attività aziendali contribuendo alle fasi iniziali previste.

Obiettivo Realizzativo	Intervallo di tempo	Task principale
OR1	M1-M6	Ingegnerizzazione e sviluppo dell'hardware
OR2	M7-M15	Realizzazione del sistema di riconoscimento degli alimenti
OR3	M7-M15	Realizzazione del sistema di riconoscimento dei composti volatili, dell'aspetto e dell'umidità in funzione del grado di maturazione
OR4	M10-M18	Realizzazione dei modelli di intelligenza artificiale per il calcolo della <i>shelf-life</i> dinamica
OR5	M19-M24	Realizzazione dell'applicazione per dispositivi mobili
OR6	M25-M30	Messa a punto e prototipazione del sistema hardware-software

Tabella 1.1 Organizzazione temporale delle attività.

I primi tre OR rappresentano il nucleo fondativo del progetto aziendale e costituiscono la fase in cui sono state sviluppate, testate e validate le componenti essenziali del sistema. Questa parte del lavoro ha permesso di definire l'architettura hardware, costruire i dataset necessari e implementare i primi moduli di riconoscimento visivo e olfattivo, creando le condizioni per lo sviluppo successivo della *shelf-life* dinamica.

Gli obiettivi OR4, OR5 e OR6 sono programmati per una fase successiva del progetto e saranno completati in futuro. Tali attività non ricadranno nel periodo di mia partecipazione.

Obiettivo Realizzativo 1 – Ingegnerizzazione e sviluppo dell'hardware (M1–M6)

Nel primo semestre del progetto è stato completato lo sviluppo del modulo hardware del dispositivo, la FMB. In una fase preliminare, sono stati analizzati diversi componenti elettronici e sensori disponibili sul mercato, con l'obiettivo di individuare soluzioni ottimali in termini di prestazioni e sostenibilità economica e sono stati contattati vari fornitori per la valutazione tecnica dei sensori di rilevazione presenti sul mercato.

Successivamente, è stato redatto il progetto definitivo dell'hardware, che è stato ingegnerizzato tenendo conto delle criticità d'uso in ambiente domestico. È stato realizzato un primo prototipo funzionante, sottoposto a test in condizioni reali: immersione in acqua, esposizione ad agenti

chimici, resistenza agli urti, escursioni termiche (4 °C–50 °C), durata della batteria e ricarica. Per garantire robustezza e sicurezza alimentare, è stato selezionato un materiale idoneo per il rivestimento e implementata una tecnologia di ricarica wireless. Inoltre, è stato progettato e testato un tappo ermetico per proteggere il blocco sensori di gas e umidità, contenente i sensori VOC, il sensore di umidità relativa e il modulo ottico per l'analisi dell'aspetto.

Obiettivo Realizzativo 2 – Sistema di riconoscimento degli alimenti (M7–M15)

Nel secondo OR è stato sviluppato il sistema di riconoscimento automatico degli alimenti, basato sull'integrazione tra fotocamera e naso elettronico. Il dispositivo ha dimostrato di identificare correttamente i prodotti inseriti nella scatola, consentendo l'applicazione degli algoritmi di calcolo della *shelf-life* predittiva.

Il riconoscimento è stato realizzato attraverso un software di intelligenza artificiale che ha elaborato le immagini acquisite dalla fotocamera integrata, classificando gli alimenti per categoria e, ove possibile, per specificità. Parallelamente, il naso elettronico ha rilevato i composti volatili emessi dai prodotti, fornendo una seconda modalità di identificazione.

Sono stati selezionati diversi prodotti ortofrutticoli e raccolti dati visivi in condizioni variabili di illuminazione e dimensioni. È stato costruito un dataset rappresentativo e riproducibile. I dati acquisiti sono stati successivamente filtrati, validati e modellati, definendo le relazioni tra le variabili. Il sistema è stato testato su un campione diversificato di alimenti, dimostrando un'elevata accuratezza.

Obiettivo Realizzativo 3 – Riconoscimento del grado di maturazione (M7–M15)

Parallelamente all'OR2, è stato sviluppato un sistema per il riconoscimento dello stadio di maturazione e degradazione degli alimenti. È stato costruito un dataset relativo ai cento prodotti selezionati, contenente i dati raccolti dai sensori di gas, dalla fotocamera e dal sensore di umidità, in corrispondenza delle diverse fasi di maturazione. Le variazioni cromatiche e i livelli di umidità ambientale sono stati monitorati e correlati ai dati olfattivi. Le analisi sono state condotte all'interno di camere climatiche controllate, messe a disposizione da un partner progettuale esterno, che ha fornito supporto tecnico nell'interpretazione dei dati. Il sistema ha permesso di tracciare con precisione l'evoluzione fisiologica dei prodotti nel tempo.

Riferimento al secondo Progetto aziendale

Poiché il prototipo del progetto cardine non potrà essere testato nei tempi previsti, la presente tesi integra i dati di un secondo obiettivo aziendale sviluppato nel contesto dell'agricoltura 4.0, che documenta l'applicazione di tecnologie di intelligenza artificiale e visione artificiale per la classificazione automatica di frutti come mango e banana. L'inclusione di questo progetto non ha una funzione meramente descrittiva: la convergenza tecnologica tra i due sistemi consente infatti di utilizzare tali risultati come validazione preliminare delle scelte hardware previste per la FMB. In particolare, l'impiego di una telecamera con capacità di inferenza *edge* e di modelli di visione artificiale avanzati rappresenta un riferimento concreto per valutare le potenzialità delle soluzioni che potrebbero essere integrate nel dispositivo domestico.

Il progetto ha portato alla realizzazione di un sistema *embedded* avanzato per il rilevamento, la classificazione e la trasmissione in tempo reale di informazioni relative a mango e banana, finalizzato alla selezione automatizzata mediante un braccio robotico collaborativo (cobot). Per sistema *embedded* si intende un dispositivo elettronico in cui hardware e software sono integrati in un'unità compatta e dedicata, progettata per svolgere in modo autonomo una funzione specifica con risorse computazionali ed energetiche limitate. Nel caso in esame, il sistema si compone di una telecamera OAK Lite con capacità di inferenza *edge*, un modulo 5G Quectel RM500U CNV per la connettività a bassa latenza e un Raspberry Pi 4 come nodo di coordinamento e trasmissione dati.

Elemento centrale è l'impiego di un modello di visione artificiale YOLOv8, addestrato per distinguere i frutti in tre stadi di maturazione (acerbo, media maturazione e maturo), consentendo non solo l'identificazione e la localizzazione, ma anche la classificazione degli oggetti. L'intero processo si basa su una *pipeline* visiva, ovvero una sequenza strutturata di operazioni che trasformano un'immagine grezza in un'informazione utile attraverso fasi di acquisizione, *pre-processing*, inferenza e interpretazione del risultato. L'integrazione di tali tecnologie permette al sistema robotico di prendere decisioni autonome in base allo stato rilevato, aprendo prospettive concrete per applicazioni future quali raccolta automatizzata, controllo qualità in tempo reale e logistica agricola intelligente.

A supporto di questa scelta, è opportuno sottolineare che YOLOv8 appartiene alla famiglia dei modelli “*You Only Look Once*”, architetture di deep learning progettate per eseguire rilevamento e classificazione in un'unica fase. Questo approccio *single-shot* consente di ottenere tempi di inferenza estremamente ridotti, ossia il tempo necessario affinché il modello elabori un'immagine e produca una predizione, un aspetto cruciale nelle applicazioni *real-time* e nei sistemi *embedded* con risorse computazionali limitate. YOLOv8 introduce inoltre miglioramenti strutturali rispetto alle versioni precedenti, tra cui un *backbone* ottimizzato per

l'estrazione delle caratteristiche e una testa di rete più stabile ed efficiente. Queste caratteristiche lo rendono particolarmente adatto alla classificazione degli stadi di maturazione dei frutti, che richiede robustezza rispetto a variazioni di illuminazione, forma e colorazione. Le prestazioni ottenute nel progetto di applicazione agricola confermano quindi la solidità dell'approccio basato sulla visione artificiale e costituiscono un riferimento metodologico rilevante per la FMB.

L'inserimento di questo progetto nella tesi consente quindi di valorizzare dati sperimentali già disponibili e di mostrare come approcci tecnologici avanzati possano essere trasferiti e adattati al contesto della gestione della *shelf-life* di frutta e verdura fresca in Europa, contribuendo così alla riduzione dello spreco alimentare. Nell'ambito del secondo progetto aziendale, il mio contributo ha riguardato la ricerca bibliografica sulla banana e sul mango, con particolare attenzione alla cultivar *Kensington Pride*. Tale approfondimento ha evidenziato come, in questa varietà, la colorazione esterna del frutto non rappresenti un indicatore affidabile dello stato di maturazione, poiché essa varia in funzione dell'esposizione solare più che del reale grado di maturazione (Nordey *et al.*, 2014).

Questa peculiarità rende necessario lo sviluppo di strumenti alternativi per la valutazione dello stato di maturazione e deterioramento. In tale prospettiva, sarebbe auspicabile l'implementazione futura, all'interno del sistema robotico collaborativo, di un sensore multifunzione capace di rilevare i composti organici volatili emessi dal frutto. Tali composti costituiscono infatti marcatori più precisi e affidabili del processo di maturazione e deterioramento. L'adozione di un dispositivo di questo tipo, analogo a quello sviluppato nel progetto cardine, consentirebbe di integrare la classificazione visiva con una valutazione chimico-sensoriale, migliorando l'accuratezza complessiva del sistema e rafforzando la prospettiva di riduzione dello spreco alimentare attraverso tecnologie innovative.

Prima di affrontare gli aspetti progettuali e sperimentali dei due progetti, risulta essenziale approfondire i fondamenti teorici che descrivono i processi di maturazione e deterioramento dei prodotti ortofrutticoli. Una solida comprensione dei meccanismi fisici, biochimici e fisiologici che caratterizzano queste fasi costituisce infatti la base scientifica indispensabile per interpretare correttamente i fenomeni osservati e per definire quali parametri possano essere realmente significativi ai fini del monitoraggio della qualità. Solo attraverso questo inquadramento teorico è possibile valutare con rigore le scelte tecnologiche adottate, identificare i marcatori più rilevanti e comprendere le potenzialità e i limiti dei sistemi di rilevamento sviluppati nel corso del progetto.

Caratteristiche e fisiologia post-raccolta di frutta e verdura

La comprensione dei meccanismi che regolano la maturazione e il deterioramento dei prodotti ortofrutticoli costituisce un passaggio fondamentale per poter valutare in modo affidabile lo stato di qualità degli alimenti. Analizzare come evolvono le caratteristiche fisiche, biochimiche e metaboliche durante queste fasi permette infatti di individuare i marcatori più significativi del cambiamento, dai composti volatili alla variazione di texture, colore e umidità. Solo a partire da questa conoscenza di base è possibile progettare un sistema di rilevamento realmente efficace: il dispositivo sviluppato nel progetto si fonda proprio sulla capacità di intercettare tali segnali, traducendoli in informazioni utili per stimare la *shelf-life* dinamica e monitorare il grado di maturazione e deterioramento del prodotto.

La maturazione rappresenta una fase cruciale nello sviluppo dei frutti, durante la quale avvengono trasformazioni di natura qualitativa, metabolica, fisica e fisiologica. La conoscenza del comportamento di maturazione è essenziale poiché determina la qualità del prodotto, la sua *shelf-life* e le strategie di gestione post-raccolta. Questo processo è regolato da fattori genetici e biochimici che operano in maniera complessa ma coordinata, modificando caratteristiche sensoriali come texture, colore, aroma e sapore, fino a rendere il frutto idoneo al consumo (Wills *et al.*, 1998; Sethi *et al.*, 2011; Su-Mon *et al.*, 2022).

Cambiamenti fisici durante la maturazione

Colore

La perdita della tonalità verde è uno dei segnali più evidenti della maturazione. Tale cambiamento è dovuto alla degradazione della clorofilla ad opera dell'enzima clorofillasi, con formazione di clorofillide e fitolo, e successiva trasformazione in composti privi di colore come clorine e purpurine (Kanayama e Kochetov, 2015). Parallelamente, la sintesi di pigmenti secondari come β -carotene, antociani, licopene, luteina, xantofille e violaxantine conferisce ai frutti tonalità gialle, rosse, arancioni o blu/viola, che diventano indicatori di maturità e raccolta (Wills *et al.*, 1998). La perdita del verde è quindi un indicatore universale di maturazione, con eccezioni in specie come avocado, kiwi, mela Granny Smith, feijoa, pera Anjou e uva Thompson *seedless*.

Consistenza

La consistenza dei frutti è determinata principalmente dalla struttura della parete cellulare, composta da pectina, cellulosa, emicellulosa e polisaccaridi non cellulosici. Durante la maturazione, la pectina subisce processi di solubilizzazione ed esterificazione che portano all'ammorbidimento dei tessuti. La pectina insolubile (protopectina) viene trasformata in

polimeri solubili (poluronidi), con conseguente perdita di integrità strutturale (Sulaimankhil *et al.*, 2021).

La degradazione della parete cellulare è mediata da enzimi chiave come protopectinasi, pectin metilesterasi, poligalatturonasi, cellulasi e β -galattosidasi, che agiscono in sequenza sulla lamella mediana favorendo il distacco cellulare (Prasanna *et al.*, 2007). Inoltre, la perdita di zuccheri neutri (galattosio, arabinosio) e di pectine acide (rhamnogalatturonano) contribuisce al processo di ammorbidimento. Studi genetici hanno evidenziato che geni codificanti per enzimi come poligalatturonasi, pectin metilesterasi, expansine e galattosidasi sono direttamente associati alla riduzione della consistenza dei frutti (Wang *et al.*, 2021).

Cambiamenti biochimici durante la maturazione

Amido

Durante la maturazione, le riserve di amido presenti nei frutti vengono progressivamente degradate in zuccheri semplici come glucosio, fruttosio e saccarosio, determinando un aumento del contenuto zuccherino e un miglioramento delle caratteristiche sensoriali. Questo processo può avvenire per importazione di zuccheri dalla pianta madre o per conversione dell'amido immagazzinato nel frutto. L'enzima invertasi catalizza la scissione del saccarosio in glucosio e fruttosio, mentre α -amilasi e β -amilasi frammentano l'amido in glucosio e maltosio. Quest'ultimo può essere ulteriormente convertito in glucosio-1-fosfato e glucosio-6-fosfato, utilizzati nei processi di respirazione glicolitica o nella sintesi di saccarosio (Kader, 1985).

Un esempio tipico è la banana, che durante la fase post-climaterica mostra una netta diminuzione del contenuto di amido accompagnata da un aumento degli zuccheri solubili, caratteristica distintiva della maturazione.

Acidi organici

Gli acidi organici svolgono un ruolo cruciale nello sviluppo dei frutti e nella loro difesa contro patologie post-raccolta. I frutti tendono ad accumulare acidi come citrico (mango, guava, ananas, agrumi), malico (mela, banana, ciliegia, anguria), tartarico (uva, tamarindo), chinico (kiwi, mirtillo) ed ellagico (fragola, jamun). In generale, il contenuto di acidi diminuisce con la maturazione, sebbene in frutti come banana e ananas rimanga elevato anche dopo la maturazione completa. La riduzione dell'acidità è spesso associata a un aumento della permeabilità di membrana e alla diluizione dovuta all'incremento del volume del frutto (Kader, 1985).

Composti caratterizzanti l'aroma e il sapore

Il gusto dei frutti è determinato dall'interazione di zuccheri, acidi organici, composti fenolici e VOC (*Volatile Organic Compounds*). I principali composti responsabili dell'aroma sono esteri,

alcoli, aldeidi, acidi e chetoni, molecole di piccole dimensioni (<250 Dalton) presenti in concentrazioni di circa 10 mg/100 g di prodotto (Gundewadi *et al.*, 2018). Gli esteri, in particolare, conferiscono note fruttate e floreali e sono considerati marcatori chiave della qualità sensoriale.

Minerali e vitamine

Il contenuto minerale tende a rimanere relativamente stabile durante la maturazione, come ad esempio il potassio nella banana verde e matura; al contrario, gli antiossidanti aumentano con la maturazione, in particolare la vitamina C (acido ascorbico), che svolge funzioni metaboliche e protettive. Tuttavia, in alcuni frutti e ortaggi (pera, patata, asparago, okra) i livelli di vitamina C diminuiscono durante la maturazione o la conservazione post-raccolta, a causa della sua ossidazione in deidroascorbico catalizzata dall'enzima ascorbato ossidasi. In altri casi, come nel peperone maturo, il contenuto di vitamina C può risultare fino al 50% superiore rispetto allo stadio verde, mentre la vitamina A aumenta di dieci volte (Nerdy, 2018). Differenze significative sono state osservate anche tra frutti di pomodoro maturati sulla pianta e frutti staccati, con variazioni nei livelli di Mg, Ca, Mn, Zn e Cu (Paul e Srivastava, 2007; Paul *et al.*, 2012a).

Fenoli e flavonoidi

I fenoli e i flavonoidi sono composti bioattivi fondamentali per la qualità e il profilo aromatico dei frutti. Durante la maturazione, il contenuto fenolico e antocianico tende a diminuire fino alla maturità fisiologica, con variazioni legate a genotipo, pratiche colturali e condizioni ambientali (Prasanna *et al.*, 2007). Questi composti svolgono ruoli chiave nella pigmentazione e nella resistenza ai patogeni, oltre a possedere attività antiossidanti con effetti benefici sulla salute (Ghasemzadeh e Ghasemzadeh, 2011). Studi hanno evidenziato variazioni significative nei fenoli in diverse cultivar di mela (Kumar *et al.*, 2018) e agrumi (Nayak *et al.*, 2020; 2024). I flavonoidi, presenti in forma glicosilata o esterificata, includono molecole come antociani e quercetina, ampiamente distribuite nei prodotti ortofrutticoli (Liu, 2004; El-Ramady *et al.*, 2015).

Cambiamenti fisiologici durante la maturazione

La respirazione consiste nella degradazione delle riserve organiche (carboidrati, proteine e lipidi) in molecole più semplici, con produzione di energia sotto forma di ATP (adenosintrifosfato). Il substrato respiratorio utilizzato può essere identificato tramite il quoziente respiratorio (RQ), ossia il rapporto tra CO₂ prodotta e O₂ consumato: per i carboidrati RQ = 1, per gli acidi organici RQ > 1, mentre per i lipidi RQ < 1. Valori elevati di RQ indicano la possibilità di respirazione anaerobica.

La respirazione è una reazione esotermica che contribuisce all'aumento della temperatura dei frutti, soprattutto nei frutti climaterici come mango e banana, che mostrano un incremento della respirazione durante la maturazione (*respiratory climacteric*). Il metabolismo respiratorio coinvolge quattro vie principali: glicolisi, ciclo dell'acido citrico, trasporto elettronico e via dei pentoso-fosfati. La velocità respiratoria è inversamente proporzionale alla *shelf-life*: un aumento di 10 °C raddoppia i processi respiratori, accelerando il deterioramento (Fagundes *et al.*, 2013). La modulazione dei livelli di O₂ e CO₂ attorno ai frutti consente di ridurre la respirazione e prolungarne la conservazione. I frutti non climaterici, come agrumi, ananas, fragole, non mostrano un picco respiratorio evidente, ma comunque subiscono cambiamenti di maturazione, seppur più lenti rispetto ai frutti climaterici.

Etilene: funzioni, effetti e implicazioni nella qualità post-raccolta

L'etilene è un ormone vegetale gassoso che svolge un ruolo chiave nella regolazione della maturazione dei frutti e di numerosi processi fisiologici post-raccolta. Comprenderne la produzione, l'azione e gli effetti è essenziale per interpretare le dinamiche di maturazione e deterioramento e per sviluppare sistemi di monitoraggio efficaci.

La distinzione tra frutti climaterici e non climaterici si basa sulla produzione e risposta all'etilene. Tutti i frutti producono piccole quantità di etilene durante lo sviluppo, ma i frutti climaterici ne producono livelli molto più elevati in fase di maturazione. L'etilene può indurre aumenti multipli della respirazione nei frutti non climaterici, mentre nei climaterici provoca un singolo ma significativo incremento.

Dal punto di vista pratico, è fondamentale non conservare insieme prodotti ad alta produzione di etilene con quelli sensibili, per evitare alterazioni fisiologiche e deterioramento. Ad esempio, le mele possono accelerare la senescenza di verdure come spinaci o broccoli; le patate emettono etilene che causa germinazione precoce nelle cipolle. Alcuni ortaggi non climaterici manifestano disordini fisiologici legati all'etilene, come il *russet spotting* della lattuga o l'insorgenza del gusto amarognolo nelle carote (isocumarine).

Il percorso biosintetico dell'etilene, noto come Yang Cycle (Yang, 1980), ha origine dall'amminoacido metionina, che viene attivato con ATP per formare S-adenosil metionina (SAM). L'enzima SAM sintetasi catalizza questa reazione. SAM viene poi convertito in 1-amino ciclopropano carbossilico (ACC) tramite ACC sintasi (ACS), considerato il passaggio limitante della biosintesi. Infine, l'enzima ACC ossidasi (ACO) ossida ACC producendo etilene, CO₂ e acido cianidrico (HCN), successivamente detossificato in β-cianoalanina da β-cianoalanina sintetasi. È stato osservato che la selenometionina può essere un substrato più efficace della metionina per la sintesi di etilene.

Il meccanismo di segnalazione dell'etilene è stato inizialmente descritto con la *triple response* (Neljubow, 1901), caratterizzata da modificazioni morfologiche nei germogli esposti all'etilene. La percezione dell'etilene avviene tramite recettori localizzati nel reticolo endoplasmatico (ER), che richiedono un cofattore rame (Cu) fornito da RAN-1.

I recettori attivano una cascata di segnalazione che coinvolge la proteina chinasi CTR-1, la proteina di membrana EIN-2 e i fattori di trascrizione EIN-3 ed ERF. Questo processo porta all'attivazione di geni responsivi all'etilene, con conseguenti modifiche fisiologiche legate alla maturazione e alla senescenza (Chen *et al.*, 2005).

Classificazione di frutti e ortaggi in base al comportamento di maturazione

Frutti e ortaggi vengono comunemente classificati come climaterici o non climaterici sulla base del loro *pattern* respiratorio e dei livelli di produzione di etilene. Tuttavia, la distinzione non è sempre netta: la sensibilità all'etilene gioca un ruolo più rilevante rispetto alla sola quantità prodotta (Paul *et al.*, 2012b). Alcuni frutti, come guava, melone, susino giapponese, pero asiatico e peperone, mostrano caratteristiche intermedie, influenzate dal genotipo o dalla cultivar. Ad esempio, alcune varietà di guava (Pedro Sato, Jen-Ju Bar) sono non climateriche, mentre altre (Allahabad Safeda e la maggior parte delle varietà indiane) presentano tratti climaterici. I pomodori sono spesso utilizzati come modello per lo studio dei frutti climaterici, mentre le fragole per i non climaterici.

I frutti climaterici, come banana, pomodoro, mela e mango, e alcune verdure come alcune cultivar di peperone, mostrano un marcato incremento della respirazione e della produzione di etilene durante la maturazione, noto come fase climaterica. Questo consente loro di continuare a maturare anche dopo la raccolta. Durante questa fase si osservano la degradazione della parete cellulare con conseguente ammorbidimento della texture, l'aumento degli zuccheri che accresce la dolcezza, la riduzione dell'acidità che bilancia il gusto e l'intensificazione dei composti aromatici volatili che migliorano il profilo sensoriale (Prasad *et al.*, 2022; Menaka *et al.*, 2024; Jayarajan *et al.*, 2024). La gestione post-raccolta di questi frutti è complessa, poiché la continua maturazione comporta rischi di deterioramento e riduzione della *shelf-life*.

L'etilene accelera la maturazione anche dei prodotti vicini e per contrastare questi effetti si utilizzano tecniche come l'atmosfera controllata, che regola i livelli di ossigeno e anidride carbonica rallentando la respirazione, e l'impiego di inibitori o *scavenger* di etilene. I frutti climaterici hanno grande importanza economica per il loro valore nutrizionale e sensoriale, ma richiedono pratiche di conservazione e trasporto molto accurate. La ricerca attuale si concentra sulla regolazione dell'etilene, sulle modificazioni genetiche e su nuove tecniche di stoccaggio per ridurre le perdite post-raccolta.

Nei frutti climaterici, l'applicazione di etilene esogeno accelera la maturazione stimolando la sintesi endogena e l'attivazione dei geni responsivi, con conseguente ammorbidimento, cambiamenti di colore, conversione dell'amido in zuccheri e sviluppo di aroma. Per scopi commerciali, l'etilene viene spesso utilizzato per uniformare la maturazione post-raccolta. Nei frutti non climaterici, invece, l'effetto dell'etilene è limitato: può favorire il *degreening* negli agrumi, rendendoli più appetibili sul mercato, ma non controlla l'intero processo di maturazione, che rimane regolato da altri fattori ormonali e ambientali.

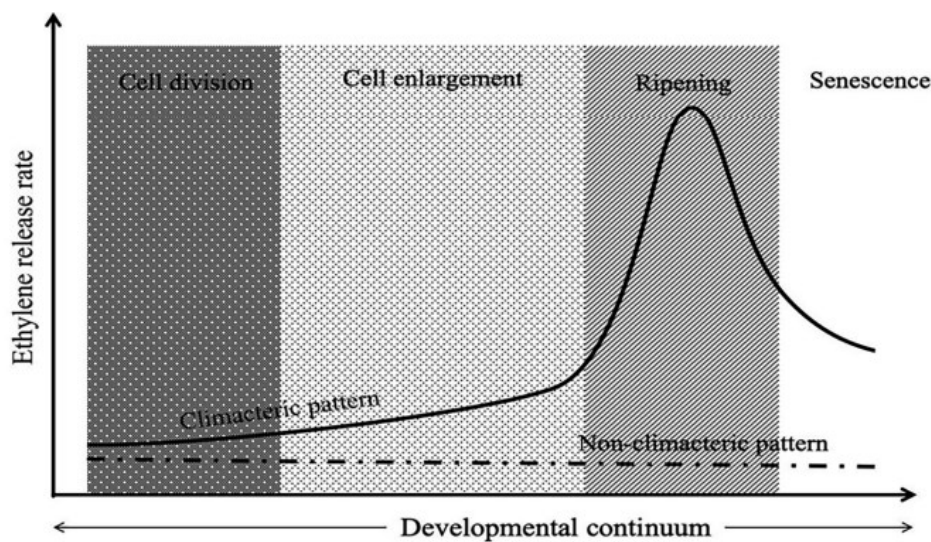


Figura 1.4 Pattern di rilascio dell'etilene nei frutti climaterici e non.

I frutti non climaterici, come agrumi, fragole e ananas, non mostrano la tipica produzione autocatalitica di etilene. Alcuni studi hanno comunque evidenziato un lieve aumento di etilene in uva e fragole durante la maturazione, suggerendo un ruolo parziale del gas in processi come il cambiamento di colore. Tuttavia, la maturazione di questi frutti è regolata da fattori multipli, ormonali e ambientali, e non dipende esclusivamente dall'etilene. Analisi di espressione genica in pomodoro, uva e peperone hanno suggerito meccanismi regolatori comuni, ma le differenze genetiche tra specie rendono necessarie ulteriori indagini (Paul e Pandey, 2016).

Alcune cultivar di susino, mela, kiwi e pera producono quantità molto ridotte di etilene, probabilmente per una limitata capacità di convertire ACC in etilene o per scarsa sensibilità recettoriale. Questi frutti mostrano un climaterio respiratorio attenuato e maturano lentamente, anche se esposti a etilene esogeno. Alcuni esempi risultano essere le cultivar di susino Late Santa Rosa, Casselman, Roysum Shiro, Ruby-Red e Angeleno. Altri frutti, come i peperoni, mostrano caratteristiche intermedie: la respirazione raggiunge il picco allo stadio

verde maturo, mentre la produzione di etilene aumenta allo stadio rosso maturo. Per questo motivo vengono definiti semiclimaterici (Gross *et al.*, 1986). Fenomeni simili sono stati osservati in guava, susino, fico, oliva e melone.

In alcuni casi, frutti non climaterici mostrano *pattern* respiratori simili ai climaterici, ma regolati da reti metaboliche diverse e da una maggiore sensibilità tissutale all'etilene. Questo comportamento, definito pseudoclimaterico, è stato osservato in frutti immaturi di melograno cultivar (cv) Wonderful (Ben-Arie *et al.*, 1984) e in agrumi come arance e pompelmi (Eaks, 1970; Grierson, 2013).

Rilevazione del deterioramento

Nel controllo della qualità alimentare, la valutazione dei prodotti si è tradizionalmente basata su due approcci distinti: da un lato l'analisi sensoriale soggettiva, fondata sulla percezione umana (vista, tatto, olfatto), dall'altro i metodi strumentali oggettivi, che si avvalgono di apparecchiature specifiche per ottenere risultati ripetibili e quantificabili. Sebbene la valutazione sensoriale umana sia preziosa in molti contesti, essa presenta limiti legati alla variabilità interindividuale e alla soggettività. Al contrario, i test strumentali garantiscono maggiore precisione, ma risultano spesso complessi, costosi e poco adatti a un impiego su larga scala. I principali parametri utilizzati per monitorare la qualità e la sicurezza degli alimenti comprendono aspetto, odore, sapore e consistenza. Tuttavia, il naso umano, pur dotato di circa 400 recettori olfattivi, non è in grado di distinguere con precisione miscele complesse di odori né di rilevare gas tossici o composti volatili a basse concentrazioni (Baietto *et al.*, 2015).

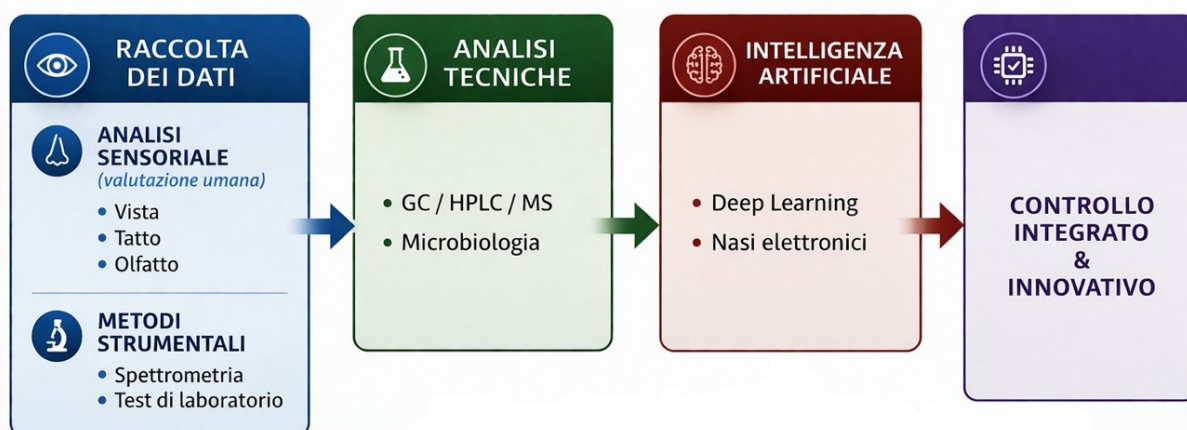


Figura 1.5 Mappa concettuale dei principali approcci per la rilevazione del deterioramento alimentare: dall'analisi sensoriale (vista, tatto, olfatto) ai metodi strumentali e alle tecniche analitiche (GC, HPLC, MS, microbiologia), fino all'integrazione con sistemi di intelligenza artificiale e nasi elettronici, nell'ottica di un controllo qualità integrato e innovativo della *shelf-life*.

Tecniche analitiche e modelli di microbiologia predittiva

La valutazione della *shelf-life* di frutta e verdura fresca veniva storicamente attuata mediante metodologie analitiche e microbiologiche, tra queste tecniche tradizionali vi sono la gascromatografia (GC), la cromatografia liquida ad alte prestazioni (HPLC) e la spettrometria di massa; strumenti fondamentali per la rilevazione di VOC e di molecole bio-emesse durante le fasi di maturazione, trasformazione o deterioramento degli alimenti, che possono fungere da

marcatori di freschezza e qualità (Bashir, 2025; Vats *et al.*, 2024). Parallelamente, le analisi microbiologiche consentono di valutare la crescita di batteri, lieviti e muffe attraverso parametri quali pH, ossidazione lipidica e produzione di etilene (Fox *et al.*, 2023).

Nonostante la loro efficacia, tali approcci presentano limiti significativi: richiedono elevata manodopera, sono di natura distruttiva e poco adattabili al monitoraggio in tempo reale. Per questo motivo, nel progetto aziendale cardine, queste tecniche analitiche verranno impiegate principalmente come riferimento per la validazione dei dati raccolti tramite la FMB, garantendo una conferma scientifica dei segnali rilevati dai sensori.

I modelli di microbiologia predittiva, basati su approcci cinetici ed empirici, offrono previsioni quantitative sulla crescita microbica, ma risultano spesso vincolati da parametri statici e non considerano pienamente le interazioni tra microrganismi, che possono influenzare i tassi di deterioramento attraverso meccanismi di competizione o sinergia (Fox *et al.*, 2023).

Per superare le limitazioni dei modelli tradizionali, si stanno diffondendo approcci integrati che combinano metodi statistici, dinamica della qualità e algoritmi di intelligenza artificiale. Questi sistemi sono in grado di analizzare grandi volumi di dati in tempo reale e di adattarsi a condizioni ambientali variabili, offrendo maggiore flessibilità e accuratezza (Ventura-Aguilar *et al.*, 2024). In tale contesto, tecniche di machine learning come Random Forest, Support Vector Machine e Gradient Boosting Machine sono state ampiamente applicate per classificare la freschezza dei prodotti sulla base di parametri chimici e fisici. Random Forest utilizza insiemi di alberi decisionali per ridurre errori e migliorare la robustezza delle previsioni; le Support Vector Machine separano i dati in classi diverse trovando l'iperpiano ottimale nello spazio delle caratteristiche; mentre il Gradient Boosting costruisce modelli predittivi sequenziali, dove ogni nuovo albero corregge gli errori del precedente, aumentando progressivamente la capacità di predizione (Rashvand *et al.*, 2025).

Deep learning per la previsione della *shelf-life*

Le analisi supportate da algoritmi di intelligenza artificiale si basano su un insieme articolato di parametri chimici, fisici e ambientali: dalla composizione dei composti volatili e dell'etilene alle variazioni di colore, texture e firme spettrali, fino a temperatura, umidità e tempo di conservazione. L'integrazione di questi indicatori consente di descrivere in modo più completo l'evoluzione della maturazione e del deterioramento, fornendo ai modelli predittivi una base informativa solida e rappresentativa dello stato reale del prodotto. L'evoluzione del deep learning nella previsione della *shelf-life* degli alimenti ha aperto nuove prospettive per l'analisi e la modellazione di dati complessi. Le reti neurali profonde hanno introdotto modelli più

sofisticati, come i Multi-Layer Perceptron (MLP), le Recurrent Neural Networks (RNN) e le Convolutional Neural Networks (CNN), che garantiscono una maggiore capacità di analisi e adattamento, migliorando la precisione delle previsioni sulla *shelf-life*. I MLP rappresentano la forma più semplice di rete neurale profonda e vengono utilizzati sia per attività di classificazione che di regressione. Sono in grado di modellare relazioni non lineari e di generalizzare su nuovi dati, ma il loro addestramento richiede un notevole impegno computazionale e una calibrazione accurata dei parametri che ne regolano il funzionamento. In assenza di adeguate tecniche di regolarizzazione, questi modelli possono incorrere nel problema dell'*overfitting*, ossia la tendenza a memorizzare eccessivamente i dati di addestramento perdendo capacità di generalizzazione su dati nuovi. (Rashvand *et al.*, 2025). Le RNN sono particolarmente adatte all'elaborazione di dati sequenziali e alla previsione di serie temporali, grazie alla capacità di mantenere memoria degli input precedenti e di modellare relazioni temporali tra dati successivi. Tuttavia, soffrono del problema del *vanishing gradient*, ovvero la progressiva riduzione del segnale di apprendimento durante la retropropagazione, che rende difficile l'addestramento su sequenze lunghe.

Architetture avanzate come Long Short-Term Memory (LSTM) e Gated Recurrent Unit (GRU) hanno superato questo limite, dimostrandosi molto efficaci nel monitoraggio della *shelf-life* di alimenti soggetti a variazioni temporali (Rashvand *et al.*, 2025). Le CNN, infine, sono progettate per l'elaborazione di dati strutturati su griglie, come immagini e spettri. Grazie ai filtri convoluzionali, esse estraggono caratteristiche significative dai dati grezzi, identificando *pattern* spaziali quali bordi, texture e forme. Questa capacità le rende fondamentali per la previsione della *shelf-life* basata su dati visivi e per l'analisi di immagini iperspettrali, utilizzate per monitorare variazioni chimico-fisiche negli alimenti e fornire una valutazione accurata della loro qualità e freschezza (Rashvand *et al.*, 2025).

Visione artificiale e imaging iperspettrale

Accanto ai modelli numerici, la visione artificiale ha assunto un ruolo centrale nella rilevazione del deterioramento, grazie all'impiego di tecnologie avanzate come YOLOv8 e YOLOv9 per il rilevamento visivo in tempo reale, e *Vision Transformers* per l'analisi iperspettrale della maturazione. Questi strumenti consentono di valutare lo stato di freschezza attraverso l'elaborazione di immagini multispettrali, identificando variazioni cromatiche e strutturali associate ai processi di senescenza. L'imaging iperspettrale, in particolare, ha dimostrato maggiore efficacia rispetto alle tradizionali tecnologie RGB nella classificazione della freschezza di prodotti come patate e banane, poiché permette di rilevare alterazioni biochimiche

non visibili a occhio nudo. Anche approcci più convenzionali, basati su dataset RGB combinati con architetture ResNet e DenseNet, hanno prodotto risultati robusti nella classificazione della freschezza, sebbene ostacolati da problemi di squilibrio dei dati.

La visione artificiale consente valutazioni non distruttive e automatizzabili, facilitando il controllo qualità in tempo reale e migliorando l'efficienza produttiva nelle linee industriali. Tuttavia, la sua applicazione pratica può essere limitata da fattori ambientali, come variazioni di illuminazione, rumore visivo e texture superficiali complesse, oltre che dalla variabilità morfologica degli alimenti (forme, colori e dimensioni differenti), che richiede tecniche di preelaborazione per garantire l'affidabilità del modello. Pur essendo molto efficace nell'analisi delle modifiche esterne, la visione artificiale tradizionale non è generalmente in grado di rilevare alterazioni biochimiche interne. Solo tecniche più avanzate, come l'imaging iperspettrale o la Near-Infrared Spectroscopy (NIR), possono talvolta individuare variazioni non visibili a occhio nudo, ma con limiti legati alla profondità di penetrazione e alla complessità del segnale. (Rashvand *et al.*, 2025).

La letteratura scientifica recente ha dimostrato l'efficacia di tali modelli in ambito industriale, evidenziando un miglioramento significativo nella gestione della qualità e nella riduzione dello spreco alimentare (Ventura-Aguilar *et al.*, 2024). Persistono tuttavia alcune criticità legate alla standardizzazione dei dati, alla variabilità biologica dei prodotti e alla scalabilità delle soluzioni. Le prospettive future si orientano verso lo sviluppo di sistemi ibridi, capaci di integrare sensori ambientali, tecniche di imaging e algoritmi di intelligenza artificiale in un'unica piattaforma, al fine di garantire una previsione dinamica e personalizzata della *shelf-life* lungo l'intera filiera agroalimentare (Bashir, 2025; Zainal *et al.*, 2022).

Nasi elettronici

In questo scenario si collocano i nasi elettronici (*e-nose*), dispositivi avanzati che combinano componenti hardware e software per la rilevazione e l'analisi dei VOC emessi da alimenti e altre matrici. Il loro principio di funzionamento si basa sulla trasformazione delle informazioni chimiche relative alla presenza di gas o vapori in segnali elettrici digitalizzati, successivamente elaborati tramite modelli statistici e algoritmi di intelligenza artificiale. L'architettura tipica di un *e-nose* comprende un modulo di campionamento, una sezione di rilevamento costituita da array di sensori chimici, un'unità di acquisizione e digitalizzazione del segnale e un modulo software per il riconoscimento dei *pattern*. I sensori impiegati sono spesso rivestiti con materiali nanostrutturati, capaci di interagire selettivamente con specifici VOC e di caratterizzare la "firma olfattiva" di un alimento. Questi dispositivi trovano ampie applicazioni nel settore

agroalimentare, dove vengono utilizzati per valutare freschezza, autenticità e sicurezza dei prodotti, nonché per monitorare la presenza di additivi indesiderati. La capacità di operare in modo rapido, non distruttivo ed economicamente vantaggioso li rende un'alternativa valida ai metodi analitici tradizionali, soprattutto in contesti che richiedono un'elevata frequenza di campionamento (Baietto *et al.*, 2015).

Negli ultimi anni, l'evoluzione della tecnologia e-nose ha beneficiato di progressi significativi nella progettazione di nanomateriali, nella miniaturizzazione dei sensori e nell'integrazione con tecniche di machine learning, ampliandone il potenziale diagnostico. Alcuni dispositivi moderni raggiungono un'accuratezza del 99% nella discriminazione tra diversi profili odorosi grazie all'impiego di algoritmi avanzati come Principal Component Analysis (PCA), Linear Discriminant Analysis (LDA), K-Nearest Neighbors (K-NN), Artificial Neural Networks (ANN) e Partial Least Squares Discriminant Analysis (PLS-DA). L'e-nose trova applicazione anche nel controllo dei processi produttivi, ad esempio nella tostatura del caffè, nell'identificazione di residui chimici o nella valutazione dell'efficienza dei sistemi di conservazione.

Nonostante le numerose potenzialità, permangono alcune limitazioni legate al consumo energetico, alla complessità circuitale e ai costi produttivi, oltre alla necessità di infrastrutture dedicate per le reti di sensori wireless. In ambito alimentare, il monitoraggio dinamico delle emissioni volatili ha dimostrato l'efficacia degli e-nose nel rilevare alterazioni precoci durante la decomposizione di carne, latticini e ortaggi. La capacità di individuare segnali precoci consente una gestione più efficiente della qualità e una riduzione concreta degli sprechi lungo la catena distributiva (Baietto *et al.*, 2015). La rilevazione del deterioramento di frutta e verdura fresca richiede l'integrazione di tecniche analitiche, microbiologiche, fisiche e digitali, necessaria per validare i dati raccolti e garantire una previsione affidabile e dinamica della *shelf-life*, come previsto nel progetto.

Scopo del lavoro

Lo spreco di alimenti freschi e deperibili rappresenta una delle principali criticità della filiera agroalimentare, interessando tanto le fasi produttive e distributive quanto il consumo domestico. Le conseguenze economiche, ambientali e sociali di questo fenomeno sono ampiamente riconosciute, e la gestione della *shelf-life* costituisce un nodo centrale del problema: la definizione tradizionale, basata su modelli statici e date di scadenza predefinite, si dimostra spesso inadeguata a descrivere le reali condizioni di conservazione lungo la filiera e nel contesto domestico.

Analizzando la letteratura scientifica emerge come negli ultimi anni siano stati proposti approcci innovativi, fondati sull'integrazione di sensori avanzati e algoritmi di intelligenza artificiale, capaci di stimare in modo dinamico lo stato di conservazione degli alimenti e di fornire previsioni più accurate sulla loro durata (Ventura-Aguilar *et al.*, 2024; Bashir *et al.*, 2025; Zainal *et al.*, 2022). Studi recenti evidenziano come sistemi adattivi e predittivi possano contribuire in modo significativo alla riduzione dello spreco alimentare lungo l'intera filiera (FAO, 2019; Corrado & Sala, 2018).

Il lavoro si inserisce all'interno delle attività di ricerca e sviluppo portate avanti da Vegea s.r.l., azienda impegnata nello sviluppo di soluzioni tecnologiche innovative e in diversi progetti che condividono un approccio orientato all'integrazione tra sensoristica avanzata e sistemi intelligenti. La tesi rappresenta quindi un contributo specifico all'interno di un progetto più ampio e in continua evoluzione, destinato a proseguire con ulteriori fasi di sperimentazione e prototipazione. In tale quadro, lo scopo della tesi è quello di definire e motivare lo sviluppo di un dispositivo domestico integrato hardware/software, concepito per monitorare in tempo reale lo stato di conservazione dei prodotti vegetali freschi. Il cuore tecnologico del sistema è la Food Monitoring Board (FMB), una piattaforma sensoriale avanzata che combina una fotocamera, un naso elettronico e sensori ambientali, i cui dati vengono elaborati da modelli di intelligenza artificiale per stimare la *shelf-life* residua e supportare il consumatore nella gestione quotidiana del cibo.

Poiché il prototipo della FMB non potrà essere testato nei tempi previsti, la tesi integra i risultati di un secondo progetto aziendale sviluppato nel contesto dell'agricoltura 4.0. Questa scelta ha permesso di disporre di risultati sperimentali concreti da analizzare e commentare, garantendo una base oggettiva per valutare l'efficacia delle tecnologie di visione artificiale che, in prospettiva, potranno essere adottate anche nella FMB.

L'analisi di mercato da me condotta sulle componenti hardware della FMB ha evidenziato come alcune soluzioni impiegate nel sistema *embedded* agricolo, in particolare la telecamera con capacità di inferenza *edge* e la *pipeline* di classificazione basata su YOLOv8, risultino

concettualmente compatibili con l'architettura prevista per il dispositivo domestico. Sebbene la FMB utilizzi una fotocamera più semplice, la OV2640, i risultati ottenuti dal cobot dimostrano che un approccio visivo può raggiungere livelli di affidabilità molto elevati nella classificazione degli stadi di maturazione. Ciò conferma la validità della scelta di includere una componente visiva nella FMB e suggerisce che, tramite elaborazione remota, anche la OV2640 possa supportare modelli di classificazione avanzati.

L'inserimento del secondo progetto nella tesi consente quindi di valorizzare dati sperimentali già disponibili e di mostrare come metodologie avanzate di visione artificiale e machine learning possano essere trasferite e adattate al contesto della conservazione domestica. Questa convergenza tecnologica rafforza la prospettiva che la FMB possa beneficiare dell'integrazione di *pipeline* visive affidabili, contribuendo allo sviluppo di un sistema multimodale capace di stimare la *shelf-life* in modo più accurato e di supportare la riduzione dello spreco alimentare attraverso soluzioni innovative.

Materiali e metodi

1. Ricerca nella letteratura scientifica e analisi dei composti organici volatili

La ricerca bibliografica ha rappresentato un elemento metodologico centrale di questa tesi, non come semplice raccolta di fonti, ma come processo strutturato di analisi critica e comparativa. L'obiettivo non era soltanto individuare studi pertinenti, ma costruire un quadro teorico solido capace di guidare le scelte progettuali, interpretare i risultati disponibili e valutare la trasferibilità delle tecnologie considerate.

La consultazione è stata condotta attraverso le principali banche dati scientifiche, tra cui ScienceDirect, PubMed, Elsevier, Google Scholar e repository istituzionali, privilegiando articoli *peer-reviewed*, *review* recenti e contributi metodologici rilevanti per i temi della maturazione dei frutti, dei composti organici volatili, della *shelf-life* dinamica e delle tecnologie di visione artificiale. La selezione delle fonti ha seguito criteri di attualità, rigore metodologico e pertinenza, con particolare attenzione agli studi che integrano approcci sensoriali, analitici e algoritmici, in linea con la natura multimodale della Food Monitoring Board (FMB).

Questa attività ha permesso di approfondire i meccanismi fisiologici e biochimici che regolano la maturazione dei prodotti ortofrutticoli, identificando i VOC più rappresentativi dei processi di senescenza e deterioramento e chiarendo quali segnali risultino effettivamente informativi per la modellazione predittiva della *shelf-life*. Allo stesso tempo, l'analisi della letteratura ha evidenziato i limiti degli approcci esclusivamente visivi, soprattutto per frutti la cui colorazione esterna non riflette in modo affidabile lo stato fisiologico, e ha messo in luce il valore dei sistemi multimodali che combinano segnali chimici e immagini.

La ricerca bibliografica ha inoltre svolto un ruolo determinante nel collegare il progetto cardine della tesi al secondo progetto aziendale integrato nel lavoro. Gli studi individuati hanno infatti fornito criteri oggettivi per valutare la validità delle *pipeline* di visione artificiale basate su modelli come YOLOv8 e per interpretare i risultati ottenuti nel sistema *embedded* agricolo come una possibile validazione preliminare dell'approccio previsto per la FMB. In questo modo, la letteratura ha contribuito non solo a definire il contesto scientifico di riferimento, ma anche a motivare le scelte tecnologiche adottate e a sostenere la trasferibilità delle metodologie analizzate al contesto della conservazione domestica.

Nel complesso, la ricerca bibliografica ha costituito un passaggio metodologico essenziale per garantire coerenza scientifica al lavoro, orientare le decisioni progettuali e consolidare le basi teoriche necessarie allo sviluppo della FMB.

2. Food Monitoring Board

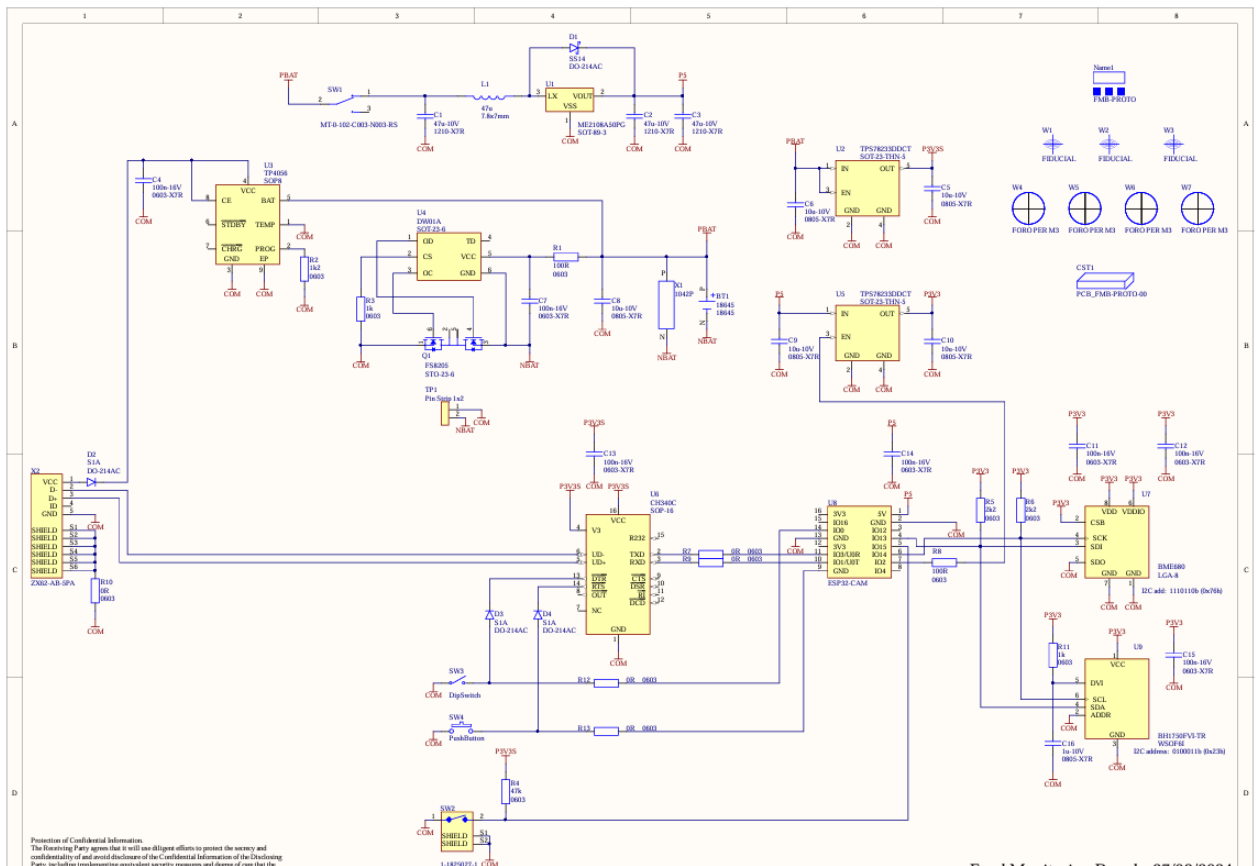


Figure 2.1 PCB prototipale (*Printed Circuit Board*).

L'hardware sviluppato per il progetto cardine di questa tesi è rappresentato dalla FMB, una scheda elettronica progettata per la rilevazione ambientale e la trasmissione dati in contesti di monitoraggio alimentare. La progettazione si articola in due livelli di rappresentazione: lo schema elettrico (*schematic diagram*), che illustra le connessioni funzionali tra i componenti, e il PCB fisico (*Printed Circuit Board*), che ne mostra la realizzazione concreta.

L'architettura della FMB è basata su un insieme di moduli integrati che garantiscono l'acquisizione, l'elaborazione e la trasmissione dei dati ambientali. Di seguito si riportano le principali sezioni funzionali.

Sezioni funzionali

Alimentazione e regolazione

- Batteria Li-Ion 3.7V / 3200mAh (marca AMAZIPOWER): installata in un apposito alloggiamento, fornisce energia al sistema in modalità autonoma.

- Regolatori di tensione TPS7A2030DCT e TPS7A2033DCT: stabilizzano rispettivamente le linee a 3.0V e 3.3V, necessarie per il corretto funzionamento dei sensori e del microcontrollore. Questi componenti sono identificati come U1 e U2 sul PCB.

Unità di controllo

- ESP32-CAM: microcontrollore con modulo Wi-Fi e fotocamera integrata (fotocamera OV2640), responsabile della gestione logica del sistema, dell'acquisizione immagini e della trasmissione dati. È montato centralmente sulla scheda e connesso a diverse linee GPIO, UART e I²C.

Sensori ambientali

- BME680: sensore multifunzione per la rilevazione di temperatura, umidità, pressione atmosferica e composti organici volatili (VOC).
- BH1750FVI: sensore digitale di luminosità, con interfaccia I²C. Entrambi i sensori sono alimentati a 3.3V e comunicano con l'ESP32-CAM tramite le linee SDA e SCL.

Interfacce e connettori

- Connettori W1–W4: distribuiti lungo il perimetro della scheda, consentono l'espansione del sistema, il collegamento a moduli esterni o l'accesso per operazioni di debug.
- Porta USB: prevista per l'alimentazione diretta o la programmazione del microcontrollore.

Switch e pulsanti

- SH1 e SH2: pulsanti multifunzione, utilizzabili per accensione, reset o selezione modalità operative (es. flashing firmware).

Test Point

- TP1: punto di test accessibile per la verifica di segnali e tensioni durante le fasi di collaudo e debug.

Componenti passivi

- Resistenze (R1–R13): impiegate per la limitazione di corrente, configurazioni pull-up/down e protezione dei circuiti.
- Condensatori (C1–C16): utilizzati per il filtraggio e la stabilizzazione delle tensioni.

- Induttori: non visibili nella fotografia, ma previsti nello schema elettrico per eventuali funzioni di filtraggio o conversione DC/DC.

Circuiti integrati secondari

- U3–U5: identificati come IC supplementari, possono includere driver, convertitori o interfacce di comunicazione. La loro funzione specifica è definita nello schema elettrico.

Considerazioni progettuali

La scheda è etichettata con il nome PCB_FMB-PROTO-00 e presenta una serigrafia chiara che facilita l'identificazione dei componenti durante le fasi di assemblaggio e test. L'integrazione del modulo ESP32-CAM consente una gestione avanzata dei dati, con possibilità di trasmissione wireless e acquisizione visiva, rendendo il sistema adatto a contesti di monitoraggio alimentare in ambienti dinamici.

Nell'ambito dell'Obiettivo Realizzativo 1 (OR1), che comprende la progettazione, ingegnerizzazione e prototipazione dell'hardware del dispositivo, è stata sviluppata la FMB, una scheda multi-sensore dedicata al monitoraggio ambientale all'interno di contenitori alimentari. Questa attività si colloca all'interno della Task 1, che prevede l'analisi e la selezione dei componenti elettronici più adatti alla realizzazione del modulo di rilevazione.




Figura 2.2 Fotografia che ritrae l'hardware: Food Monitoring Board

La FMB è stata progettata per rilevare in tempo reale parametri ambientali critici per la conservazione di frutta e verdura, tra cui temperatura, umidità relativa, luminosità e composti organici volatili. Il sensore ambientale integrato, selezionato a seguito di un'analisi comparativa di mercato, è il BME680, scelto per il suo buon rapporto qualità/prezzo, la compatibilità con sistemi *embedded* e la capacità di operare in ambienti a microclima controllato. A completamento del sistema, è stato integrato il sensore di luminosità OPT3001 e una fotocamera OV2640 da 2MP, utile per l'acquisizione di immagini a fini di riconoscimento visivo.

La Task 2, dedicata alla realizzazione e prototipazione, ha portato alla produzione del primo prototipo funzionante della FMB. Questo è stato sottoposto a test in condizioni di utilizzo reale, come previsto dall'OR1, per verificarne la resistenza e l'affidabilità. I test hanno incluso:

- ✓ Immersione in acqua
- ✓ Esposizione ad agenti chimici
- ✓ Resistenza agli urti
- ✓ Funzionamento in ambienti con temperature comprese tra 4°C e 50°C
- ✓ Test di durata e ricarica della batteria

La scheda è alimentabile tramite batteria Li-ion 18650 da 3.7V (2700mAh) o alimentatore USB da 5V, e può operare anche durante la ricarica. I dati acquisiti dai sensori vengono visualizzati tramite un'interfaccia web dedicata e, se configurata, trasmessi via Wi-Fi a un server esterno.

Dal punto di vista strutturale, la FMB presenta dimensioni di 120 × 100 mm, è priva di LED per ottimizzare il consumo energetico, e dispone di un case esterno con indicazioni serigrafate sui tasti. Il funzionamento è automatizzato e la frequenza di acquisizione è personalizzabile.

Sono state inoltre definite le procedure di prima accensione e reset allo stato di fabbrica, necessarie per la configurazione e il ripristino del dispositivo, in linea con le esigenze di test e validazione previste dall'OR1.

Questa fase ha permesso di evidenziare criticità legate alla protezione del blocco sensori durante il lavaggio, portando allo sviluppo di soluzioni tecniche come il tappo ermetico e lo studio di un rivestimento protettivo per garantire la resistenza del sistema sensoristico. Tali interventi rispondono direttamente alle problematiche previste dall'OR1 e contribuiscono al raggiungimento dell'obiettivo di un dispositivo robusto, affidabile e commercializzabile. Dopo aver presentato l'architettura e le funzionalità della FMB, la sezione seguente riporta i risultati sperimentali ottenuti nel secondo progetto aziendale. Questi dati, pur riferendosi a un

contesto applicativo differente, offrono indicazioni utili per valutare la trasferibilità delle metodologie di visione artificiale e per interpretare criticamente le potenzialità della FMB nel monitoraggio della *shelf-life*.

Sensore di luminosità – OPT3001

Il OPT3001 è un sensore digitale di luminosità progettato per misurare l'intensità della luce visibile secondo la risposta fotopica dell'occhio umano. Si tratta di un luxmetro monolitico ad alta precisione, ideale per applicazioni *embedded* che richiedono una rilevazione affidabile della luce ambientale, anche in presenza di vetri oscurati o fonti luminose miste.

Caratteristiche principali

- Spettro di risposta: ottimizzato per la visione umana, con forte reiezione dell'infrarosso (IR), che garantisce misure accurate indipendentemente dalla sorgente luminosa.
- Campo di misura: da 0.01 lux a 83.000 lux, con selezione automatica del range grazie alla funzione di scalatura interna.
- Risoluzione dinamica: 23 bit effettivi, che permettono una rilevazione fine anche in condizioni di luce molto bassa.
- Interfaccia digitale: compatibile I²C e SMBus, con comunicazione su bus a due fili.
- Modalità operative: supporta sia misure continue che single-shot, con sistema di interrupt autonomo che consente al microcontrollore di entrare in modalità *sleep* fino al verificarsi di eventi rilevanti.
- Consumo energetico ridotto: ottimizzato per sistemi alimentati a batteria, grazie alla bassa tensione operativa e all'efficienza energetica.

Vantaggi applicativi

Il sensore OPT3001 rappresenta una soluzione avanzata rispetto a fotodiodi e fotoresistenze tradizionali, grazie alla sua capacità di replicare fedelmente la percezione luminosa umana e di filtrare efficacemente le componenti IR. Questa caratteristica lo rende particolarmente adatto per dispositivi che operano in ambienti estetici o industriali, dove il sensore può essere montato sottovetri scuri senza compromettere la precisione della misura.

Integrazione nel sistema FMB

Nel contesto della FMB, il sensore OPT3001 può essere integrato per monitorare l'intensità luminosa all'interno di ambienti di conservazione alimentare, contribuendo alla valutazione delle condizioni ambientali che influenzano la *shelf-life* dei prodotti.

La sua interfaccia I²C consente una facile connessione al microcontrollore ESP32-CAM già presente sulla scheda, mentre il basso consumo energetico ne favorisce l'uso in sistemi portatili o alimentati a batteria.

Sensore ambientale multifunzione – BME680

Il BME680 è un sensore digitale avanzato a basso consumo, progettato per la rilevazione simultanea di gas, pressione atmosferica, temperatura e umidità relativa. Si tratta di un dispositivo 4-in-1 basato su principi di misura consolidati, integrato in un package compatto e robusto, ideale per applicazioni *embedded*, dispositivi indossabili e sistemi IoT alimentati a batteria.

Caratteristiche generali

- Package: LGA con coperchio metallico, dimensioni $3.0 \times 3.0 \text{ mm}^2$, altezza $0.93 \pm 0.07 \text{ mm}$ (max 1.00 mm)
- Interfacce digitali: compatibile con I²C (fino a 3.4 MHz) e SPI (3 e 4 fili, fino a 10 MHz)
- Tensione di alimentazione:
 - V_{DD}: 1.71 V – 3.6 V
 - V_{DDIO}: 1.2 V – 3.6 V
- Consumo energetico:
 - 2.1 μA @ 1 Hz (umidità + temperatura)
 - 3.1 μA @ 1 Hz (pressione + temperatura)
 - 3.7 μA @ 1 Hz (umidità + pressione + temperatura)
 - 0.09–12 mA in modalità operativa completa
 - 0.15 μA in modalità sleep

Gamma operativa

- Temperatura: $-40 \text{ }^\circ\text{C} \div +85 \text{ }^\circ\text{C}$
- Umidità relativa: $0\% \div 100\%$
- Pressione atmosferica: $300 \div 1100 \text{ hPa}$
- I singoli sensori possono essere attivati/disattivati indipendentemente, permettendo una gestione energetica flessibile.

Prestazioni specifiche per ciascun sensore

Il sensore BME680 integra quattro moduli di misura ambientale (gas, umidità, pressione, temperatura), ciascuno caratterizzato da parametri prestazionali distinti che ne determinano l'accuratezza, la reattività e l'idoneità all'impiego in sistemi *embedded* per il monitoraggio ambientale.

Sensore di gas (VOC)

Il modulo gas del BME680 è progettato per rilevare la presenza complessiva di composti organici volatili, contribuendo alla stima della qualità dell'aria indoor tramite un indice IAQ (Indoor Air Quality) calcolato internamente.

- Tempo di risposta ($\tau_{33-63\%}$): < 1 s per sensori nuovi, indicativo di una risposta rapida ai cambiamenti nella concentrazione di VOC.
- Consumo energetico: < 0.1 mA in modalità ultra-low power.
- Output: indice IAQ su scala 0–500, elaborato tramite algoritmo BSEC.
- Composti rilevati: il sensore non è selettivo, ma è sensibile a un ampio spettro di VOC tra cui:
 - Idrocarburi alifatici e aromatici (metano, propano, benzene)
 - Alcoli (etanolo, isopropanolo)
 - Aldeidi e chetoni (formaldeide, acetone)
 - Monossido di carbonio (CO) e idrogeno (H₂). Questi composti sono tipicamente emessi da materiali da costruzione, prodotti per la pulizia, attività di cottura e processi biologici.

Sensore di umidità relativa

- Tempo di risposta ($\tau_{0-63\%}$): ~8 s
- Accuratezza: $\pm 3\%$ r.H.
- Isteresi: $\pm 1.5\%$ r.H., utile per valutare la stabilità del sensore in condizioni ambientali costanti.

Sensore di pressione atmosferica

- Rumore RMS: 0.12 Pa, equivalente a una risoluzione verticale di circa 1.7 cm
- Coefficiente di offset termico: ± 1.3 Pa/K, corrispondente a una variazione di ± 10.9 cm per ogni grado Celsius

Sensore di temperatura

- Misura la temperatura ambientale con buona stabilità e risoluzione, utile per la compensazione interna degli altri sensori e per la modellazione termica.

Applicazioni tipiche

Il BME680 è adatto a una vasta gamma di dispositivi e contesti:

- Monitoraggio della qualità dell'aria indoor
- Automazione domestica e controllo ambientale
- Dispositivi IoT, wearable e mobili
- Navigazione indoor (rilevamento piani, ascensori)
- Previsioni meteo e stazioni personali
- Ottimizzazione GPS (es. time-to-first-fix, dead reckoning)

Integrazione nel sistema FMB

Nel progetto, il sensore BME680 è integrato per fornire dati ambientali critici all'interno del contenitore alimentare. La sua capacità di rilevare VOC, umidità, temperatura e pressione consente di monitorare le condizioni di conservazione e di supportare la modellazione predittiva della *shelf-life*. La compatibilità con il bus I²C e il basso consumo energetico ne facilitano l'integrazione con il microcontrollore ESP32-CAM, già presente sulla scheda FMB.

Modulo microcontrollore ESP32-CAM

L'ESP32-CAM è un modulo compatto che integra un microcontrollore ESP32 *dual-core* con connettività Wi-Fi/Bluetooth e un'interfaccia dedicata per fotocamere digitali. È progettato per applicazioni *embedded* che richiedono acquisizione visiva, elaborazione locale leggera e trasmissione wireless dei dati, risultando particolarmente adatto a sistemi IoT e di monitoraggio ambientale. Nel progetto FMB, il modulo è accoppiato alla fotocamera OV2640, un sensore da 2 megapixel caratterizzato da dimensioni ridotte, basso consumo energetico e piena compatibilità con l'ESP32-CAM.



Figura 2.3 Modulo microcontrollore ESP32-CAM

Questa configurazione consente di acquisire immagini sufficientemente dettagliate per il riconoscimento della tipologia di alimento, mantenendo al contempo un ingombro minimo e un'efficienza energetica adeguata ai vincoli del dispositivo.

Caratteristiche principali

- Microcontrollore: ESP32-S (SoC Tensilica LX6 dual-core, fino a 240 MHz)
 - Architettura a 32 bit con supporto per elaborazione parallela
 - Memoria: 520 KB SRAM interna + supporto PSRAM esterna (fino a 4 MB)
 - Flash integrata: 4 MB
- Connettività:
 - Wi-Fi 802.11 b/g/n
 - Bluetooth 4.2 BLE + BR/EDR
 - Supporto per protocolli TCP/IP, HTTP, MQTT, UDP
- Interfaccia fotocamera:
 - Connettore FPC per sensore OV2640 (risoluzione fino a 2 MP)
 - Supporto per formati JPEG, YUV, RGB
 - Frame rate fino a 30 fps a risoluzioni inferiori
- Slot microSD:
 - Supporta schede fino a 4–16 GB
 - Utilizzabile per archiviazione locale di immagini, log ambientali o backup
- Flash LED integrato:
 - LED bianco ad alta intensità, controllabile via GPIO
 - Utile per illuminazione in ambienti scarsamente illuminati
- GPIO e interfacce digitali:
 - Fino a 9 pin GPIO disponibili (es. IO0, IO2, IO12–IO16)
 - Supporto UART, SPI, I²C, PWM
 - Pin dedicati per programmazione (IO0, RX, TX)

- Alimentazione:
 - Tensione operativa: 3.3 V
 - Consumo tipico: ~160 mA in trasmissione Wi-Fi, <10 μ A in deep sleep
 - Compatibile con alimentazione da batteria Li-Ion (es. 3.7 V 3200 mAh)

Funzionalità operative

- Modalità di acquisizione:
 - Acquisizione continua o su trigger (es. evento ambientale)
 - Salvataggio su microSD o invio via Wi-Fi
- Programmazione e debug:
 - Via UART (RX/TX) con convertitore USB-seriale esterno
 - Supporto per ambienti di sviluppo come Arduino IDE, PlatformIO, ESP-IDF
- Gestione energetica:
 - Modalità deep sleep per risparmio energetico
 - Wake-up via timer, GPIO o interrupt da sensori

Integrazione nel sistema FMB

Nel progetto, l'ESP32-CAM svolge il ruolo di unità centrale di controllo e acquisizione visiva. È responsabile di:

- Gestione dei sensori ambientali (BME680, BH1750FVI) tramite bus I²C
- Acquisizione immagini per il monitoraggio visivo del contenuto alimentare
- Trasmissione dati via Wi-Fi verso server, interfacce utente o cloud
- Archiviazione locale su microSD per analisi offline o backup
- Controllo energetico per ottimizzare il consumo in modalità batteria

Panoramica tecnica della fotocamera OV2640

La fotocamera OV2640 è un sensore CMOS a colori da 2 megapixel progettato per applicazioni *embedded* e a basso consumo energetico. È in grado di acquisire immagini con risoluzione UXGA (1600 × 1200 pixel) e supporta diverse modalità di output, tra cui YUV, RGB, GRB e dati RAW, rendendola compatibile con una vasta gamma di microcontrollori e sistemi di elaborazione.

Dal punto di vista ottico, il sensore utilizza la tecnologia OmniPixel2™, che garantisce una buona sensibilità in condizioni di luce ambientale ridotta. Il formato ottico è da 1/4", con pixel da 2.2 μm e un'area attiva di 3590 × 2684 μm. Il sensore opera in modalità di scansione progressiva e può raggiungere fino a 15 frame per secondo in risoluzione UXGA, oppure 30 fps in risoluzioni inferiori come SVGA o CIF.

La OV2640 integra una serie di funzioni automatiche per il controllo dell'immagine, tra cui esposizione (AEC), guadagno (AGC), bilanciamento del bianco (AWB), riduzione del rumore (ABF) e compensazione della luminosità (ABL). Questi algoritmi consentono di ottenere immagini stabili e bilanciate anche in condizioni ambientali variabili, pur trattandosi di un sensore a basso profilo computazionale.

Dal punto di vista dell'interfaccia, il modulo utilizza il protocollo SCCB (Serial Camera Control Bus), compatibile con I²C, e supporta l'uscita di immagini compresse in formato JPEG, rendendolo adatto all'integrazione in sistemi con memoria limitata. La tensione operativa è distribuita su tre livelli: 1.2 V per il core, 2.5–3.0 V per l'analogico e 1.7–3.3 V per l'I/O, con un consumo attivo di circa 125 mW e una corrente di standby inferiore a 20 μA.

Nel contesto della FMB, la OV2640 svolge la funzione di acquisizione visiva dell'alimento presente nel contenitore. Sebbene non disponga di capacità di elaborazione locale per modelli complessi di visione artificiale, la sua compatibilità con output compressi e la presenza di controlli automatici la rendono adatta alla trasmissione remota delle immagini per l'elaborazione su server esterni. In questo modo, la fotocamera contribuisce alla *pipeline* multimodale del sistema, fornendo informazioni visive utili alla classificazione dell'alimento e alla contestualizzazione dei dati chimico-sensoriali.

3. Sistema di visione artificiale per la classificazione della frutta

Nel contesto dell'automazione agroalimentare, la classificazione della frutta in base al grado di maturazione rappresenta una sfida strategica, con applicazioni in ambiti quali raccolta automatizzata, confezionamento e controllo qualità. Per rispondere a tale esigenza è stato sviluppato un sistema di visione artificiale basato sul modello YOLOv8, finalizzato al riconoscimento di mango e banana e alla loro classificazione in tre stadi di maturazione: acerbo (*raw*), media maturazione (*medium*) e maturo (*ripe*). L'obiettivo finale del secondo progetto in analisi è l'integrazione del sistema con un braccio robotico collaborativo (cobot), in grado di eseguire selezione e manipolazione automatizzata della frutta in base alla maturazione stimata. Il lavoro è iniziato con la preparazione del dataset, organizzato secondo la struttura standard di YOLOv8, comprendente le cartelle di addestramento e validazione, il file di configurazione e le annotazioni in formato testuale. Ogni immagine è stata etichettata con *bounding box* e classi, per un totale di sei categorie: tre dedicate alle banane (acerbe, a media maturazione e mature) e tre ai mango (acerbi, a media maturazione e maturi). Le *bounding box* rappresentano rettangoli che delimitano l'oggetto di interesse all'interno dell'immagine, definendone la posizione e l'estensione spaziale tramite coordinate normalizzate; costituiscono quindi l'informazione geometrica fondamentale che permette al modello di apprendere dove si trova il frutto e a quale classe appartiene.

Il modello scelto è YOLOv8s, la versione "*small*", selezionata per il suo equilibrio tra accuratezza e leggerezza, caratteristiche che lo rendono particolarmente adatto a contesti *real-time* e a sistemi *embedded*. La sua architettura si basa su un backbone CSPDarknet, che garantisce un'estrazione robusta delle caratteristiche, mentre la testa del modello utilizza un decoder con convoluzioni e regressione multiclasse, capace di generare *bounding box*, valori di confidenza e predizioni di classe in un unico passaggio.

Questa configurazione consente di ottenere elevate velocità di inferenza e buone performance in termini di precisione e mAP, rendendo il sistema facilmente deployabile su dispositivi *edge* come OAK-D, Jetson o microserver. In tal modo, il modello non solo risponde alle esigenze di accuratezza e leggerezza, ma si presta anche a un'integrazione concreta in sistemi robotici collaborativi per l'automazione agroalimentare.

Ambiente di addestramento e parametri

L'addestramento del modello è stato condotto su una GPU NVIDIA RTX 3060 da 12 GB, utilizzando il framework ufficiale Ultralytics YOLOv8, che integra in un'unica piattaforma le fasi di addestramento, validazione, inferenza ed esportazione del modello in diversi formati (ONNX, OpenVINO, TensorRT, CoreML). L'infrastruttura di deep learning si è basata su

PyTorch 2.1.0, con supporto a CUDA 12.6, sfruttando appieno le capacità di calcolo della GPU e garantendo stabilità e compatibilità con le funzioni accelerate. L'ambiente operativo scelto è stato Ubuntu 22.04 LTS, una distribuzione Linux robusta e ampiamente utilizzata in ambito di ricerca e sviluppo, mentre la versione di Python 3.10.12 ha assicurato piena compatibilità con YOLOv8, le librerie Ultralytics e gli strumenti di visualizzazione.

Questa configurazione ha consentito un workflow di addestramento stabile ed efficiente, replicabile sia su workstation locali che su server cloud o ambienti *embedded* per l'inferenza distribuita.

Il modello è stato addestrato per 100 epoche, un numero scelto per garantire la convergenza stabile del sistema mantenendo tempi di *training* ragionevoli. Già entro le prime 50 epoche si osservava una significativa riduzione della funzione di perdita, con progressivo assestamento verso l'epoca 100. Le immagini in input sono state ridimensionate a 640×640 pixel, dimensione predefinita in YOLOv8, che rappresenta un compromesso ottimale tra dettaglio spaziale e prestazioni computazionali. Il batch size è stato fissato a 32, valore che ha permesso di sfruttare in modo efficiente la memoria della GPU e di ottenere una stima più stabile del gradiente durante la fase di backpropagation.

Per l'ottimizzazione è stato utilizzato l'algoritmo SGD (Stochastic Gradient Descent), noto per garantire una convergenza più stabile e una migliore capacità di generalizzazione rispetto ad altri algoritmi come Adam, soprattutto in modelli di tipo YOLO. Inoltre, è stato applicato il sistema di data augmentation integrato in YOLOv8, comprendente flip orizzontale, variazioni HSV e ridimensionamento casuale, al fine di aumentare la robustezza del modello e la sua capacità di generalizzare in condizioni di luce, colore e dimensione dei frutti differenti da quelle presenti nel dataset di addestramento.

La combinazione di questi parametri ha permesso di ottenere un addestramento stabile ed efficace, con metriche elevate e senza segni di overfitting, rendendo il modello pienamente compatibile con l'esecuzione in tempo reale su sistemi *embedded*.

Risultati

1. Risultati dell'analisi bibliografica sui composti organici volatili

Per orientare la definizione dei parametri da monitorare nella Food Monitoring Board (FMB) e comprendere l'evoluzione dei composti organici volatili nei frutti climaterici, sono stati analizzati studi sperimentali presenti in letteratura. Tra questi, particolare rilievo assumono le ricerche dedicate alla variabilità dei VOC nel mango e nella banana durante la conservazione, che forniscono risultati utili a identificare i marcatori biochimici più significativi.

Studio sulla variabilità dei composti volatili nel mango durante la conservazione

Tra i lavori analizzati, particolare rilievo assume lo studio di Lalel *et al.* (2003), dedicato alla produzione di composti volatili aromatici durante la maturazione del mango *Kensington Pride*. La ricerca ha utilizzato tecniche avanzate di microestrazione in fase solida dello spazio di testa (HS-SPME) e gascromatografia accoppiata a spettrometria di massa (GC-MS), consentendo l'identificazione di 61 composti volatili, di cui 35 mai segnalati prima in questa cultivar. Tra questi figurano due sesquiterpeni inediti, (+)-spatulenolo e β -maaliene, che suggeriscono la presenza di vie biosintetiche ancora poco esplorate e potenzialmente rilevanti per la qualità sensoriale del frutto.

Lo studio ha evidenziato una stretta correlazione tra la produzione di etilene, l'attività respiratoria e la sintesi dei VOC. In particolare, i terpeni sono risultati predominanti nelle fasi iniziali della maturazione, mentre gli esteri, responsabili delle note fruttate e dolci, hanno mostrato un incremento progressivo in relazione all'accumulo di acidi grassi. Questo andamento conferma il ruolo chiave degli acidi grassi come precursori dell'aroma e sottolinea la complessità del profilo aromatico della cultivar.

Dal punto di vista fisiologico, la maturazione del mango *Kensington Pride* è accompagnata da un picco climaterico nella produzione di etilene e nella respirazione, coincidente con l'inizio della maturazione avanzata. Parallelamente, si osserva un progressivo accumulo di acidi grassi e una ricca produzione di composti volatili aromatici, molti dei quali mai identificati prima. Questi elementi confermano l'importanza della componente aromatica nella qualità sensoriale del frutto e aprono nuove prospettive per la valorizzazione commerciale e scientifica della cultivar.

Nel complesso, i dati emersi dallo studio offrono un contributo rilevante alla caratterizzazione biochimica e aromatica del mango *Kensington Pride*, fornendo una base scientifica utile per il miglioramento delle tecniche di raccolta, conservazione e valorizzazione commerciale. La conoscenza approfondita del profilo dei composti volatili e della loro evoluzione durante la

maturazione potrà inoltre essere impiegata nello sviluppo di strumenti analitici per il monitoraggio della qualità e della tracciabilità del prodotto, nonché per la selezione di varietà con caratteristiche aromatiche superiori.

In questa tesi, la ricerca bibliografica su studi come quello di Lalel *et al.* rappresenta un pilastro metodologico: essa consente di integrare dati sperimentali consolidati con le esigenze progettuali della FMB, orientando la scelta di sensori e strategie di rilevazione verso soluzioni capaci di intercettare parametri biochimici e aromatici.

Studio sulla variabilità dei composti volatili nella banana durante la conservazione

La banana (*Musa spp.*) è un frutto climaterico di largo consumo mondiale, coltivato nelle regioni tropicali e subtropicali, con un ruolo di primaria importanza economica e sociale (Menezes *et al.*, 2011; FAO; Aziz *et al.*, 2011). Apprezzata per il gusto e l'elevato valore nutrizionale, ricca di carboidrati, polifenoli e minerali (Baskar *et al.*, 2011), la banana è tuttavia altamente deperibile e soggetta a rapidi cambiamenti fisico-chimici dopo la raccolta. Nella fase acerba, l'amido rappresenta circa il 70% della sostanza secca e viene progressivamente convertito in zuccheri semplici durante la maturazione (Agama-Acevedo *et al.*, 2015). La conservazione è resa complessa anche dalla sensibilità alle basse temperature, che favoriscono la degradazione dell'amido attraverso il pathway dell' α -amilasi (Peroni-Okita *et al.*, 2013). Per questo motivo, lo studio dei composti organici volatili durante la conservazione assume un ruolo centrale per il monitoraggio della qualità e della *shelf-life*.

Tradizionalmente, la maturazione è stata valutata con la scala di Von Loesecke, basata sul colore della buccia (Gomes *et al.*, 2014). Metodi più recenti, come l'immagine processing (Prabha e Kumar, 2015), hanno mostrato limiti nel distinguere tra frutti maturi e sovramaturi. Lo studio analizzato propone invece un approccio innovativo, basato sull'identificazione dei cambiamenti negli odori derivanti dai VOC presenti in buccia e polpa, come indicatore dell'*overripening*.

Dal punto di vista metodologico, le banane utilizzate provenivano dalle Filippine e appartenevano a un ibrido tra Cavendish e Sen-nin. I campioni sono stati conservati per sette giorni a 25 °C e analizzati quotidianamente mediante SPME-GC/MS. La tecnica ha consentito di identificare oltre 52 VOC, appartenenti principalmente alle classi di alcoli, esteri, aldeidi e acidi grassi superiori. L'analisi statistica, condotta tramite Principal Component Analysis (PCA), ha permesso di discriminare i campioni odorosi in funzione del tempo di conservazione, evidenziando cluster distinti al secondo, quarto e sesto giorno (Theodoridis e Koutroumbas, 2006; Bishop, 2006).

I risultati hanno mostrato che l'etanolo è il composto più rappresentativo della fase di sovraturazione: assente nei primi due giorni, ha raggiunto oltre il 23% del totale dei VOC al terzo giorno, accompagnandosi a segni visibili di deterioramento della buccia. Questo andamento è attribuibile alla degradazione dell'amido in zuccheri semplici e alla successiva fermentazione microbica (Purgatto *et al.*, 2001; Odebode e Sanusi, 1996; Lebaka *et al.*, 2014). Gli esteri, responsabili delle note fruttate e dolci, sono risultati la classe più abbondante, con 18 molecole identificate, tra cui 3-metilbutil acetato e 3-metilbutil butanoato, considerati i più odor-attivi (Miranda *et al.*, 2001; Wang *et al.*, 2007; Shiota, 1993). In particolare, il 3-metilbutil butanoato è stato riportato come estere predominante nella Cavendish (Nogueira *et al.*, 2003). La loro concentrazione, tuttavia, diminuisce rapidamente nelle fasi avanzate di conservazione, causando un indebolimento dell'aroma tipico della banana (Pino e Febles, 2013).

Accanto a questi, sono stati individuati composti aromatici specifici con ruoli distintivi: il 1,2-dimetossibenzene (veratrole), attrattivo per insetti, compare dal terzo giorno e rimane stabile (Gupta *et al.*, 2012); il 3,4-dimetossibenzaldeide (veratraldeide) e l'isoeugenolo, dotati di proprietà antimicrobiche e antiossidanti, mostrano un incremento progressivo (Koeduka *et al.*, 2006; Rajakumar e Rao, 1993); il metileugenolo aumenta costantemente ed è noto come attrattivo per mosche della frutta (Chuah *et al.*, 1997); l'isovanillina cresce nei primi cinque giorni e diminuisce negli ultimi due, riflettendo un indebolimento delle capacità protettive del frutto (Vusovich *et al.*, 2014); infine, l'elemicina, con proprietà antifungine, mostra un incremento significativo al terzo giorno e una stabilizzazione successiva (Dan *et al.*, 2010).

Nel complesso, lo studio ha chiarito i meccanismi biochimici alla base della decomposizione della banana, identificando l'etanolo come indicatore chiave della marcescenza e composti come veratrole, veratraldeide e isoeugenolo come marcatori della sovraturazione. L'applicazione della PCA ha dimostrato un'elevata efficacia nella discriminazione dei campioni odorosi, confermando il valore di questo approccio statistico per il monitoraggio della *shelf-life* e per la definizione di strategie di conservazione più mirate.

Questi risultati offrono un contributo rilevante alla caratterizzazione biochimica e aromatica della banana, fornendo una base scientifica utile per il miglioramento delle tecniche di raccolta, conservazione e valorizzazione commerciale. La conoscenza approfondita del profilo dei VOC e della loro evoluzione durante la maturazione potrà inoltre essere impiegata nello sviluppo di strumenti analitici per il monitoraggio della qualità e della tracciabilità del prodotto, nonché per la selezione di varietà con caratteristiche aromatiche superiori.

2. Analisi di mercato dei sensori ambientali

Nell'ambito dell'OR1, che comprende la fase di ingegnerizzazione e sviluppo dell'hardware del dispositivo, ho condotto un'analisi preliminare dei sensori ambientali disponibili sul mercato, con l'obiettivo di individuare quelli più adatti alla realizzazione del modulo di rilevazione. Tale attività rientra nella Task 1, dedicata alla selezione dei componenti elettronici e alla progettazione del sistema, e rappresenta un passaggio fondamentale per garantire la funzionalità, l'affidabilità e la sostenibilità economica del prototipo.

La scelta dei sensori è stata guidata da criteri di compatibilità con sistemi *embedded*, precisione delle misure, basso consumo energetico e costo contenuto, in linea con il vincolo progettuale di mantenere il costo complessivo del dispositivo entro i 60 euro. In particolare, l'attenzione si è concentrata su moduli capaci di rilevare temperatura, umidità relativa, luminosità e composti organici volatili, parametri essenziali per monitorare lo stato di conservazione degli alimenti.

Al fine di contestualizzare la scelta del sensore BME680 impiegato nella scheda FMB, è stata condotta un'analisi comparativa dei principali sensori ambientali economici attualmente disponibili sul mercato, in grado di monitorare simultaneamente temperatura, umidità relativa e composti organici volatili.

La scelta dei sensori da integrare nel dispositivo previsto dal progetto deve necessariamente tenere conto non solo delle prestazioni tecniche, ma anche dei vincoli economici imposti dal progetto. Considerando che il sistema, destinato a una futura fase di commercializzazione, dovrà mantenere un costo complessivo non superiore a 60 euro, risulta fondamentale individuare componenti elettroniche che garantiscano un buon compromesso tra precisione delle misure, compatibilità con sistemi *embedded* e sostenibilità economica. In tale ottica, la selezione dei sensori ambientali si basa su un'attenta valutazione del rapporto costo/efficienza, in modo da garantire la funzionalità del dispositivo senza superare il budget previsto.

Questo approccio orienta l'analisi verso moduli integrabili a basso consumo e a basso costo, capaci di rilevare temperatura, umidità e VOC, che rappresentano le principali grandezze indicative dello stato di conservazione degli alimenti.

L'attenzione si è concentrata su sensori con caratteristiche tecniche simili al BME680, in particolare per quanto riguarda il principio di rilevamento (tipicamente MOX), la compatibilità con interfacce digitali standard (I²C, SPI) e la disponibilità di parametri ambientali multipli in un unico modulo. Tra i dispositivi presi in esame rientrano i modelli BME688, SGP30, SGP40 abbinato a SHTC3, e le soluzioni combinate come CCS811 con DHT22. Ognuno di questi viene valutato rispetto a parametri chiave come costo, accuratezza, sensibilità,

consumo energetico e facilità di integrazione, al fine di identificare eventuali alternative valide o complementari al sensore già impiegato nel progetto.

Bosch BME688

Il Bosch BME688 è un sensore ambientale avanzato che integra in un singolo chip MEMS la rilevazione di temperatura, umidità, pressione barometrica e la capacità di analizzare gas grazie alla tecnologia MOX. Questo sensore è in grado di rilevare composti organici volatili come idrogeno, monossido di carbonio, etanolo e altri gas utili per valutare la qualità dell'aria. Un elemento distintivo rispetto al precedente BME680 è la compatibilità con la piattaforma AI-Studio di Bosch, che permette l'utilizzo di algoritmi di machine learning per la classificazione intelligente degli odori. I dati forniti dal sensore includono l'indice di qualità dell'aria (IAQ), la concentrazione totale di VOC (bVOC) e la stima dell'equivalente di CO₂ (CO₂eq), mentre la comunicazione con altri dispositivi avviene tramite protocolli I²C o SPI. Il costo indicativo del BME688 si aggira tra i 9 e i 12 euro, rendendolo una soluzione accessibile per applicazioni avanzate nel monitoraggio ambientale.

Sensirion SGP30 + SHT31

SGP30 è un sensore MOX multi-pixel progettato per misurare la concentrazione totale di composti organici volatili (TVOC) e l'equivalente di anidride carbonica (CO₂eq), offrendo indicazioni utili sulla qualità dell'aria. Per completare le misurazioni con temperatura e umidità, viene comunemente integrato con l'SHT31, un sensore digitale capacitivo ad alta precisione. Questa combinazione consente una rilevazione ambientale completa e accurata, grazie anche alla possibilità di implementare una compensazione ambientale incrociata tra i due sensori. I dati generati includono TVOC in parti per miliardo (ppb), CO₂eq in parti per milione (ppm), umidità relativa (RH%) e temperatura (°C), mentre la comunicazione avviene tramite protocollo I²C. Il costo complessivo stimato per il sistema SGP30 + SHT31 si aggira tra i 12 e i 15 euro, rendendolo una soluzione efficace e relativamente economica per applicazioni nel monitoraggio dell'aria, anche in ambito IoT.

Sensirion SHTC3 + SGP40

La combinazione dei sensori SHTC3 e SGP40 costituisce una soluzione compatta ed efficiente per il monitoraggio della qualità dell'aria. SHTC3 è un sensore digitale a basso consumo progettato per misurare temperatura e umidità con grande precisione, operando con un assorbimento inferiore a 1 µA in modalità standby, ideale quindi per dispositivi portatili o a batteria. SGP40, invece, è un sensore MOX specializzato nella rilevazione dei composti organici volatili e fornisce un'uscita in forma di indice VOC su scala da 0 a 500, che semplifica

notevolmente l'integrazione in applicazioni sia consumer che di ricerca. La qualità della misurazione dei VOC è migliorata grazie alla compensazione automatica basata sui parametri ambientali rilevati dal SHTC3. Entrambi i sensori comunicano tramite protocollo I²C, permettendo un'integrazione rapida e a basso ingombro all'interno di sistemi *embedded*. Il costo complessivo stimato per una combo board con entrambi i sensori si colloca intorno ai 12-15 euro, rendendola un'opzione accessibile per lo sviluppo di soluzioni IoT intelligenti e a basso consumo.

CCS811 + DHT22

La combinazione del sensore CCS811 con il DHT22 rappresenta una soluzione buona per il monitoraggio ambientale di base, ideale per prototipi o progetti didattici. CCS811 è un sensore MOX digitale in grado di rilevare composti organici volatili totali e fornire una stima dell'equivalente di anidride carbonica, con comunicazione tramite interfaccia I²C. DHT22, invece, è un sensore digitale che misura temperatura e umidità relativa, utilizzando un pin dati dedicato e offrendo una precisione discreta, sebbene inferiore rispetto a sensori più avanzati. L'accoppiata consente una lettura ambientale completa, ma con limitazioni in termini di stabilità e accuratezza, soprattutto in applicazioni a lungo termine o in ambienti con variazioni rapide. Il costo complessivo stimato per entrambi i sensori si aggira tra i 9 e i 15 euro, rendendola una scelta accessibile per chi desidera iniziare a esplorare il mondo dell'IoT e della sensoristica ambientale

Sensore	Temperatura	Umidità	VOC / Gas	Output	Comunicazione	Costo (€)	Note
BME680	✓	✓	✓ (MOX)	IAQ, bVOC, T, RH, P	I ² C / SPI	~9–10	Utilizzato nel progetto; buona stabilità
BME688	✓	✓	✓ (MOX AI-ready)	IAQ, bVOC, gas fingerprint	I ² C / SPI	~10–12	Algoritmi AI per classificazione odori
SGP30 + SHT31	✓	✓	✓ (TVOC, CO ₂ eq)	TVOC (ppb), CO ₂ eq	I ² C	~12–15	Richiede due moduli
SGP40 + SHTC3	✓	✓	✓ (VOC Index)	VOC index 0–500, RH, T	I ² C	~12–15	Ottima efficienza energetica
CCS811 + DHT22	✓	✓	✓ (TVOC, CO ₂ eq)	TVOC, CO ₂ eq, RH, T	I ² C + digitale	~9–15	Economico ma meno preciso

Tabella 3.1 Tabella comparativa dei modelli

Questa analisi ha permesso di definire il set sensoristico da integrare nella FMB e ha fornito le basi per la Task 2, dedicata alla realizzazione e prototipazione dell'hardware. In questa fase, il sensore è stato testato in condizioni di utilizzo reale (immersione in acqua, esposizione ad agenti chimici, urti, variazioni termiche), contribuendo all'identificazione delle criticità e alla messa a punto di soluzioni tecniche come il rivestimento protettivo e il tappo ermetico per il blocco sensori.

Panoramica tecnica sulle alternative commerciali alla fotocamera OV2640

Sebbene la fotocamera OV2640 rappresenti una soluzione ampiamente adottata per progetti *embedded* grazie al suo favorevole rapporto tra costo, prestazioni e compattezza, esistono sul mercato altri moduli ottici che si prestano a sostituirla o migliorarne le prestazioni in determinati contesti applicativi. La selezione del sensore di visione più adatto deve tener conto di numerosi fattori progettuali, tra cui: risoluzione, sensibilità alla luce, funzionalità ISP integrate, formato d'uscita, compatibilità con interfacce digitali (DVP, MIPI), consumo energetico, dimensioni fisiche e naturalmente il costo.

Di seguito viene presentata un'analisi di alcuni sensori disponibili sul mercato che, per caratteristiche funzionali e livello di maturità tecnologica, risultano particolarmente significativi nel confronto con l'OV2640.

1. OV5640

La OV5640 (Figura 3.1 A) è un modulo fotografico ad alte prestazioni, progettato per applicazioni che richiedono immagini dettagliate e capacità avanzate di elaborazione visiva. Basato su tecnologia CMOS, questo sensore è in grado di acquisire immagini con risoluzione massima di 2592×1944 pixel (5 MP), risultando ideale per il riconoscimento di texture, difetti superficiali e variazioni cromatiche sottili. Dispone di autofocus meccanico integrato, che consente una messa a fuoco automatica di oggetti a distanze variabili, caratteristica utile in ambienti dinamici o poco strutturati.

La OV5640 supporta sia l'interfaccia DVP (digital video port) che la più veloce MIPI CSI-2, consentendo l'integrazione con un'ampia gamma di microcontrollori e processori *embedded*. È inoltre dotata di unità hardware per la compressione JPEG, che permette di inviare immagini compresse riducendo il traffico dati e l'occupazione di memoria in fase di acquisizione. Il modulo dispone anche di ISP (image signal processor) integrato, in grado di gestire esposizione automatica (AE), bilanciamento del bianco (AWB), correzione gamma e riduzione del rumore.

Sebbene i consumi energetici siano superiori rispetto all'OV2640 — circa 250–300 mW in modalità attiva — la OV5640 si rivela adatta per soluzioni *edge* AI o sistemi in grado di alimentare sensori più esigenti. Il costo commerciale oscilla tra 8 e 13 euro, rendendola una scelta sensata per implementazioni che richiedono alta qualità dell'immagine o capacità di analisi avanzata *onboard*.

2. GC2145

Il sensore GC2145 (Figura 3.1 B), prodotto da GalaxyCore, si propone come una sostituzione diretta e compatibile della OV2640, sia dal punto di vista meccanico che elettrico, mantenendo un formato da 2 Megapixel con risoluzione massima di 1600×1200 pixel (UXGA). Pur mantenendo un livello di complessità limitato, introduce alcune ottimizzazioni rispetto alla OV2640, in particolare una maggiore sensibilità alla luce (grazie a un pixel più ampio) e una migliore resa cromatica in condizioni di illuminazione non ottimale.

Supporta l'interfaccia DVP a 8 bit e trasmette immagini nei formati YUV422, RGB565, RGB444 e RAW, rendendolo compatibile con la maggior parte dei microcontrollori per uso generico. Integra algoritmi per il controllo automatico di esposizione, guadagno e bilanciamento del bianco, consentendo un output visivo qualitativamente adeguato a compiti di classificazione a basso consumo. Per quanto riguarda l'efficienza energetica, i consumi sono contenuti e comparabili a quelli della OV2640, con un assorbimento di circa 120–140 mW in attività. Il vantaggio competitivo risiede soprattutto nel prezzo di mercato, compreso tra 2 e 4 euro, che la rende una soluzione preferibile nei progetti distribuiti su larga scala o soggetti a vincoli di budget severi.

3. Himax HM01B0

Il modulo HM01B0 (Figura 3.1 C), prodotto da Himax, è un sensore di immagine monocromatico in bianco e nero con risoluzione QVGA (320×240 pixel), pensato per applicazioni in cui l'autonomia è una priorità assoluta. Questo sensore si distingue per un consumo energetico estremamente ridotto: meno di 1 mW in standby e circa 2 mW durante l'acquisizione attiva. Tali caratteristiche lo rendono idoneo per dispositivi *wearable*, sistemi *edge* AI o sensori intelligenti Always-On in ambienti privi di alimentazione stabile.

La fotocamera utilizza un'interfaccia ad alta velocità MIPI CSI-2 per la trasmissione dei dati, riducendo la latenza e ottimizzando l'integrazione con processori che supportano questa tecnologia. Tra le funzionalità avanzate va segnalata la modalità *wake-on-motion*, che attiva automaticamente il sistema al rilevamento di cambiamenti visivi nel campo visivo, ottimizzando ulteriormente il risparmio energetico.

Tuttavia, la risoluzione limitata e l'assenza del colore rendono l'HM01B0 poco adatta ad applicazioni come quelle richieste nell'ambito dell'obiettivo aziendale, dove la classificazione visiva di alimenti simili (diverse varietà o stati di maturazione) è fondamentale. Il prezzo medio è contenuto, intorno ai 5–7 euro, in linea con le sue caratteristiche specialistiche.

4. GC032A

La GC032A (Figura 3.1 D) è un modulo sensore CMOS a bassissima risoluzione (VGA – 640×480 pixel), progettato per applicazioni didattiche, giocattoli elettronici, sistemi con vincoli di costo estremamente bassi o sperimentazioni prototipali. Sebbene supporti formati di uscita come YUV, RGB e RAW, la sua qualità visiva è limitata e non adeguata a compiti che richiedono interpretazione dettagliata di scene o analisi cromatica avanzata.

Il sensore si interfaccia tramite protocollo SCCB e trasmette dati attraverso un canale DVP standard a 8 bit. Le funzionalità ISP sono minime: esposizione, contrasto e colore possono essere regolati, ma senza algoritmi evoluti. Il consumo energetico è ridotto, e le dimensioni lo rendono facilmente integrabile anche in spazi molto contenuti.

Nel contesto del progetto, la GC032A non risponde ai requisiti minimi di accuratezza visiva, ma può trovare impiego in fasi iniziali di test o in progetti concettuali dove la rilevanza visiva è secondaria. Il suo prezzo oscilla tra 1 e 2 euro, posizionandola come la soluzione più economica tra le opzioni considerate.

Valutando queste considerazioni, la fotocamera OV2640 è stata selezionata nel contesto del progetto per il suo ottimo bilanciamento tra prestazioni, consumo e costo, risultando più vantaggiosa rispetto alle altre opzioni considerate. Con una risoluzione massima di due Megapixel, il supporto a formati video compressi e non compressi, funzionalità avanzate di *pre-processing* e la piena compatibilità con microcontrollori a risorse limitate, il modulo offre una flessibilità elevata in un formato compatto. Il bassissimo consumo energetico, inferiore a 1 mW in standby, lo rende ideale per sistemi *embedded* alimentati a batteria. Inoltre, il prezzo contenuto (3–5 €), l'ampia disponibilità commerciale e il forte supporto da parte della community hardware ne giustificano pienamente l'adozione come soluzione standard per acquisizioni visive affidabili e a basso costo all'interno di dispositivi IoT.



Figura 3.1 Panoramica delle soluzioni sensoriali alternative presenti sul mercato.

Dalla valutazione dei sensori alla validazione sperimentale

Questa analisi di mercato assume un ruolo particolarmente significativo se messa in relazione con il secondo progetto aziendale integrato nella tesi. Sebbene la FMB utilizzi un sensore più semplice rispetto a moduli avanzati come la OAK Lite, la valutazione comparativa delle alternative commerciali ha permesso di chiarire quali caratteristiche siano realmente necessarie per un dispositivo domestico e quali invece appartengano a contesti applicativi più complessi. In questo quadro, il progetto agricolo del cobot basato su OAK Lite rappresenta un riferimento utile per comprendere il potenziale delle *pipeline* visive avanzate, ovvero delle sequenze di operazioni che trasformano un'immagine grezza in un'informazione classificata attraverso fasi di acquisizione, *pre-processing*, inferenza e interpretazione.

I risultati ottenuti in quel contesto, che verranno presentati nella sezione successiva, offrono infatti un esempio concreto di come modelli di deep learning come YOLOv8 possano raggiungere un'elevata affidabilità nella classificazione degli stadi di maturazione.

Pur operando con hardware più semplice, la FMB può beneficiare di questa evidenza: l'elaborazione remota delle immagini acquisite dalla OV2640 consente infatti di sfruttare modelli avanzati senza gravare sul dispositivo. In questo modo, l'analisi di mercato e il confronto tecnologico con il progetto agricolo convergono nel definire un quadro coerente, in cui la scelta della OV2640 risulta pienamente giustificata e la trasferibilità dell'approccio visivo trova un riscontro sperimentale concreto.

3. Output sperimentali del sistema di rilevamento e classificazione dei frutti

Dopo 100 epoche di addestramento, il modello YOLOv8 ha mostrato prestazioni molto elevate. Il valore di $mAP@0.5$ pari a 0.994 indica un'eccellente capacità di distinguere correttamente gli oggetti nelle tre classi di maturazione. Anche la metrica più stringente, $mAP@0.5:0.95$, ha raggiunto un valore di 0.91, confermando la robustezza del modello su soglie di IoU più severe. La precisione media (0.98) evidenzia una bassa incidenza di falsi positivi, mentre il recall medio (0.96) mostra che il sistema riesce a individuare quasi tutti i frutti presenti nelle immagini, con un numero minimo di falsi negativi. Nel complesso, questi risultati dimostrano l'affidabilità del modello nel riconoscere e classificare gli stadi di maturazione di mango e banana in un contesto *embedded*.




Figura 3.2 Matrice di confusione ottenuta dal modello YOLOv8 dopo il processo di addestramento e validazione. Ogni cella rappresenta il numero di volte in cui una classe è stata predetta come un'altra. I valori lungo la diagonale indicano le classificazioni corrette, mentre quelli fuori dalla diagonale evidenziano gli errori di classificazione. La matrice consente di valutare in modo dettagliato le prestazioni del modello, mostrando quali classi vengono riconosciute con maggiore accuratezza e quali risultano maggiormente soggette a confusione.

La Figura 3.2 mostra la matrice di confusione ottenuta dal modello YOLOv8 dopo il processo di addestramento e validazione. Ogni cella rappresenta il numero di occorrenze in cui una classe è stata classificata come un'altra. I valori lungo la diagonale indicano le classificazioni corrette, mentre quelli fuori dalla diagonale rappresentano errori di classificazione.

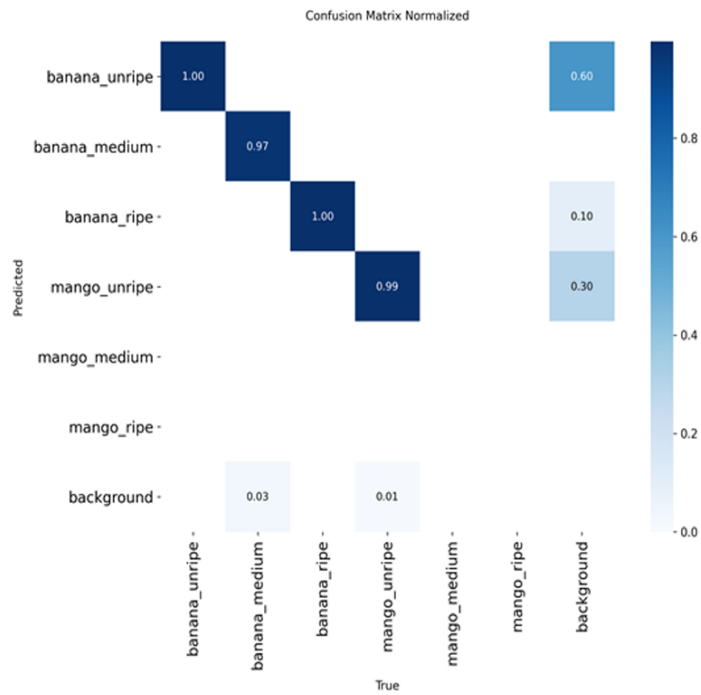


Figura 3.3 Matrice di confusione normalizzata del modello YOLOv8. I valori rappresentano la percentuale di campioni di ciascuna classe reale assegnati alle diverse classi predette. La diagonale indica le classificazioni corrette, mentre le celle fuori diagonale mostrano le principali confusioni, permettendo di confrontare in modo equilibrato le prestazioni tra classi con numerosità diversa.

La Figura 3.3 mostra la matrice di confusione normalizzata, in cui ogni valore è espresso in termini percentuali rispetto al totale delle istanze per ciascuna classe reale. Questo consente una migliore comprensione delle prestazioni relative del modello, indipendentemente dal bilanciamento delle classi. Le celle più chiare indicano una maggiore precisione, mentre quelle più scure evidenziano le aree in cui il modello tende a sbagliare più frequentemente.




Figura 3.4
Curva F1 in funzione della confidenza.




Figura 3.5
Precisione in funzione della confidenza.




Figura 3.6
Precision-Recall curve.




Figura 3.7
Recall in funzione della confidenza.

La curva F1, mostrata nella figura 3.4, rappresenta il bilanciamento tra precisione e richiamo (recall) al variare della soglia di confidenza. Valori elevati della metrica F1 indicano che il modello mantiene buone prestazioni in termini di correttezza delle predizioni e capacità di rilevare tutti i casi positivi. L'analisi di questa curva consente di scegliere una soglia di confidenza ottimale che massimizzi l'efficienza complessiva del modello. Un picco ben definito suggerisce una soglia ideale che può essere utilizzata per il deployment.

Nella figura 3.5 viene mostrata la precisione in funzione della confidenza. La precisione misura la percentuale di predizioni corrette tra tutte quelle considerate positive. Questa curva mostra come la precisione cambia al variare della soglia di confidenza: in genere, aumentando la confidenza richiesta, la precisione migliora, ma a scapito del numero di predizioni effettuate (recall). Questo grafico aiuta a trovare un equilibrio tra false positive e *true positive*, ed è utile per applicazioni in cui è cruciale ridurre al minimo gli errori di classificazione positiva.

La curva Precision-Recall è una rappresentazione molto usata per valutare modelli su dataset sbilanciati. Mostra la precisione (asse y) rispetto al recall (asse x) e consente di comprendere le prestazioni del modello nel rilevare la classe positiva. Un'area sotto la curva (AUC-PR) più vicina a 1 indica un buon compromesso. Curve che si mantengono elevate lungo tutto il range di recall indicano un modello robusto e affidabile, mentre curve che scendono rapidamente indicano problemi di *overfitting* o difficoltà nel gestire la classe positiva. Il recall misura la percentuale di veri positivi rilevati sul totale dei positivi reali.

La figura 3.5, mostra come il recall varia in funzione della soglia di confidenza: tipicamente, a soglie basse il recall è elevato ma con possibile aumento dei falsi positivi.

Questa curva è particolarmente utile per applicazioni in cui è prioritario non perdere alcun caso positivo, anche a costo di accettare qualche falso allarme.

Risultati dell'addestramento del modello YOLOv8

Le tabelle riportate in seguito mostrano l'andamento delle principali metriche di addestramento e validazione del modello YOLOv8 nel corso delle 100 epoche. Ogni riga corrisponde a un ciclo completo di addestramento, mentre le colonne descrivono l'evoluzione delle prestazioni del modello sia nella fase di *training* sia nella fase di validazione.

Le prime colonne mostrano le *loss* di addestramento (*train/box_loss*, *train/cls_loss*, *train/dfl_loss*), che rappresentano l'errore commesso dal modello nel predire la posizione dei *bounding box*, la classe dell'oggetto e la distribuzione spaziale. La progressiva diminuzione di questi valori indica che il modello sta imparando a riconoscere e localizzare correttamente i frutti.

Le metriche di performance (*precision*, *recall*, mAP50 e mAP50-95) descrivono la qualità delle predizioni. In particolare, la precisione misura la capacità del modello di evitare falsi positivi, mentre il *recall* indica la capacità di individuare tutti gli oggetti presenti. Il valore mAP50 rappresenta la media della precisione a una soglia IoU di 0.50, mentre mAP50-95 è una metrica più rigorosa che valuta il modello su soglie crescenti da 0.50 a 0.95. L'aumento costante di queste metriche, che raggiungono valori molto elevati nelle epoche finali, conferma l'efficacia del modello nel classificare correttamente i frutti nei diversi stadi di maturazione.

Le colonne relative alla validazione (*val/box_loss*, *val/cls_loss*, *val/dfl_loss*) mostrano l'errore commesso dal modello su dati non utilizzati durante l'addestramento. Anche in questo caso si osserva una riduzione progressiva, segno che il modello generalizza bene e non presenta fenomeni significativi di *overfitting*.

Infine, i valori *tr/pg0*, *tr/pg1* e *tr/pg2* rappresentano parametri interni dell'ottimizzazione, utili a monitorare la stabilità del processo di *training*.

Epoche	time	train/box_loss	train/cls_loss	train/dfll_loss	precision(B)	/recall(B)	mAP50(B)	/mAP50-95(B)	val/box_loss	val/cls_loss	val/dfll_loss	lr/pg0	lr/pg1	lr/pg2
1	479.718	0.68896	0.69559	102.108	0.80076	0.82793	0.8163	0.66148	0.75705	120.767	110.212	0.000330667	0.000330667	0.000330667
2	956.895	0.66169	0.59381	10.057	0.869	0.82462	0.90146	0.7416	0.6976	0.87159	105.343	0.000657426	0.000657426	0.000657426
3	143.827	0.65609	0.56865	100.436	0.9226	0.86858	0.94773	0.75102	0.72827	116.471	108.722	0.000977586	0.000977586	0.000977586
4	190.787	0.65813	0.54228	0.99999	0.92737	0.91186	0.94511	0.77091	0.71754	0.55	106.694	0.0009703	0.0009703	0.0009703
5	237.169	0.64719	0.51793	100.411	0.95027	0.95687	0.9813	0.81399	0.67527	0.45956	103.897	0.0009604	0.0009604	0.0009604
6	283.595	0.63323	0.49763	0.99415	0.92225	0.89939	0.94087	0.77006	0.71622	0.55703	109.711	0.0009505	0.0009505	0.0009505
7	329.898	0.6227	0.47275	0.99131	0.9003	0.89366	0.92084	0.75639	0.70713	0.5963	103.659	0.0009406	0.0009406	0.0009406
8	377.171	0.61303	0.44971	0.98685	0.91537	0.92373	0.94861	0.79821	0.65145	0.54095	10.316	0.0009307	0.0009307	0.0009307
9	424.132	0.5924	0.43708	0.97635	0.91584	0.94178	0.96201	0.81623	0.64452	0.46032	101.694	0.0009208	0.0009208	0.0009208
10	471.457	0.60023	0.43278	0.97906	0.95046	0.94863	0.96414	0.7951	0.69633	0.47393	106.624	0.0009109	0.0009109	0.0009109
11	517.436	0.59395	0.4285	0.97814	0.97218	0.97397	0.98775	0.81653	0.6693	0.37671	102.209	0.000901	0.000901	0.000901
12	564.12	0.58553	0.41545	0.97085	0.97315	0.98404	0.9919	0.83389	0.65438	0.36278	103.005	0.0008911	0.0008911	0.0008911
13	610.134	0.57956	0.41209	0.97179	0.97669	0.97669	0.99266	0.84097	0.64376	0.34778	103.046	0.0008812	0.0008812	0.0008812
14	656.202	0.5814	0.4072	0.97269	0.96644	0.9735	0.98784	0.84463	0.61353	0.36468	100.279	0.0008713	0.0008713	0.0008713
15	702.186	0.56981	0.39346	0.96206	0.97785	0.98221	0.99303	0.84586	0.62814	0.33438	100.031	0.0008614	0.0008614	0.0008614
16	748.241	0.56796	0.38866	0.96301	0.97114	0.97563	0.99207	0.83845	0.66714	0.35807	104.077	0.0008515	0.0008515	0.0008515
17	794.197	0.56063	0.37866	0.96171	0.98851	0.99257	0.99399	0.84486	0.64003	0.32011	102.302	0.0008416	0.0008416	0.0008416
18	840.193	0.55924	0.38	0.96093	0.98593	0.97126	0.99079	0.84956	0.61366	0.33731	101.959	0.0008317	0.0008317	0.0008317
19	886.279	0.55418	0.38167	0.95816	0.97808	0.98397	0.99275	0.8439	0.636	0.33358	102.718	0.0008218	0.0008218	0.0008218
20	931.919	0.55125	0.36903	0.95576	0.9722	0.96694	0.98838	0.839	0.63224	0.35578	101.581	0.0008119	0.0008119	0.0008119
21	977.487	0.56037	0.37012	0.95874	0.93309	0.96939	0.9872	0.83482	0.646	0.38551	102.079	0.000802	0.000802	0.000802
22	1023.06	0.55231	0.36244	0.95712	0.97521	0.97381	0.99052	0.85217	0.61248	0.33206	0.99999	0.0007921	0.0007921	0.0007921
23	1068.64	0.54458	0.35949	0.95171	0.95538	0.96583	0.97266	0.82878	0.62555	0.36264	101.241	0.0007822	0.0007822	0.0007822
24	1114.24	0.54285	0.3584	0.95586	0.98255	0.98909	0.99243	0.84547	0.61534	0.31288	100.154	0.0007723	0.0007723	0.0007723
25	1159.82	0.53375	0.35028	0.94641	0.99224	0.99275	0.9938	0.85634	0.60205	0.29953	0.99313	0.0007624	0.0007624	0.0007624
26	1205.71	0.5428	0.34998	0.94985	0.97339	0.94987	0.98695	0.84159	0.62858	0.35386	0.99445	0.0007525	0.0007525	0.0007525
27	1251.27	0.53605	0.35181	0.94943	0.97486	0.97526	0.98709	0.8468	0.61996	0.32424	101.974	0.0007426	0.0007426	0.0007426
28	1296.86	0.53581	0.34824	0.94709	0.97959	0.98301	0.99289	0.85581	0.61909	0.30721	1.015	0.0007327	0.0007327	0.0007327
29	1342.47	0.53325	0.34392	0.94766	0.94835	0.97934	0.98994	0.8564	0.61233	0.354	0.99836	0.0007228	0.0007228	0.0007228
30	1388.04	0.52595	0.33893	0.94443	0.98586	0.99234	0.99359	0.8526	0.61831	0.29541	0.99821	0.0007129	0.0007129	0.0007129
31	1433.59	0.52566	0.33441	0.94681	0.98493	0.99027	0.99408	0.85288	0.60574	0.2909	0.99677	0.000703	0.000703	0.000703
32	1479.17	0.52558	0.33518	0.94054	0.991	0.99487	0.99405	0.85097	0.61565	0.28004	0.99236	0.0006931	0.0006931	0.0006931
33	1525.39	0.51669	0.32908	0.93589	0.98414	0.99228	0.99399	0.85972	0.6087	0.28561	0.98273	0.0006832	0.0006832	0.0006832
34	1571.35	0.53297	0.33991	0.94392	0.96781	0.97322	0.98345	0.8447	0.61274	0.32837	0.99903	0.0006733	0.0006733	0.0006733
35	1617.24	0.52675	0.33776	0.94194	0.9814	0.99056	0.99336	0.8545	0.61433	0.2966	0.99582	0.0006634	0.0006634	0.0006634
36	1663.17	0.52255	0.3339	0.94299	0.99104	0.99114	0.99364	0.85353	0.6114	0.28876	100.362	0.0006535	0.0006535	0.0006535
37	1709.03	0.52256	0.32668	0.9389	0.98209	0.99192	0.99201	0.86012	0.60938	0.28876	0.98992	0.0006436	0.0006436	0.0006436
38	1755	0.51401	0.32623	0.9399	0.98923	0.98895	0.99374	0.86283	0.60081	0.27959	0.98625	0.0006337	0.0006337	0.0006337
39	1800.93	0.51702	0.32674	0.93826	0.97997	0.98569	0.99389	0.86211	0.61025	0.28925	0.99138	0.0006238	0.0006238	0.0006238
40	1847.12	0.52039	0.32364	0.94111	0.99592	0.99358	0.99429	0.85458	0.60912	0.27875	0.98038	0.0006139	0.0006139	0.0006139
41	1892.66	0.51312	0.31743	0.93646	0.98703	0.98922	0.99281	0.86279	0.61393	0.27791	0.99074	0.000604	0.000604	0.000604
42	1938.27	0.50908	0.31763	0.93479	0.99326	0.99164	0.99441	0.85709	0.62744	0.27335	0.99859	0.0005941	0.0005941	0.0005941
43	1984.7	0.5055	0.31793	0.93255	0.99223	0.99329	0.99421	0.86136	0.60038	0.26512	0.98224	0.0005842	0.0005842	0.0005842
44	2030.36	0.50548	0.31065	0.9291	0.93681	0.97242	0.96766	0.83405	0.61035	0.35311	0.99716	0.0005743	0.0005743	0.0005743
45	2075.94	0.50358	0.30718	0.92874	0.96259	0.93732	0.96653	0.83782	0.60298	0.37844	0.99231	0.0005644	0.0005644	0.0005644
46	2121.54	0.50241	0.30881	0.93153	0.98274	0.98633	0.99239	0.85829	0.6025	0.28125	0.99371	0.0005545	0.0005545	0.0005545
47	2167.36	0.49982	0.30371	0.92766	0.98966	0.99577	0.99444	0.86344	0.5958	0.25826	0.99374	0.0005446	0.0005446	0.0005446
48	2213.08	0.49618	0.29893	0.92826	0.9919	0.99328	0.99404	0.8662	0.60594	0.264	0.9941	0.0005347	0.0005347	0.0005347
49	2258.7	0.49458	0.30012	0.92654	0.99691	0.99514	0.99414	0.86162	0.60956	0.2596	0.99129	0.0005248	0.0005248	0.0005248
50	2304.31	0.49525	0.30228	0.92435	0.99288	0.99017	0.99443	0.85994	0.60575	0.26312	0.9922	0.0005149	0.0005149	0.0005149
51	2349.88	0.49436	0.30175	0.92821	0.99367	0.9956	0.99436	0.8685	0.59281	0.2626	0.97784	0.000505	0.000505	0.000505
52	2395.58	0.49761	0.30171	0.92332	0.98683	0.99134	0.99429	0.86501	0.59511	0.26452	0.98592	0.0004951	0.0004951	0.0004951
53	2441.18	0.48752	0.29305	0.92419	0.99404	0.99392	0.99434	0.8589	0.5992	0.25772	0.98253	0.0004852	0.0004852	0.0004852

54	2486.97	0.49245	0.29594	0.92699	0.99432	0.99527	0.99443	0.86717	0.59312	0.25172	0.98657	0.0004753	0.0004753	0.0004753
55	2533.36	0.49089	0.29417	0.92468	0.97012	0.99219	0.98942	0.85922	0.59594	0.27633	0.97893	0.0004654	0.0004654	0.0004654
56	2580.44	0.48937	0.28928	0.92235	0.98897	0.99491	0.99436	0.86746	0.6027	0.25439	0.99573	0.0004555	0.0004555	0.0004555
57	2627.23	0.479	0.28817	0.92222	0.99203	0.99439	0.99443	0.86956	0.5884	0.25019	0.9761	0.0004456	0.0004456	0.0004456
58	2673.72	0.47335	0.2829	0.91781	0.98796	0.99109	0.99439	0.86386	0.59999	0.25904	0.98887	0.0004357	0.0004357	0.0004357
59	2720.64	0.48106	0.28489	0.91689	0.99386	0.99627	0.9943	0.86031	0.60324	0.25034	0.99855	0.0004258	0.0004258	0.0004258
60	2767.55	0.48073	0.28834	0.92255	0.99323	0.98847	0.99439	0.86022	0.61261	0.25934	100.206	0.0004159	0.0004159	0.0004159
61	2814.48	0.47641	0.2831	0.91659	0.99221	0.99379	0.99401	0.86425	0.6053	0.2528	0.98562	0.000406	0.000406	0.000406
62	2861.26	0.47793	0.28011	0.91572	0.97451	0.97779	0.99216	0.86255	0.59818	0.27885	0.97743	0.0003961	0.0003961	0.0003961
63	2907.89	0.47359	0.28116	0.91207	0.99367	0.98648	0.99364	0.86774	0.60469	0.2604	0.98392	0.0003862	0.0003862	0.0003862
64	2954.35	0.46639	0.27076	0.91303	0.98496	0.99495	0.99417	0.86855	0.59799	0.25064	0.98495	0.0003763	0.0003763	0.0003763
65	3001.24	0.47688	0.27915	0.92035	0.98944	0.98713	0.99419	0.86622	0.59565	0.24914	0.97055	0.0003664	0.0003664	0.0003664
66	3047.94	0.47124	0.2748	0.91399	0.98815	0.99075	0.99367	0.86908	0.59125	0.25407	0.96817	0.0003565	0.0003565	0.0003565
67	3094.76	0.46634	0.27202	0.91339	0.99624	0.98618	0.9943	0.8689	0.59026	0.24887	0.97686	0.0003466	0.0003466	0.0003466
68	3141.24	0.4725	0.27343	0.91612	0.99473	0.98123	0.99436	0.86679	0.60158	0.25292	0.98563	0.0003367	0.0003367	0.0003367
69	3188.11	0.46665	0.26966	0.91455	0.9952	0.98728	0.99401	0.8736	0.59083	0.24597	0.98149	0.0003268	0.0003268	0.0003268
70	3234.89	0.46732	0.2676	0.91425	0.99203	0.98711	0.99395	0.86161	0.61397	0.25647	100.644	0.0003169	0.0003169	0.0003169
71	3281.89	0.46125	0.26623	0.91275	0.99427	0.9887	0.99374	0.87116	0.59033	0.24595	0.97726	0.000307	0.000307	0.000307
72	3328.87	0.46833	0.26841	0.91663	0.99284	0.98925	0.99414	0.87159	0.59142	0.24986	0.9803	0.0002971	0.0002971	0.0002971
73	3375.07	0.46428	0.26691	0.91526	0.9923	0.99225	0.99333	0.86826	0.60352	0.25177	0.98736	0.0002872	0.0002872	0.0002872
74	3421.28	0.46015	0.261	0.90898	0.98968	0.99215	0.99419	0.86866	0.59828	0.24654	0.98271	0.0002773	0.0002773	0.0002773
75	3467.47	0.45644	0.25782	0.90617	0.98999	0.98811	0.99392	0.86726	0.60359	0.24969	0.98776	0.0002674	0.0002674	0.0002674
76	3513.67	0.46103	0.26391	0.90806	0.99019	0.99491	0.99408	0.86631	0.60032	0.23806	0.98051	0.0002575	0.0002575	0.0002575
77	3559.84	0.45883	0.25822	0.91172	0.98964	0.98854	0.99397	0.86581	0.60199	0.2527	0.98596	0.0002476	0.0002476	0.0002476
78	3606.04	0.45616	0.25839	0.90845	0.9927	0.98389	0.99408	0.86712	0.60395	0.24854	0.98594	0.0002377	0.0002377	0.0002377
79	3652.09	0.44949	0.25528	0.90255	0.99438	0.98845	0.99415	0.86596	0.60392	0.24593	0.9973	0.0002278	0.0002278	0.0002278
80	3697.68	0.45031	0.25319	0.90499	0.99233	0.98707	0.99413	0.86954	0.59583	0.246	0.98432	0.0002179	0.0002179	0.0002179
81	3743.21	0.44892	0.24917	0.90619	0.99504	0.98133	0.99391	0.86561	0.60404	0.25186	0.98835	0.000208	0.000208	0.000208
82	3788.81	0.44369	0.24863	0.9048	0.99168	0.99219	0.99405	0.87023	0.5955	0.24034	0.98086	0.0001981	0.0001981	0.0001981
83	3834.33	0.44192	0.24542	0.9003	0.99301	0.98484	0.99357	0.8657	0.59634	0.24748	0.98381	0.0001882	0.0001882	0.0001882
84	3879.98	0.45157	0.24716	0.90459	0.98879	0.98725	0.99393	0.86926	0.59566	0.2437	0.97621	0.0001783	0.0001783	0.0001783
85	3925.53	0.43792	0.24441	0.89782	0.98636	0.99012	0.99405	0.87006	0.60019	0.24588	0.97568	0.0001684	0.0001684	0.0001684
86	3971.1	0.44361	0.24548	0.90075	0.98614	0.99268	0.99408	0.86921	0.60141	0.24516	0.97834	0.0001585	0.0001585	0.0001585
87	4016.63	0.44118	0.24482	0.90576	0.98743	0.99085	0.99427	0.86896	0.59943	0.24693	0.98786	0.0001486	0.0001486	0.0001486
88	4062.65	0.43997	0.24049	0.90216	0.98997	0.98788	0.99421	0.87288	0.58883	0.24597	0.97936	0.0001387	0.0001387	0.0001387
89	4108.84	0.4386	0.24054	0.90144	0.99123	0.98845	0.99419	0.86868	0.60158	0.25116	0.98925	0.0001288	0.0001288	0.0001288
90	4155.04	0.43935	0.24334	0.90762	0.99635	0.9837	0.99394	0.86946	0.59727	0.2514	0.9905	0.0001189	0.0001189	0.0001189
91	4202.06	0.37612	0.1925	0.85015	0.99314	0.98653	0.99386	0.86494	0.59806	0.24841	0.98902	0.000109	0.000109	0.000109
92	4248.05	0.372	0.18803	0.84547	0.99136	0.98738	0.99346	0.86676	0.59865	0.24929	0.98181	9.91e-05	9.91e-05	9.91e-05
93	4294.01	0.37245	0.18685	0.8475	0.98975	0.98775	0.99341	0.86856	0.59884	0.25161	0.9845	8.92e-05	8.92e-05	8.92e-05
94	4339.99	0.3685	0.18592	0.84332	0.98845	0.98956	0.99364	0.87129	0.59346	0.2474	0.97923	7.93e-05	7.93e-05	7.93e-05
95	4386.3	0.36753	0.18303	0.84514	0.98803	0.98728	0.99326	0.87236	0.59131	0.25007	0.98112	6.94e-05	6.94e-05	6.94e-05
96	4432.22	0.36635	0.18124	0.84252	0.98712	0.98386	0.99286	0.87193	0.5925	0.25272	0.98105	5.95e-05	5.95e-05	5.95e-05
97	4478.2	0.36315	0.1787	0.83964	0.98735	0.9877	0.99407	0.87218	0.59225	0.24365	0.97784	4.96e-05	4.96e-05	4.96e-05
98	4524.2	0.36111	0.17777	0.84184	0.98764	0.98623	0.99364	0.87097	0.59391	0.24881	0.97778	3.97e-05	3.97e-05	3.97e-05
99	4570.22	0.35968	0.17733	0.83933	0.98645	0.98747	0.99401	0.87245	0.59393	0.24731	0.97578	2.98e-05	2.98e-05	2.98e-05
100	4616.78	0.36027	0.17497	0.83927	0.98676	0.98859	0.99404	0.87358	0.59115	0.24489	0.97351	1.99e-05	1.99e-05	1.99e-05

Figura 3.8 Risultati dell'addestramento del modello YOLOv8.

L'addestramento del modello YOLOv8 ha evidenziato prestazioni estremamente elevate. La precisione finale superiore al 98% indica che il modello commette un numero molto ridotto di falsi positivi, mentre il recall oltre il 98% conferma la capacità di individuare correttamente quasi tutti gli oggetti presenti nelle immagini. Anche le metriche di accuratezza complessiva risultano particolarmente solide: il mAP@0.5 raggiunge valori prossimi al 99%, e il più severo

mAP@0.5:0.95 si attesta intorno al 90%, dimostrando una buona capacità di generalizzazione anche con soglie di *Intersection over Union* più restrittive.

Per quanto riguarda il comportamento delle *loss*, l'andamento osservato durante l'addestramento conferma la stabilità del modello. Le *loss* di *training* (*box*, *class* e DFL) mostrano una diminuzione costante, segnale di un apprendimento progressivo e regolare. Parallelamente, le *loss* di validazione rimangono stabili e prive di oscillazioni anomale, suggerendo l'assenza di fenomeni di *overfitting*. La *box loss* in validazione, pari a 0.59, risulta coerente con l'elevata accuratezza del *bounding box* ottenuta nelle metriche finali.

Nel complesso, questi risultati dimostrano che il modello YOLOv8 è in grado di classificare e localizzare con elevata affidabilità gli stadi di maturazione di mango e banana, confermandone l'idoneità per applicazioni *embedded* e sistemi di automazione intelligente.

Analisi qualitativa delle predizioni del modello

Le Figure 3.9–3.14 offrono una rappresentazione visiva chiara dell'efficacia del modello YOLOv8 durante la fase di validazione, mostrando il confronto tra le etichette reali (ground truth) e le predizioni generate dalla rete su tre batch differenti.

Nel primo caso, illustrato nella Figura 3.9, sono riportate le annotazioni manuali relative al batch 0, ottenute in un contesto ben illuminato e ordinato. I frutti risultano facilmente distinguibili e i *bounding box* appaiono accurati e privi di ambiguità. La Figura 3.10 mostra invece le predizioni del modello sul medesimo batch: l'allineamento con le etichette reali è pressoché totale. Tutte le classi vengono riconosciute correttamente, senza falsi positivi né errori di classificazione, e con livelli di confidenza superiori a 0.90, a conferma della precisione del modello sia nella localizzazione sia nell'assegnazione della classe.



Figura 3.9 Annotazioni manuali del batch 0, ottenute in condizioni ottimali e con frutti ben separati, utili come riferimento per la valutazione del modello.

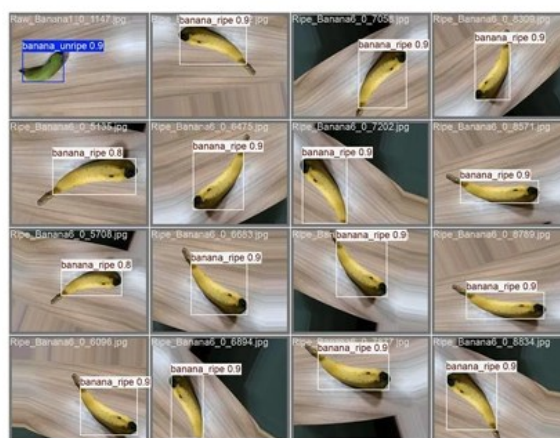


Figura 3.10 Predizioni del modello sul batch 0, perfettamente allineate alle etichette reali, senza errori né falsi positivi.

Le Figure 3.11 e 3.12 riguardano il batch 1, caratterizzato da condizioni più complesse: sfondi irregolari, illuminazione non uniforme e parziali occlusioni degli oggetti. Nonostante queste difficoltà, YOLOv8 mantiene prestazioni elevate. Le predizioni riportate nella Figura 3.12 risultano infatti molto vicine alle annotazioni reali, dimostrando la capacità del modello di operare in modo affidabile anche in scenari meno controllati e più simili a contesti applicativi reali.




Figura 3.11 Annotazioni del batch 1, caratterizzato da una disposizione più variabile dei frutti rispetto al batch precedente.



Figura 3.12 Predizioni del modello sul batch 1, accurate e coerenti con le etichette, con corretta identificazione di tutte le classi.

La Figura 3.14 presenta infine le predizioni relative al batch 2, che include casi particolarmente realistici, con frutti disposti in posizioni non canoniche o parzialmente ruotati. Anche in questo caso il comportamento del modello si conferma stabile e robusto: tutti gli oggetti vengono rilevati correttamente, con confidenze elevate e senza confusione tra classi visivamente simili, come nel caso di *banana_medium* e *banana_ripe*.



Figura 3.13 Annotazioni del batch 2, che include frutti in posizioni non canoniche o parzialmente ruotati.

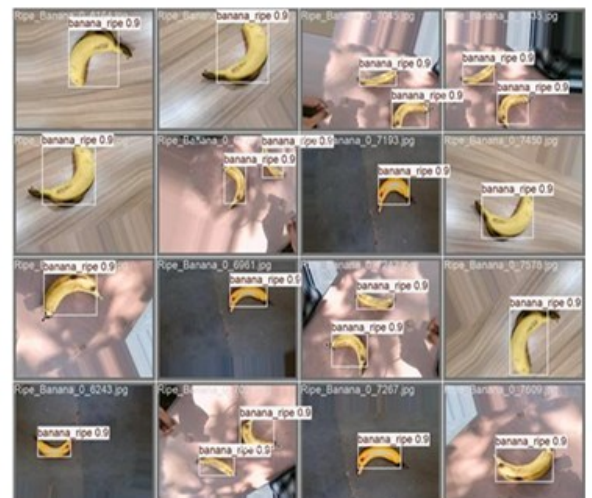


Figura 3.14 Predizioni del modello sul batch 2, tutte corrette e con confidenze elevate.

Nel complesso, l'analisi qualitativa delle immagini evidenzia l'elevato grado di affidabilità del modello YOLOv8. Le sue prestazioni risultano solide non solo in condizioni controllate, ma anche in scenari complessi e variabili, confermandone la potenziale applicabilità in sistemi robotici, *embedded* o in *pipeline* di controllo qualità operanti in tempo reale.

Le Figure 3.15–3.20 presentano una selezione di batch di validazione utilizzati per valutare in modo qualitativo le prestazioni del modello YOLOv8 nel riconoscimento e nella classificazione di mango e banane nei diversi stadi di maturazione.

Le Figure 3.15 e 3.16 mostrano le predizioni relative a batch caratterizzati da condizioni variabili di illuminazione, sfondo e inclinazione dei frutti. Nonostante queste differenze, il modello riesce a individuare correttamente gli oggetti, con *bounding box* ben posizionati anche in presenza di parziali occlusioni. I livelli di confidenza, sempre superiori a 0.90, confermano l'affidabilità del sistema anche in contesti non ideali.




Figura 3.15 Esempi di predizioni YOLOv8 su batch 0: buona localizzazione e classificazione dei frutti in condizioni controllate.




Figura 3.16 Validazione su batch 1: presenza di sfondi complessi, luci miste e occlusioni parziali.

Le Figure 3.17 e 3.18 illustrano scenari più complessi, con sfondi strutturati, oggetti di forma simile (come lime o avocado) e frutti parzialmente sovrapposti. Anche in queste condizioni, YOLOv8 mantiene un comportamento stabile, distinguendo correttamente tra frutti visivamente affini grazie a un apprendimento efficace delle *features* discriminanti.

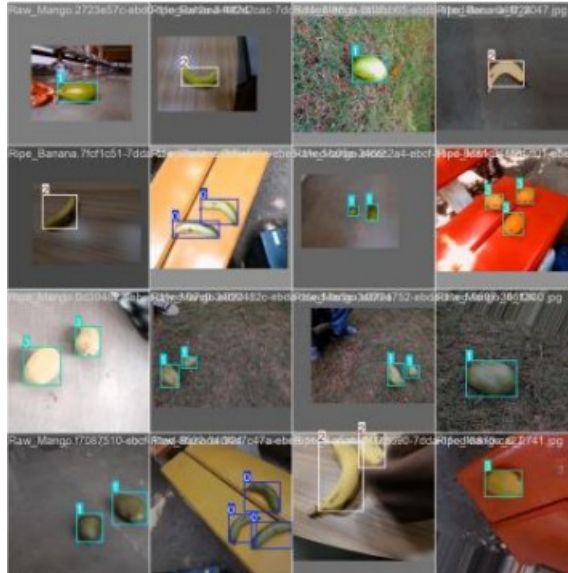


Figura 3.17 Robustezza del modello in presenza di frutti disposti in modo irregolare e variazioni di colore.




Figura 3.18 Prestazioni su frutti maturi e non maturi con possibili ambiguità visive tra mango e banana.

Le Figure 3.19 e 3.20 includono infine esempi con presenza mista di mango e banane in diversi stadi di maturazione. Il modello riesce a differenziare correttamente classi molto vicine, come *banana_ripe* e *banana_medium*, mostrando una buona capacità di generalizzazione. Si osserva soltanto una lieve variabilità nei contorni dei *bounding box*, attribuibile alle variazioni di posizione, scala e orientamento dei frutti.




Figura 3.19 Batch misto con diverse classi e livelli di maturazione: alta precisione nei bounding box.




Figura 3.20 Analisi qualitativa finale su frutti multipli e ambienti reali: il modello mantiene alte prestazioni.

Nel complesso, l'analisi qualitativa delle immagini conferma quanto emerso dalle metriche quantitative (mAP, precisione e recall): il modello YOLOv8 è in grado di operare in modo affidabile anche in condizioni ambientali eterogenee, dimostrando la sua idoneità per un possibile deployment in scenari reali, inclusi sistemi robotici e piattaforme *embedded*.

Architettura funzionale del sistema *embedded* per il rilevamento e la classificazione dei frutti

Nel corso dello sviluppo del sistema *embedded* dedicato al rilevamento e alla classificazione automatica di mango e banane, è stata progettata un'architettura funzionale in grado di operare in ambienti agricoli o industriali, garantendo l'acquisizione dei dati, l'elaborazione locale e la trasmissione in tempo reale delle informazioni a un cobot o a un sistema robotico remoto. L'intero sistema è organizzato in moduli indipendenti ma strettamente interconnessi, ciascuno con un ruolo specifico all'interno della *pipeline* operativa.

Il Raspberry Pi 4 Model B (8 GB) costituisce l'unità centrale di controllo e rappresenta il nodo di coordinamento dell'intero sistema. Questo *single-board* computer gestisce i flussi dati provenienti dalla telecamera OAK-Lite, dal modulo di comunicazione 5G e dai sistemi di alimentazione, orchestrando sia l'elaborazione locale sia la trasmissione delle informazioni verso l'esterno. La sua architettura compatta, unita alla capacità di eseguire operazioni di *edge* computing, lo rende particolarmente adatto a scenari mobili e privi di alimentazione continua. La telecamera OAK-Lite, collegata via USB, esegue direttamente a bordo l'inferenza tramite un modello YOLOv8 ottimizzato. Questo consente di rilevare in tempo reale la presenza di mango e banane, identificarne la classe di appartenenza e stimarne la dimensione attraverso *bounding box* calibrati. I dati generati dalla telecamera includono tipologia del frutto, grado di maturazione e coordinate spaziali all'interno dell'immagine, che vengono immediatamente trasferiti al Raspberry Pi per l'elaborazione successiva.

Una volta ricevute le informazioni dalla telecamera, il Raspberry Pi esegue la stima delle dimensioni reali dei frutti, convertendo le misure in pixel in valori metrici grazie a un processo di calibrazione preliminare. Questo passaggio consente di ottenere parametri geometrici utili per la manipolazione robotica, come altezza, larghezza e posizione relativa rispetto al piano operativo.

La trasmissione dei dati elaborati avviene tramite il modulo 5G Quectel RM500U-CNV, anch'esso collegato via USB. Il modulo gestisce la connessione alla rete 5G NR, sia in modalità SA sia NSA, permettendo l'invio in tempo reale delle informazioni al cobot o a un server remoto. I dati trasmessi includono le coordinate dei frutti, la classe di maturazione e, quando necessario, anche un flusso video live per il monitoraggio visivo continuo.

La comunicazione può avvenire tramite protocolli leggeri come MQTT o tramite socket TCP/IP e HTTP, a seconda delle esigenze operative.

Il sistema è alimentato a batteria, caratteristica che ne garantisce la portabilità e l'autonomia anche in ambienti privi di alimentazione stabile. Il Raspberry Pi è inoltre in grado di monitorare parametri critici come tensione e temperatura interna, intervenendo automaticamente in caso di anomalie per preservare la continuità operativa.

Nel complesso, l'architettura sviluppata integra in modo efficace intelligenza artificiale, connettività 5G e controllo robotico in un modulo compatto e autonomo. Il Raspberry Pi 4 agisce come vero e proprio "cervello operativo" del sistema, coordinando sensori, unità di elaborazione e moduli di comunicazione, e garantendo un funzionamento affidabile anche in condizioni di campo. Questa configurazione dimostra la fattibilità di soluzioni *embedded* avanzate per l'automazione agricola di nuova generazione, in grado di supportare attività come la selezione, la raccolta e il controllo qualità dei frutti in tempo reale.

Discussione

I risultati ottenuti dal secondo progetto aziendale offrono un quadro significativo per interpretare e valorizzare gli obiettivi del progetto cardine della tesi, nonostante l'impossibilità di testare direttamente la Food Monitoring Board (FMB) nei tempi previsti. L'implementazione di un sistema *embedded* basato su telecamera OAK-Lite, connettività 5G e modello di visione artificiale YOLOv8, ha dimostrato la fattibilità tecnica di una classificazione automatica degli stadi di maturazione di mango e banana. La capacità del modello di distinguere tra frutti acerbi, in media maturazione e maturi conferma che la maturazione produce segnali visivi sufficientemente strutturati da essere riconosciuti da un sistema di intelligenza artificiale in tempo reale. Questo risultato è particolarmente rilevante perché mostra come *pipeline* di analisi basate su deep learning possano essere integrate in dispositivi compatti e a basso consumo, aprendo la strada a soluzioni applicabili anche in contesti domestici.

Tuttavia, l'analisi critica dei dati e della letteratura evidenzia anche i limiti di un approccio esclusivamente visivo. Nel caso del mango, e in particolare della cv *Kensington Pride*, la colorazione esterna non rappresenta un indicatore affidabile dello stato di maturazione, poiché è fortemente influenzata dall'esposizione solare più che dal reale avanzamento fisiologico del frutto (Nordey *et al.*, 2014). Questo limite è emerso anche nell'interpretazione dei risultati del secondo progetto, dove alcune variazioni cromatiche non corrispondevano a differenze effettive nello stadio di maturazione. Tale evidenza conferma quanto riportato dalla letteratura sui pigmenti del mango: la buccia può mostrare variazioni significative di antociani, clorofille e carotenoidi indipendentemente dalla maturazione, rendendo la sola visione artificiale un indicatore parziale e potenzialmente fuorviante.

In questo contesto, gli studi sui VOCs della banana e del mango assumono un ruolo centrale. La ricerca scientifica dimostra che l'emissione di VOCs: in particolare etanolo, esteri e aldeidi, segue *pattern* fisiologici strettamente correlati alla maturazione e al deterioramento, risultando marcatori più affidabili rispetto al colore della buccia. L'integrazione di un sensore VOC all'interno del sistema robotico del secondo progetto, e in prospettiva nella FMB, rappresenterebbe quindi un'evoluzione naturale e necessaria per ottenere una stima più robusta della *shelf-life*. L'approccio multimodale, basato sulla combinazione di segnali visivi e chimico-sensoriali, risulta infatti più coerente con la fisiologia dei frutti e con le dinamiche reali del deterioramento.

La solidità di questa direzione progettuale trova conferma nella letteratura scientifica recente. Lo studio di Zhao *et al.* (2024) mostra come l'integrazione tra un naso elettronico e modelli di deep learning consenta di ottenere classificazioni accurate e non distruttive dello stato di

maturazione. Sebbene il dispositivo descritto dagli autori differisca dalla FMB per architettura e finalità applicative, il parallelismo metodologico è evidente: entrambi i sistemi raccolgono dati metabolici e visivi per stimare la maturazione e prevedere la *shelf-life* residua. Il fatto che soluzioni analoghe siano oggetto di pubblicazioni internazionali conferma che lo sviluppo di dispositivi domestici per il monitoraggio della conservazione degli alimenti non è un'iniziativa isolata, ma si inserisce in un filone di ricerca attuale e riconosciuto, rafforzando la legittimità dell'obiettivo aziendale.

Queste considerazioni mettono in luce il fatto che il secondo progetto aziendale non rappresenti un semplice caso parallelo, ma un tassello fondamentale per comprendere la trasferibilità delle metodologie al contesto domestico. La classificazione visiva ottenuta tramite YOLOv8 dimostra la fattibilità di un sistema *embedded* per il riconoscimento degli stadi di maturazione; la letteratura sui VOC evidenzia la necessità di integrare sensori olfattivi per una stima più accurata della *shelf-life*; e il confronto con studi recenti conferma la rilevanza scientifica e applicativa dell'approccio multimodale. Questi elementi, considerati nel loro insieme, rafforzano la prospettiva che la FMB possa rappresentare una soluzione innovativa e concreta per la riduzione dello spreco alimentare domestico, contribuendo a una gestione più consapevole e sostenibile degli alimenti freschi.

Robustezza del modello

Le elevate performance ottenute sia in fase di *training* sia in fase di validazione indicano che il modello generalizza correttamente e non mostra segni di sovra-allenamento. Questo comportamento conferma la stabilità dell'apprendimento e la capacità del modello di adattarsi a dati non visti senza degradare in accuratezza.

Nel complesso, YOLOv8 si è dimostrato altamente performante per il compito di classificazione e localizzazione dei frutti, raggiungendo livelli di precisione e recall tali da renderlo idoneo a scenari *real-time*. Le sue caratteristiche lo rendono adatto all'integrazione in robot agricoli, sistemi *embedded* come OAK-D e *pipeline* di controllo qualità automatizzate.

Nonostante le prestazioni eccellenti, sono possibili ulteriori miglioramenti per aumentare la robustezza e l'adattabilità del sistema:

- Test in ambienti reali con condizioni di illuminazione variabili, per valutare la resilienza del modello fuori dal contesto controllato del dataset.
- *Data augmentation* avanzata, utile per simulare scenari complessi e aumentare la diversità dei campioni di addestramento.
- Quantizzazione del modello per ottimizzare l'inferenza su dispositivi *edge*, riducendo latenza e consumo energetico senza compromettere significativamente l'accuratezza.

Discussione dei risultati ottenuti dal sistema *embedded*

I risultati sperimentali ottenuti dal sistema *embedded* basato su Raspberry Pi 4, telecamera OAK-Lite e modulo 5G evidenziano un livello di affidabilità e stabilità molto elevato, confermando la validità dell'architettura progettata per applicazioni di rilevamento e classificazione dei frutti in scenari reali. Le prestazioni qualitative osservate nei batch di validazione mostrano come il modello YOLOv8, eseguito direttamente sulla telecamera, sia in grado di mantenere un comportamento coerente anche in condizioni ambientali non ottimali, caratterizzate da illuminazione variabile, sfondi complessi, occlusioni parziali e presenza di frutti visivamente simili.

La capacità del sistema di distinguere correttamente tra classi molto vicine, come: *banana_medium* e *banana_ripe*, rappresenta un indicatore importante della qualità dell'apprendimento delle caratteristiche e della robustezza del modello. Allo stesso modo, la stabilità dei *bounding box* e l'elevato livello di confidenza delle predizioni confermano che l'inferenza on-device tramite OAK-Lite non compromette la precisione del modello, ma anzi consente un'elaborazione rapida e affidabile, adatta a scenari *real-time*.

Un ulteriore elemento di rilievo riguarda la gestione della *pipeline* dati da parte del Raspberry Pi. La capacità di ricevere le predizioni dalla telecamera, stimare le dimensioni reali dei frutti tramite calibrazione e trasmettere le informazioni al cobot tramite rete 5G dimostra che il sistema è in grado di operare come nodo *edge* autonomo, riducendo la dipendenza da infrastrutture esterne e garantendo tempi di risposta compatibili con applicazioni robotiche. L'integrazione del modulo 5G, inoltre, abilita scenari operativi distribuiti, nei quali l'unità *embedded* può comunicare con robot o server remoti anche in ambienti agricoli isolati.

Nel complesso, i risultati ottenuti confermano che l'architettura proposta è non solo funzionale, ma anche scalabile e trasferibile a contesti applicativi più ampi. La combinazione di inferenza locale, comunicazione a bassa latenza e autonomia energetica rende il sistema adatto a operazioni di raccolta, selezione o monitoraggio continuo, aprendo la strada a soluzioni di automazione agricola di nuova generazione.

Trasferibilità dell'approccio di visione artificiale: dal sistema OAK-Lite alla FMB

La FMB integra già una componente visiva tramite la fotocamera OV2640, utilizzata per acquisire immagini dell'alimento presente nel contenitore. Tale sensore, pur essendo caratterizzato da una risoluzione limitata (2 MP) e da un ridotto carico computazionale, è pienamente adeguato al riconoscimento della tipologia di alimento, funzione essenziale per contestualizzare correttamente i dati provenienti dal naso elettronico e dagli altri sensori

ambientali. L'elaborazione delle immagini non avviene localmente, poiché l'ESP32-CAM non dispone della potenza necessaria per eseguire modelli complessi di visione artificiale; tuttavia, la trasmissione delle immagini a un server esterno consente di demandare l'analisi a sistemi più performanti.

In questo quadro, i risultati ottenuti nel secondo progetto aziendale, basato sulla telecamera OAK-Lite e sul modello YOLOv8, assumono un ruolo particolarmente rilevante. Le metriche di addestramento e validazione mostrano valori molto elevati di precisione, *recall* e mAP, evidenziando la capacità del modello di distinguere con grande affidabilità i frutti nei diversi stadi di maturazione. Queste prestazioni dimostrano la solidità dell'approccio basato sulla visione artificiale e costituiscono una validazione preliminare dell'efficacia di una *pipeline* analoga anche nel contesto della FMB.

Sebbene la FMB utilizzi un hardware più semplice rispetto alla OAK-Lite, la logica di funzionamento rimane coerente: la fotocamera acquisisce immagini, che vengono poi elaborate esternamente da un modello di classificazione. In questo modo, la componente visiva della FMB può essere potenziata sfruttando modelli avanzati come YOLOv8, senza compromettere i vincoli energetici e computazionali del dispositivo. L'elevata affidabilità dimostrata dal sistema OAK-Lite suggerisce che l'integrazione di un modello di visione artificiale più sofisticato potrebbe migliorare significativamente la capacità della FMB di riconoscere gli alimenti e di associare correttamente i *pattern* metabolici e volatili alla specifica categoria di prodotto monitorato.

La valutazione comparativa tra i due progetti mette quindi in luce una continuità metodologica: entrambi i sistemi si basano sull'acquisizione di immagini e sulla loro interpretazione tramite algoritmi di intelligenza artificiale, seppur con livelli di complessità differenti. I risultati del cobot confermano che la visione artificiale rappresenta un approccio robusto e trasferibile, capace di supportare in modo efficace la stima della maturazione e della *shelf-life*. Infine, l'analisi bibliografica condotta sulla cultivar *Kensington Pride* ha evidenziato come la sola informazione visiva non sia sempre sufficiente per valutare correttamente lo stato di maturazione, poiché la colorazione esterna può essere influenzata da fattori non correlati al reale grado di maturazione. Questo elemento rafforza ulteriormente la prospettiva di integrare, sia nel cobot sia nella FMB, un sensore dedicato alla rilevazione dei composti organici volatili (VOC). La combinazione di segnali visivi e chimico-sensoriali rappresenta infatti un approccio più completo e affidabile, capace di migliorare la precisione delle previsioni sulla *shelf-life* e di contribuire in modo significativo alla riduzione dello spreco alimentare.

Dopo aver analizzato la trasferibilità dell'approccio visivo, è utile ampliare la prospettiva e considerare anche la coerenza metodologica complessiva tra i due sistemi.

Trasferibilità metodologica tra il sistema OAK-Lite e la Food Monitoring Board

La comparazione tra il sistema *embedded* basato su telecamera OAK-Lite e la FMB mette in evidenza una forte coerenza metodologica, nonostante le differenze hardware e i diversi contesti applicativi. Entrambi i sistemi condividono infatti la stessa logica operativa: acquisire dati in tempo reale, elaborarli tramite algoritmi di intelligenza artificiale e trasmettere informazioni strutturate a un'unità remota per supportare processi decisionali automatizzati. Questa continuità rappresenta un elemento chiave per valutare la trasferibilità dell'approccio visivo adottato nel progetto OAK-Lite al contesto della FMB.

Un primo parallelismo riguarda la *pipeline* di acquisizione dei dati. Nel sistema *embedded* agricolo, la telecamera OAK-Lite acquisisce immagini e fornisce informazioni dettagliate su classe, maturazione e posizione dei frutti. Nella FMB, la fotocamera OV2640 svolge una funzione analoga di acquisizione visiva, seppur con un hardware più semplice e senza capacità di elaborazione locale. In entrambi i casi, l'immagine costituisce il punto di partenza per una *pipeline* di classificazione basata su modelli di visione artificiale, con la differenza che nella FMB l'inferenza viene delegata a un server esterno. Questa analogia conferma che la componente visiva della FMB può essere potenziata sfruttando modelli avanzati come YOLOv8, mantenendo al contempo bassi consumi energetici.

Un secondo elemento di continuità riguarda la trasmissione dei dati. Il sistema OAK-Lite utilizza un modulo 5G per inviare informazioni al cobot, mentre la FMB prevede la comunicazione verso un'applicazione mobile o un server remoto per la gestione della *shelf-life*. In entrambi i sistemi, la comunicazione wireless è fondamentale per abilitare scenari IoT distribuiti e per integrare i dispositivi in ecosistemi più ampi. I risultati del progetto OAK-Lite dimostrano inoltre che protocolli leggeri e affidabili sono compatibili con applicazioni *real-time*, suggerendo la loro possibile adozione anche nella FMB.

Un ulteriore parallelismo riguarda la scalabilità e modularità dell'architettura. Il sistema *embedded* dimostra che è possibile integrare visione artificiale, *edge computing* e connettività avanzata in un modulo compatto e autonomo. Questa evidenza è rilevante per la FMB, che può evolvere verso un'architettura ibrida in cui l'acquisizione avviene a bordo e l'elaborazione è demandata a un server esterno. Tale approccio consentirebbe di integrare modelli predittivi basati sia su immagini sia su VOC, migliorando la capacità del sistema di stimare la *shelf-life* in modo dinamico e personalizzato.

Infine, la robustezza del modello YOLOv8 nel riconoscere frutti in condizioni ambientali variabili rappresenta un'indicazione importante per la FMB. L'elevata accuratezza ottenuta nelle predizioni suggerisce che la visione artificiale può essere utilizzata non solo per identificare la tipologia di alimento, ma anche per supportare o validare le misure sensoriali del naso elettronico. L'integrazione di segnali visivi e chimico-sensoriali potrebbe quindi migliorare significativamente l'affidabilità delle stime di maturazione e qualità.

Nel complesso, il parallelismo tra i due progetti evidenzia una forte complementarità: il sistema OAK-Lite fornisce evidenze sperimentali sulla fattibilità e affidabilità di un'architettura basata su visione artificiale, mentre la FMB rappresenta il contesto applicativo ideale per trasferire tali tecnologie in un sistema avanzato di monitoraggio della *shelf-life*. Questa convergenza metodologica conferma la validità delle scelte progettuali e apre la strada a future integrazioni tra i due sistemi.

Confronto con la letteratura: lo studio di Zhao *et al.*

Il confronto con lo studio di Zhao *et al.* (2024) consente di collocare i risultati ottenuti nel presente lavoro all'interno del panorama scientifico più recente, evidenziando punti di convergenza, differenze metodologiche e potenziali sinergie tra approcci basati su visione artificiale e sistemi olfattivi artificiali. Lo studio propone un sistema integrato per la valutazione della maturazione dei frutti fondato sull'impiego di matrici di sensori colorimetrici cross-reattivi e modelli di deep learning, con l'obiettivo di ottenere una classificazione accurata e non distruttiva degli stadi di maturazione.

Un primo elemento di interesse riguarda la sensibilità e la capacità discriminante delle matrici colorimetriche. Zhao *et al.* dimostrano che specifici coloranti, tra cui: pararosanilina, merocianina 540 e blu di bromofenolo, sono in grado di rilevare variazioni cromatiche proporzionali alla concentrazione dei VOC, con limiti di rilevabilità fino a 10 ppm per composti chiave come il trans-2-esenale. L'analisi quantitativa basata sulla distanza euclidea e le mappe differenziali RGB confermano la capacità delle matrici di distinguere *pattern* chimici complessi, mentre l'HCA evidenzia una separazione netta tra nove VOC caratteristici della maturazione. Questi risultati sottolineano l'efficacia dei sensori colorimetrici come strumenti non distruttivi per il monitoraggio delle trasformazioni post-raccolta.

Parallelamente, l'impiego di modelli di deep learning, in particolare DenseNet, ha permesso di ottenere accuratezze molto elevate, pari al 97,39% sul set di validazione e all'82,20% su un set di test indipendente. L'uso di Grad-CAM ha inoltre fornito un livello di interpretabilità utile a identificare i coloranti maggiormente influenti nella classificazione, evidenziando la solidità del modello e la sua capacità di generalizzare su dati non visti.

Nel complesso, lo studio dimostra che l'integrazione tra sensori colorimetrici e reti neurali profonde rappresenta un approccio promettente per la valutazione della maturazione e della *shelf-life*.

Il confronto con il sistema *embedded* sviluppato in questo progetto mette in luce differenze significative nelle tecnologie e negli obiettivi applicativi, pur partendo da presupposti metodologici simili. Mentre Zhao *et al.* si concentrano sull'analisi dei VOC e sulla costruzione di impronte olfattive, il sistema *embedded* proposto in questa tesi si basa sulla visione artificiale e sull'inferenza on-device tramite YOLOv8, con l'obiettivo di ottenere una classificazione rapida e operativa in contesti reali. L'approccio visivo presenta vantaggi in termini di immediatezza, portabilità e integrazione con sistemi robotici, mentre quello colorimetrico offre una caratterizzazione chimica più profonda e sensibile alle trasformazioni fisiologiche interne del frutto.

Queste differenze rendono i due approcci fortemente complementari. I risultati di Zhao *et al.* forniscono una base scientifica solida per l'integrazione di sensori VOC nella FMB, confermando che i composti volatili rappresentano marcatori affidabili della maturazione. Allo stesso tempo, i risultati ottenuti dal sistema *embedded* dimostrano che la visione artificiale può costituire un ulteriore livello informativo, utile per validare o arricchire le misure VOC, soprattutto in scenari dinamici o outdoor. La combinazione dei due approcci, chimico e visivo, potrebbe quindi rappresentare un'evoluzione naturale della FMB, migliorandone la capacità predittiva e la robustezza operativa.

Infine, è importante sottolineare che, mentre il sistema di Zhao *et al.* è concepito come piattaforma sperimentale validata in laboratorio, il progetto aziendale mira allo sviluppo di un dispositivo smart destinato all'ambito domestico o alla filiera agricola, con requisiti di semplicità d'uso, miniaturizzazione e autonomia operativa. In questo senso, la letteratura fornisce un riferimento metodologico prezioso, ma la trasposizione pratica richiede un adattamento tecnologico orientato alla fruibilità quotidiana e alla gestione reale della *shelf-life*. Nel complesso, il confronto con Zhao *et al.* (2024) rafforza la validità scientifica del lavoro svolto, evidenziando come il sistema *embedded* e la FMB si inseriscano in un filone di ricerca attuale e promettente. L'integrazione futura di sensori VOC e modelli di visione artificiale potrebbe rappresentare un passo decisivo verso sistemi predittivi avanzati, capaci di supportare la riduzione dello spreco alimentare e la gestione intelligente della qualità dei prodotti ortofrutticoli.

Conclusioni

Lo spreco alimentare domestico rappresenta una delle principali sfide della filiera agroalimentare contemporanea, con impatti rilevanti sul piano economico, ambientale e sociale. In questo contesto, la gestione della *shelf-life* degli alimenti freschi costituisce un nodo centrale: i modelli statici basati su date di scadenza predefinite non riflettono le reali condizioni di conservazione e contribuiscono a un utilizzo inefficiente delle risorse.

La tesi ha affrontato questa problematica proponendo e analizzando lo sviluppo di un dispositivo domestico integrato hardware/software, la Food Monitoring Board (FMB), concepito per monitorare in tempo reale lo stato di conservazione dei prodotti vegetali freschi attraverso l'integrazione di sensori ambientali, naso elettronico, fotocamera e algoritmi di intelligenza artificiale.

I risultati ottenuti nei primi tre Obiettivi Realizzativi del progetto cardine hanno permesso di definire le fondamenta tecnologiche della FMB. L'ingegnerizzazione dell'hardware ha portato alla realizzazione di un prototipo robusto, sicuro e adatto all'uso domestico, mentre lo sviluppo dei sistemi di riconoscimento degli alimenti e del grado di maturazione ha confermato la fattibilità di un approccio multimodale basato sulla combinazione di segnali visivi, VOC e parametri ambientali. Questa integrazione rappresenta il nucleo concettuale della FMB e costituisce la base per la futura modellazione predittiva della *shelf-life*.

Poiché il prototipo finale non è stato testato nei tempi previsti, la tesi ha integrato i risultati di un secondo progetto aziendale sviluppato nel contesto dell'agricoltura 4.0. Questo sistema *embedded*, basato su telecamera OAK Lite, connettività 5G e modello YOLOv8, ha dimostrato la fattibilità tecnica di un'architettura *edge* AI capace di classificare in tempo reale lo stadio di maturazione di mango e banana. Le elevate performance ottenute, unite alla stabilità dell'inferenza on device, confermano che *pipeline* di visione artificiale possono essere integrate in dispositivi compatti e a basso consumo, aprendo prospettive concrete per applicazioni domestiche e fornendo una validazione preliminare dell'approccio visivo previsto nella FMB.

La discussione dei risultati ha evidenziato anche i limiti di un approccio esclusivamente visivo, in particolare per frutti come il mango, la cui colorazione esterna non è sempre correlata allo stato fisiologico. La letteratura scientifica, e in particolare lo studio di Zhao *et al.* (2024), conferma che i VOC rappresentano marcatori più affidabili della maturazione e che l'integrazione tra sensori olfattivi e modelli di deep learning consente di ottenere classificazioni accurate e non distruttive. Il confronto tra i due progetti aziendali e la letteratura ha quindi rafforzato la validità dell'approccio multimodale adottato dalla FMB,

evidenziando come la combinazione di segnali visivi e chimico-sensoriali sia la strada più promettente per una stima robusta e dinamica della shelf life.

Nel complesso, il lavoro svolto dimostra che la FMB non è solo tecnicamente realizzabile, ma si colloca in un filone di ricerca attuale, riconosciuto e supportato da evidenze scientifiche. L'integrazione di sensori avanzati, algoritmi di machine learning e tecnologie *edge* rappresenta una soluzione concreta per supportare il consumatore nella gestione quotidiana del cibo, contribuendo alla riduzione dello spreco alimentare domestico e alla promozione di modelli di consumo più sostenibili.

Prospettive future del progetto: sviluppo dei modelli predittivi, applicazione mobile e prototipazione finale

Gli Obiettivi Realizzativi (OR) 4, 5 e 6 delineano il percorso attraverso cui la FMB potrà evolvere da prototipo funzionale a sistema completo e pienamente operativo. L'OR4 costituisce il nucleo scientifico del progetto, poiché introduce la componente predittiva che consente di trasformare la FMB da semplice dispositivo di monitoraggio a strumento decisionale avanzato. In questa fase è prevista la realizzazione di un software basato su tecniche di machine learning, capace di riconoscere automaticamente i prodotti inseriti nel dispositivo, valutarne lo stadio di maturazione e prevederne l'evoluzione nel tempo attraverso la stima della *shelf-life* dinamica. La costruzione di tale modello sarà resa possibile dalla disponibilità di un dataset completo relativo a cento prodotti alimentari, acquisito in condizioni e stadi di maturazione differenti. L'obiettivo prestazionale fissato prevede un margine di errore inferiore al 10% nelle previsioni settimanali, traguardo che richiede algoritmi robusti, un dataset ampio e una validazione condotta in condizioni reali di conservazione.

Un aspetto particolarmente rilevante dell'OR4 riguarda la capacità del sistema di migliorare progressivamente le proprie prestazioni grazie alla condivisione dei dati tra i dispositivi installati presso gli utenti. Questo approccio consentirà di ampliare nel tempo il dataset globale, adattare i modelli a condizioni ambientali e abitudini di consumo eterogenee e ridurre progressivamente l'errore predittivo. Il software dovrà inoltre garantire l'acquisizione dei dati in tempo reale e la loro condivisione con l'utente, nel pieno rispetto della normativa vigente in materia di privacy attraverso procedure di anonimizzazione. La fase conclusiva dell'OR4 prevede il test del sistema di intelligenza artificiale, volto a verificarne la velocità di elaborazione, l'accuratezza predittiva, la stabilità e la fruibilità tramite l'applicazione mobile.

L'OR5 riguarda lo sviluppo dell'applicazione mobile, destinata a costituire l'interfaccia principale tra il dispositivo e l'utente finale. Poiché la FMB non dispone di un display fisico, l'app rappresenta l'unico canale di interazione con il sistema e deve pertanto essere intuitiva,

accessibile e compatibile anche con dispositivi Android e iOS di generazioni precedenti. La progettazione dell'applicazione prenderà avvio dall'analisi dei flussi logici del software di intelligenza artificiale, cui seguirà la realizzazione di un *mockup* utile sia per finalità comunicative sia per raccogliere feedback da un campione di potenziali utilizzatori. Lo sviluppo del *front-end* e del *back-end* richiederà un'integrazione accurata con il sistema di intelligenza artificiale, mentre la costruzione del database permetterà di gestire in modo efficiente i dati raccolti. La fase di test e debug, condotta anche tramite interviste ai consumatori finali, sarà essenziale per garantire un'esperienza d'uso fluida e priva di criticità.

L'OR6 rappresenta la fase conclusiva del progetto e prevede la realizzazione di un prototipo integrato che unisca l'hardware sviluppato negli OR1-3, i modelli predittivi dell'OR4 e l'applicazione mobile dell'OR5. Il dispositivo finale dovrà rispettare requisiti stringenti in termini di peso, resistenza agli urti, tolleranza al lavaggio e compatibilità con i detergenti comunemente utilizzati in ambito domestico. Il modulo di rilevazione, applicato al coperchio della scatola, dovrà essere in grado di identificare il contenuto e il grado di maturazione dei prodotti, rendendo disponibili i dati sull'applicazione in tempi brevi. Un elemento particolarmente innovativo è rappresentato dalla capacità del sistema di apprendere dai dati raccolti, contribuendo all'espansione di un dataset globale condiviso tra tutti i dispositivi installati. La fase finale dell'OR6 prevede la sincronizzazione completa tra hardware, software e applicazione mobile, seguita da un'estesa attività di testing e debug condotta anche con utenti reali, al fine di garantire affidabilità, accuratezza e facilità d'uso.

La tesi dimostra che l'integrazione di sensori avanzati, visione artificiale e modelli di intelligenza artificiale rappresenta una strategia efficace per affrontare il problema dello spreco alimentare domestico. Il lavoro svolto costituisce un passo significativo verso la realizzazione di un dispositivo intelligente per la gestione dinamica della *shelf-life* e fornisce un contributo concreto alla definizione delle basi tecnologiche e metodologiche del progetto. Sebbene l'attività sviluppata in questa tesi rappresenti solo una parte del più ampio programma di ricerca e sviluppo portato avanti dall'azienda, essa si inserisce in modo coerente all'interno di un percorso progettuale articolato, contribuendo a orientare scelte tecniche, a supportare la validazione preliminare delle tecnologie adottate e a consolidare la visione multimodale alla base della FMB.

Le analisi condotte, la revisione critica della letteratura, la valutazione delle tecnologie sensoriali e l'integrazione dei risultati provenienti dal progetto di applicazione agricola costituiscono un patrimonio informativo che sarà di utilità per le fasi successive del lavoro aziendale. In particolare, le considerazioni emerse in questa tesi potranno supportare lo sviluppo

dei modelli predittivi, la progettazione dell'applicazione mobile e la futura prototipazione del sistema integrato, contribuendo a ridurre l'incertezza progettuale e a guidare le scelte tecniche verso soluzioni più robuste ed efficaci.

La FMB ha il potenziale per diventare uno strumento innovativo e concreto per la riduzione dello spreco alimentare, contribuendo alla transizione verso un sistema alimentare più sostenibile, efficiente e consapevole. Il progetto, nella sua interezza, continuerà ad evolvere ben oltre i confini di questo elaborato, e il lavoro svolto rappresenta un tassello iniziale ma significativo di un percorso di sviluppo più ampio, che nei prossimi mesi e anni potrà tradursi in un prodotto maturo, affidabile e realmente utile per i consumatori.

Bibliografia

- Agama-Acevedo E, Nuñez-Santiago MC, Alvarez-Ramirez J, Bello Pérez LA (2015) Physicochemical, digestibility and structural characteristics of starch isolated from banana cultivars. *Carbohydr Polym* 124:17–24
- Aziz NAA, Ho LH, Azahari B, Bhat R, Cheng LH, Ibrahim MNM(2011) Chemical and functional properties of the native banana (*Musa acuminata* × *balbisiana* Colla cv. Awak) pseudo-stem and pseudo-stem tender core flours. *Food Chem* 128(3):748–753
- Baietto M, Wilson A D (2015) Electronic-nose applications for fruit identification ripeness and quality grading *Sensors* 15(1):899–931
- Bashir H (2025) Metabolomics and mass spectrometry in postharvest science Tools for quality and shelf life management *Trends in Animal and Plant Sciences*
- Baskar R, Shrisakthi S, Sathyapriya B, Shyampriya R, Nithya R, Poongodi P (2011) Antioxidant potential of peel extracts of banana varieties (*Musa sapientum*). *Food Nutr Sci* 2(10):1128–1133
- Ben-Arie R, Segal N, Guelfat-Reich S (1984) The maturation and ripening of the ‘Wonderful’ pomegranate. *J Am Soc Hortic Sci* 109:898–902
- Bianchi A & Venturi F (2025). Enhancing the Shelf Life of Food Products: Strategies, Challenges, and Innovations. *Foods*, 14(23), 4034.
- Bishop CM (2006) Pattern recognition and machine learning. Springer, New York, USA
- Chen YF, Etheridge N, Schaller GE (2005) Ethylene signal transduction. *Ann Bot* 95:901–915
- Chuah CH, Yong HS, Goh SH (1997) Methyl eugenol, a fruit-fly attractant, from the browning leaves of *Proiphys amboinensis* (amaryllidaceae). *Biochem Syst Ecol* 25(5):391–393
- Corrado & Sala (2018). “Food waste accounting along global and European food supply chains.” *Journal of Cleaner Production*.
- Dan Y, Liu HY, Gao WW, Chen SL (2010) Activities of essential oils from *Asarum heterotropoides* var. *mandshuricum* against five phytopathogens. *Crop Prot* 29(3):295–299
- Eaks IL (1970) Respiratory response, ethylene production, and response to ethylene of citrus fruit during ontogeny. *Plant Physiol* 45:334–338
- El-Ramady HR, Domokos-Szabolcsy E, Abdalla NA et al (2015) Postharvest management of fruits and vegetables storage. *Sustain Agric Rev* 15:65–152
- Fagundes C, Carciofi BAM, Monteiro AR (2013) Estimate of respiration rate and physicochemical changes of fresh-cut apples stored under different temperatures. *Food Sci Technol* 33:60–67
- FAO (2019). “The State of Food and Agriculture: Food Loss and Waste.”
- Fox A, Gilbert J, Morgan S L (1990) Analytical microbiology A perspective In Fox A, Morgan S L, Larsson L, Odham G (eds) *Analytical Microbiology Methods* Springer Boston MA https://doi.org/10.1007/978-1-4899-3564-9_1
- Ghasemzadeh A, Ghasemzadeh N (2011) Flavonoids and phenolic acids: role and biochemical activity in plants and human. *J Med Plant Res* 5:6697–6703

- Gomes JFS, Vieira RR, de Oliveira IAA, Leta FR (2014) Influence of illumination on the characterization of banana ripening. *J Food Eng* 120(1):215–222
- Grierson D (2013) Ethylene and the control of fruit ripening. In: *The molecular biology and biochemistry of fruit ripening*, vol 36. Wiley, pp 43–73
- Gross KC, Watada AE, Kang MS et al (1986) Biochemical changes associated with the ripening of hot pepper fruit. *Physiol Plant* 66:31–36
- Gundewadi G, Reddy VR, Bhimappa BB (2018) Physiological and biochemical basis of fruit development and ripening-a review. *J Hill Agric* 9:7–21
- Gupta AK, Akhtar TA, Widmer A, Pichersky E, Schiestl FP (2012) Identification of white campion (*Silene latifolia*) guaiacol o-methyl transferase involved in the biosynthesis of veratrole, a key volatile for pollinator attraction. *BMC Plant Biol* 12(158):1–13
- Jayarajan S, Sethi S, Awasthi OP et al (2024) Synergistic influence of melatonin- hydrocolloid coating on decay and senescence of nectarine (*Prunus persica* var. *nucipersica*) during supermarket storage conditions. *Plan Theory* 13:822–835
- Kader AA (1985) Postharvest biology and technology an: overview. In: *Postharvest technology of horticultural crops, Agriculture and natural resources pub* (No. 3311). University of California, California, pp 1–10
- Kanayama Y, Kochetov A (eds) (2015) *Abiotic stress biology in horticultural plants*. Springer, New York
- Koeduka T, Fridman E, Gang DR, Vassão DG, Jackson BL, Kish CM, Orlova I, Spassova SM, Lewis NG, NoelJP, Baiga TJ, Dudareva N, Pichersky E (2006) Eugenol and isoeugenol, characteristic aromatic constituents of spices, are biosynthesized via reduction of a coniferyl alcohol ester. *PNAS* 103(26):10128–10133
- Kumar P, Sethi S, Sharma RR et al (2018) Nutritional characterization of apple as a function of genotype. *J Food Sci Technol* 55:2729–2738
- Lalel H J D, Singh Z, Tan S C (2003) Aroma volatiles production during fruit ripening of Kensington Pride mango *Postharvest Biology and Technology* 27(3):323–336
- Lebaka VR, Ryu HW, Wee YJ (2014) Effect of fruit pulp supplementa tion on rapid and enhanced ethanol production in very high gravity (VHG) fermentation. *Bioresour Bioproc* 1(1):1–22
- Liu RH (2004) Potential synergy of phytochemicals in cancer prevention: mechanism of action. *J Nutr* 134:3479S–3485S
- Menaka M, Asrey R, Meena NK et al (2024) Effect of melatonin on biochemical changes, antioxidant system and oxidative membrane damage of Indian guava (cv. Barafkhana) during cold storage. *S Afr J Bot* 169:95–108
- Menezes EW, Tadini CC, Tribess TB, Zulet A, Binaghi J, Pak N, Vera G, Dan MCT, Bertolini AC, Cordenunsi BR, Lajolo FM (2011) Chemical composition and nutritional value of unripe banana flour (*Musa acuminata*, var. Nanicão). *Plant Foods Hum Nutr* 66(3):231–237
- Miranda EJJ, Nogueira RI, Pontes SM, Rezende CM (2001) Odour active compounds of banana passa identified by aroma extract dilu tion analysis. *Flavour and Fragrance J* 16(4):281–285
- Moschopoulou E, Moatsou G, Syrokou M K, Paramithiotis S, Drosinos E H (2019) Food quality changes during shelf life. In: Galanakis C M (ed) *Food Quality and Shelf Life*. Academic Press:1–31. <https://doi.org/10.1016/B978-0-12-817190-5.00001-X>

- Nayak SL, Sethi S, Dubey AK et al (2024) Impact of on-tree storage and genotype on citrus granulation: Physico-chemical analysis. *Erwerbs-obstbau*. <https://doi.org/10.1007/s10341-024-01049-0>
- Nayak SL, Sethi S, Sharma RR et al (2020) Variation in fruit quality traits and health promoting compounds of citrus fruits grown in semi-arid region. *Indian J Hortic* 77:635–640
- Neljubow DJBCB (1901) Über die horizontale Nutation der Stengel von *Pisum sativum* und einiger anderen Pflanzen. *Beihefte zum Botanischen Centralblatt* 10:128–139
- Nerdy N (2018) Determination of vitamin C in various colours of bell pepper (*Capsicum annuum* L.) by titration method. *ALCHEMY Jurnal Penelitian Kimia* 14:164–177
- Nogueira JMF, Fernandes PJP, Nascimento AMD (2003) Composition of volatiles of banana cultivars from Madeira Island. *Phytochem Anal* 14(2):87–90
- Nordey T, Joas J, Davrieux F, Génard M, Léchaudel M (2014) Non-destructive prediction of color and pigment contents in mango peel *Scientia Horticulturae* 171:37–44
- Odeode AC, Sanusi J (1996) Influence of fungi associated with bananas on nutritional content during storage. *Z Lebensm Unters Forsch* 202(6):471–473
- Paul V, Pandey R (2016) Internal atmosphere of fruits: role and significance in ripening and storability. In: Pareek S (ed) *Postharvest ripening physiology of crops*. Series: innovation in postharvest technology. CRC Press/Taylor & Francis Group, Boca Raton, pp 359–412
- Paul V, Pandey R, Ramesh KV et al (2012a) Role of mineral nutrients in physiology, ripening and storability of fruits. In: *Nutriophysiological and molecular interventions for crop improvement under changing climate*, vol 13. Scientific Publishers (India), pp 56–96
- Paul V, Pandey R, Srivastava GC (2012b) The fading distinctions between classical patterns of ripening in climacteric and non-climacteric fruit and the ubiquity of ethylene—an overview. *J Food Sci Technol* 49:1–21
- Paul V, Srivastava GC (2007) Minerals in pericarp of tomato (*Solanum lycopersicum* L.) fruit and its ripening behaviour. *J Appl Hortic* 9:140–145
- Peroni-Okita FHG, Cardoso MB, Agopian RGD, Louro RP, Nascimento JRO, Purgatto E, Tavares MIB, Lajolo FM, Cordenunsi BR (2013)
- Pino JA, Febles Y (2013) Odour-active compounds in banana fruit cv. Giant Cavendish. *Food Chem* 141(2):795–801
- Prabha DS, Kumar JS (2015) Assessment of banana fruit maturity by image processing technique. *J Food Sci Technol* 52(3):1316–1327
- Prasad K, Sharma RR, Asrey R et al (2022) Hydrocolloid edible coatings extend shelf life and reduce postharvest decay and maintain quality of mango fruits (*Mangifera indica* L.) under ambient storage. *J Food Biochem*.
- Prasanna V, Prabha TN, Tharanathan RN (2007) Fruit ripening phenomena—an overview. *Crit Rev Food Sci Nutr* 47:1–19
- Purgatto E, Lajolo FM, do Nascimento JRO, Cordenunsi BR (2001) Inhibition of β -amylase activity, starch degradation and sucrose formation by indole-3-acetic acid during banana ripening. *Planta* 212(5):823–828
- Rajakumar DV, Rao MNA (1993) Dehydrozingerone and isoeugenol as inhibitors of lipid peroxidation and as free radical scavengers. *Biochem Pharmacol* 46(11):2067–2072
- Rashvand M, Ren Y, Sun D W, Senge J, Krupitzer C, Fadiji T, Sanzo Miró M, Shenfield A, Watson N J, Zhang H (2025) Artificial intelligence for prediction of *shelf-life* of

various food products Recent advances and ongoing challenges *Trends in Food Science & Technology* 159:104989

- Sethi S, Srivastav M, Samuel DVK et al (2011) Evaluation of newly developed mango hybrids for their storage behaviour and peel colour. *Indian J Agric Sci* 81:58–61
- Shiota H (1993) New esteric components in the volatiles of banana fruit (*Musa sapientum* L.). *J Agric Food Chem* 41(11):2056–2062
- Sulaimankhil Z, Sethi S, Sharma RR et al (2021) Influence of aqueous hexanal on quality of ‘Royal Delicious’ apple during cold storage. *Acta Physiol Plant* 43:134
- Su-Mon M, Asrey R, Meena N et al (2022) Attenuating sugar spot and retaining quality of banana fruits by combined use of hot water and calcium lactate during storage. *Food Sci Technol Int* 30:49–60
- Theodoridis S, Koutroumbas K (2006) Pattern recognition. Academic Press, San Diego, USA
- Vats M, Cillero-Pastor B, Cuypers E, Heeren R M A (2024) Mass spectrometry imaging in plants microbes and food A review *Analyst* 149(18):4553–4582
- Ventura-Aguilar R I, Lucas-Bautista J A, Arévalo-Galarza M d L, Bosquez-Molina E (2024) Volatile organic compounds as a diagnostic tool for detecting microbial contamination in fresh agricultural products Mechanism of action and analytical techniques *Processes* 12(8):1555
- Vusovich OV, Lapin IN, Svetlichnyi VA, Sul'timova NB, Tchaikovskaya ON (2014) Comparison of vanillin and isovanillin photolysis in aqueous solutions. *Russ Phys J* 56(11):1287–1291
- Wang J, Zhi LY, Chen RR, Bao JY, Yang GM (2007) Comparison of volatiles of banana powder dehydrated by vacuum belt drying, freeze-drying and air drying. *Food Chem* 104(4):1516–1521
- Wang Y, Deng L, Meng J et al (2021) Transcriptomic and metabolic analyses reveal the mechanism of ethylene production in stony hard peach fruit during cold storage. *Int J Mol Sci* 22:11308
- Wills R, Mc Glasson B, Graham D et al (1998) Postharvest: an introduction to the physiology and handling of fruit, vegetables and ornamentals. CAB International, Oxford
- Wills R, Mc Glasson B, Graham D et al (1998) Postharvest: an introduction to the physiology and handling of fruit, vegetables and ornamentals. CAB International, Oxford
- Yang SF (1980) Regulation of ethylene biosynthesis. *Hortic Sci* 15(3):238–243
- Zainal P W, Aurum F S, Imaizumi T, Thammawong M, Nakano K (2022) Applications of mass spectrometry-based metabolomics in postharvest research *Reviews in Agricultural Science* 10:56–67
- Zhao M, You Z, Chen H, Wang X, Ying Y, Wang Y (2024). Integrated Fruit Ripeness Assessment System Based on an Artificial Olfactory Sensor and Deep Learning. *Foods*, 13(5), 793.

Siti web:

[Eurostat – Spreco alimentare UE: costo e impatto ambientale](#)

[Waste Watcher – Cresce lo spreco alimentare: frutta fresca in testa](#)

Il Giornale dell'Ambiente. (2023). *Spreco alimentare: si potrebbero sfamare miliardi di persone*. Recuperato da <https://ilgiornaledellambiente.it/spreco-alimentare-sfamare-miliardi-persone/>