



Sapienza per tutti



METROFOOD-IT: il quaderno

*Conoscere l'Infrastruttura di Ricerca
dedicata alla qualità, alla sicurezza
e alla valorizzazione delle filiere
agroalimentari attraverso casi studio*

a cura di Cesare Manetti



University Press



SAPIENZA
UNIVERSITÀ EDITRICE

Collana Sapienza per tutti 32

METROFOOD-IT: il quaderno

*Conoscere l'infrastruttura di ricerca
dedicata alla qualità, alla sicurezza
e alla valorizzazione delle filiere
agroalimentari attraverso casi studio*

a cura di Cesare Manetti



SAPIENZA
UNIVERSITÀ EDITRICE

2026

Volume finanziato dal Progetto METROFOOD-IT - Strengthening of the Italian RI for Metrology and Open Access Data in support to the Agrifood”), finanziato dal PNRR, Missione 4 Componente 2, Investimento 3.1 (NextGenerationEU) - IR0000033.

Redattore Scientifico: Dott.ssa Clelia Palanza

Copyright © 2026

Sapienza Università Editrice

Piazzale Aldo Moro 5 – 00185 Roma

www.editricesapienza.it

editrice.sapienza@uniroma1.it

Iscrizione Registro Operatori Comunicazione n. 11420

Registry of Communication Workers registration n. 11420

ISBN: 978-88-9377-470-3

DOI: 10.13133/9788893774703

Pubblicato nel mese di giugno 2026 | *Published in June 2026*



Opera diffusa in modalità *open access* e distribuita con licenza
Creative Commons Attribuzione – Non commerciale – Non opere
derivate 4.0 Internazionale (CC BY-NC-ND 4.0)

Work published in open access form and licensed under Creative Commons Attribution – NonCommercial – NoDerivatives 4.0 International (CC BY-NC-ND 4.0)

In copertina | *Cover image: gingsulku_stock.adobe.com_1370204600.*

Indice

Introduzione	7
L'evoluzione del packaging bioattivo da scarti e sottoprodotti dell'agroalimentare italiano	9
<i>De Rinaldis G., Miccoli G., Del Fiore A., Nobili C., Rotolo P., Notarfonso M., Zoani C., Miceli V.</i>	
La firma spettroscopica del lievito naturale nel pane: Spettroscopia NIR e imaging iperspettrale per l'autenticazione	21
<i>Lombardi G., Rizzello C. G., Manetti C.</i>	
Modelli di explainable artificial intelligence e machine learning per l'agroalimentare: dall'origine e qualità degli alimenti ai servizi intelligenti per gli utenti	33
<i>Magarelli M., Novielli P., Di Bitonto P., Romano D., Ahsen R., Tangaro S.</i>	
Dal suolo al pomodoro: l'impronta geochimica per l'autenticazione di prodotti agroalimentari	53
<i>Ofano R., Ruggiero L., Agrelli D., Amalfitano C., Adamo P.</i>	
La volatilità per la sicurezza alimentare: impiego della tecnologia del naso elettronico e della gascromatografia spettrometria di massa ad alta risoluzione orbitrap integrate con tecniche di machine learning per la rivelazione di metaboliti volatili di micotossine emergenti in cereali	67
<i>Piergiovanni M., Giliberti C., Maffezzoni C., Errico D., Blandino M., Dall'asta C., Mattarozzi M., Bianchi F., Giannetto M., Careri M.</i>	

Piattaforma Open Data e Infrastruttura Blockchain per la Tracciabilità e la Fiducia nei Sistemi Agroalimentari <i>Salzano F., Pareschi R.</i>	77
Percorrendo la strada del cibo: nuovi modelli di coltivazione, trasformazione e confezionamento per una filiera sostenibile <i>Tozzi C., Parri S., Costa J., Romi M., Cai G., Marti P., Pogni R., Riccaboni A.</i>	89
Microplastics analyzer: una piattaforma digitale per la quantificazione e l'analisi morfologica e composizionale di microplastiche <i>Vicentini M., Acquavia M. A., Fadda M., Mariano A., Sacco A., Giovannozzi A. M., Rossi A. M., Manzin A.</i>	101

METROFOOD-IT: un'infrastruttura per il futuro del sistema agroalimentare

Il sistema agroalimentare rappresenta uno degli asset strategici del nostro Paese, non solo sul piano economico, ma anche per il suo valore sociale, culturale e ambientale. Garantire qualità, sicurezza, autenticità e sostenibilità delle produzioni significa oggi investire in ricerca, innovazione e infrastrutture scientifiche capaci di rispondere alle sfide di un contesto in rapida evoluzione.

È in questa prospettiva che si inserisce METROFOOD-IT, il nodo nazionale italiano dell'infrastruttura europea METROFOOD-RI, dedicata alla metrologia applicata ai sistemi agroalimentari e alla nutrizione. "Il progetto di potenziamento finanziato nell'ambito del PNRR – NextGenerationEU ha consentito di rafforzare e rendere pienamente operativa una rete integrata di laboratori, piattaforme digitali, competenze e servizi avanzati a supporto della ricerca, delle imprese, delle istituzioni e dei territori".

METROFOOD-IT promuove un approccio sistemico, nel quale facilities fisiche ed elettroniche collaborano per offrire strumenti concreti nei campi della qualità alimentare, della sicurezza, della tracciabilità, dell'autenticazione, della valorizzazione delle filiere e della gestione dei dati secondo i principi FAIR. È un ecosistema aperto, orientato al trasferimento tecnologico, alla collaborazione con gli stakeholder, alla costruzione di nuove competenze ed al sostegno della transizione sostenibile del settore agroalimentare.

Questo quaderno rappresenta in modo esemplare tale visione. Attraverso contributi che spaziano dall'intelligenza artificiale alla sensoristica avanzata, dalla blockchain al packaging sostenibile, dalla volatilomica all'analisi delle microplastiche, il volume racconta come la ricerca possa tradursi in soluzioni concrete per affrontare problemi reali e generare innovazione.

Particolarmente significativo è il ruolo dei giovani ricercatori e delle nuove professionalità che il progetto ha contribuito a formare. Le pagine che seguono testimoniano come investire in infrastrutture significhi anche investire nel capitale umano, nella capacità scientifica del Paese e nella costruzione del futuro.

METROFOOD-IT intende continuare a essere un punto di riferimento nazionale ed europeo per una transizione agroalimentare fondata su conoscenza, affidabilità dei dati, sostenibilità e apertura all'innovazione.

Cesare Manetti

*Responsabile scientifico METROFOOD-IT
per Sapienza Università di Roma e curatore dell'opera*

Claudia Zoani

Coordinatrice METROFOOD-IT

L'evoluzione del packaging bioattivo da scarti e sottoprodotti dell'agroalimentare italiano

Gianluca De Rinaldis^{1*}, Giorgia Miccoli¹, Antonella Del Fiore¹, Chiara Nobili¹,
Paolo Rotolo¹, Maurizio Notarfonso¹, Claudia Zoani², Valerio Miceli¹

¹ Laboratorio Innovazione delle Filiere Agroalimentari, Divisione Sistemi Agroalimentari Sostenibili, Dipartimento Sostenibilità, circolarità e adattamento al cambiamento climatico dei Sistemi Produttivi e Territoriali, Agenzia nazionale per le nuove tecnologie, l'energia e lo sviluppo economico sostenibile, Italia (ENEA SSPT-AGROS-IFAL)

² Divisione Sistemi Agroalimentari Sostenibili, Dipartimento Sostenibilità, circolarità e adattamento al cambiamento climatico dei Sistemi Produttivi e Territoriali, Agenzia nazionale per le nuove tecnologie, l'energia e lo sviluppo economico sostenibile, Italia (ENEA SSPT-AGROS)

* Corresponding Author: gianluca.derinaldis@enea.it

ABSTRACT - L'attuale sistema di produzione globale dipende fortemente dalle plastiche di origine fossile (431 milioni di tonnellate), mentre le bioplastiche rappresentano appena lo 0,5%. La necessità di ridurre l'impatto ambientale e lo spreco alimentare, sotto la spinta delle normative europee, orienta la ricerca verso soluzioni biodegradabili e circolari. Il settore evolve verso biomasse di seconda e terza generazione, utilizzando scarti e sottoprodotti dell'agroalimentare per lo sviluppo di biopackaging attivo. Questo packaging interagisce con il prodotto rilasciando sostanze naturali, come antiossidanti o antimicrobici, per estenderne la *shelf-life*. L'infrastruttura METROFOOD-IT con l'unità operativa di Brindisi contribuisce attivamente a questa transizione mediante lo sviluppo di biomateriali innovativi attraverso la valorizzazione di scarti e sottoprodotti dell'agroalimentare. Un esempio è rappresentato da una pellicola composta da galattomannano e kappa-carragenina, plastificata con l'aggiunta di glicerolo e attivata con un estratto della buccia del melograno. Il biofilm è efficace contro diversi microrganismi patogeni causa di intossicazioni alimentari e legati al *food spoilage*. Idrorepellente e a

bassissima permeabilità al vapore acqueo, è inoltre biodegradabile nel suolo in poco tempo. In prospettiva, l'integrazione tra soluzioni attive e biodegradabili sarà fondamentale per rispondere al nuovo regolamento UE sugli imballaggi e rifiuti di imballaggio (PPWR).

Keywords: Biomateriali, Biopackaging attivo, Scarti agroalimentari, Packaging biodegradabile, Economia circolare

Introduzione

Ogni giorno entriamo in contatto con numerosi imballaggi alimentari: confezioni, pellicole e contenitori progettati per proteggere il cibo e prolungarne la conservazione. L'attuale sistema di produzione e consumo globale è pesantemente dipendente dalle plastiche di origine fossile. Secondo i dati più recenti, la produzione annua globale di plastica ha raggiunto circa 431 milioni di tonnellate, di cui le bioplastiche ne rappresentano ancora una frazione minima, poco sopra lo 0,5% (European Bioplastics, 2025; Geyer et al., 2017). Nonostante gli sforzi dell'industria per ridurre l'impiego, gli imballaggi usati rimangono una presenza critica nei flussi di rifiuti. In questo scenario, l'esigenza di ridurre lo spreco alimentare e l'impatto ambientale della plastica diventa sempre più urgente, soprattutto nei prodotti alimentari più esposti al deterioramento, sia durante il trasporto che una volta sul mercato (Ait Ouahioune et al., 2025; Robertson et al., 2012). Questo cambiamento di paradigma non è solo una scelta etica, ma anche una necessità normativa, dettata anche dalla Direttiva (UE) 2019/904 (Single-Use Plastics), che ha imposto restrizioni severe sui prodotti in plastica monouso, spingendo la ricerca verso soluzioni che non siano solo alternative tecniche, ma che garantiscano un reale fine vita sostenibile attraverso la biodegradabilità o il riciclo nell'organico. Più recentemente il Regolamento (UE) 2025/40 sugli imballaggi e i rifiuti di imballaggio (PPWR) introduce obiettivi stringenti in termini di riduzione, riutilizzo e riciclabilità delle confezioni, promuovendo l'impiego di soluzioni sostenibili lungo l'intero ciclo di vita, incentivando lo sviluppo di materiali innovativi, senza compromettere la sicurezza alimentare e le prestazioni tecniche richieste. Tale problematica sta spingendo i consumatori, specialmente in Europa, a richiedere alternative sostenibili e biodegradabili che possano integrarsi nei principi

dell'economia circolare (European Bioplastics, 2026c; Petersen et al., 1999; Ait Ouahioune et al., 2025; Ellen MacArthur Foundation, 2017). In parallelo, si afferma la tendenza del "Clean Label": i consumatori cercano alimenti con meno additivi chimici sintetici, favorendo lo sviluppo di soluzioni come il biopackaging attivo, ovvero sistemi in grado di preservare la freschezza degli alimenti senza ricorrere a conservanti aggiunti (Ait Ouahioune et al., 2025). Va inoltre sottolineato che, nonostante la crescita del settore, l'efficienza nell'uso del suolo e la conseguente sostenibilità ambientale è altissima: la superficie agricola dedicata alle bioplastiche è stimata in meno dello 0,01% dell'area globale, non entrando in competizione diretta con la produzione alimentare (European Bioplastics, 2026d; Zia et al., 2015). Ma cosa si intende esattamente per "bioplastica"? Il termine bioplastica non si riferisce a un singolo materiale, ma a una vasta famiglia di polimeri con proprietà e applicazioni differenti (Vilela et al., 2018). È fondamentale distinguere tra plastiche bio-based, come Bio-PE, Bio-PET o Bio-PVC, che sono tecnicamente identiche alle loro controparti fossili e possono essere riciclate nei flussi esistenti, e biomateriali con nuove proprietà. Secondo le definizioni standard (European Bioplastics, 2022), un materiale plastico è classificato come bioplastica, se è bio-based (a base biologica), biodegradabile, o se possiede entrambe le caratteristiche. Si definisce bio-based un materiale derivato, almeno parzialmente, da biomassa naturale (rinnovabile) come il mais, la canna da zucchero o la cellulosa. Il suo contenuto biologico può essere misurato tramite Carbonio-14 o valutando il contenuto di massa bio-based (European Bioplastics, 2026a). Nel caso di un materiale plastico biodegradabile, la sua biodegradabilità è una proprietà che dipende esclusivamente dalla struttura chimica del polimero e non dalla sua origine (Filiciotto & Rothenberg, 2021; Kim et al., 2023). In altre parole, un materiale può essere di origine biologica senza essere biodegradabile o viceversa. Infatti, questi polimeri possono essere convertiti dai microrganismi in acqua, anidride carbonica e biomassa (European Bioplastics, 2022). Un materiale è considerato bioplastica biodegradabile quindi solo se segue standard internazionali come l'EN 13432 per il compostaggio industriale. Tuttavia, la normativa si è evoluta includendo standard per il compostaggio domestico (EN 17427) e per la biodegradabilità nel suolo (EN 17033), fondamentali per applicazioni come i teli pacciamanti (European Bioplastics, 2022; Kim et al., 2023). È importante notare che la biodegradabilità dipende dalla struttura chimica e non

necessariamente dall'origine della risorsa. Per questo motivo, non tutte le plastica considerate “alternative” sono realmente sostenibili. Un esempio significativo è quello delle plastiche “oxo-degradabili”, che si frammentano semplicemente in microplastiche per aggiunta di additivi sotto radiazione ultravioletta o per azione del calore, senza subire una vera biodegradazione biologica (European Bioplastics, 2026b). Ma come si sta evolvendo concretamente questo settore? Il mercato delle bioplastiche rappresenta una chiave di lettura importante per capire quali materiali sono oggi disponibili e quali prospettive si aprono per soluzioni più avanzate, come il packaging attivo.

Il mercato delle bioplastiche

Sebbene le bioplastiche rappresentino attualmente una minima parte della produzione globale di plastica, il settore sta vivendo una crescita esponenziale. Ma come si traduce questa crescita in termini concreti? Le previsioni indicano che la capacità di produzione mondiale raddoppierà, passando da 2,31 milioni di tonnellate del 2025 a circa 4,69 milioni di tonnellate per il 2030.

In questo scenario, l'Europa gioca un ruolo centrale, con un'industria delle bioplastiche che opera mediamente al 73% della sua capacità produttiva, sostenuta da una solida innovazione nel campo dei biomateriali. Inoltre, l'Europa non è solo un mercato di consumo, ma si configura anche come un vero e proprio hub tecnologico per lo sviluppo di polimeri avanzati come il PHAs (European Bioplastics, 2025; European Bioplastics, 2026c). Tradizionalmente, le bioplastiche bio-based biodegradabili sono prodotte a partire da colture ricche di carboidrati come mais, grano o barbabietola da zucchero (la cosiddetta “prima generazione”). Tuttavia, l'industria si sta rapidamente spostando verso l'uso di biomasse non alimentari, scarti e sottoprodotti (la seconda e terza generazione) dell'agroalimentare, con l'obiettivo di evitare la competizione con le risorse destinate alla produzione di cibo (European Bioplastics, 2026d; Silva et al., 2022). Tra queste fonti promettenti troviamo i residui agricoli non commestibili, come paglia, bagassa di canna da zucchero, tutoli di mais, e diversi sottoprodotti dell'industria forestale, come la lignocellulosa (European Bioplastics, 2026d). A queste si aggiungono altre biomasse come le alghe derivanti dall'acquacoltura e numerosi scarti e sottoprodotti della trasformazione dei prodotti

agricoli, oltre ai rifiuti organici urbani (European Bioplastics, 2026d). Accanto allo sviluppo dei materiali, un aspetto cruciale riguarda la sicurezza delle applicazioni, soprattutto nel caso del packaging alimentare. In questo ambito, il ruolo dell'EFSA (Autorità europea per la sicurezza alimentare) è centrale: ogni sostanza attiva incorporata nel packaging deve essere sottoposta a una rigorosa valutazione del rischio e successivamente approvata o meno dai singoli stati. La sfida per i ricercatori è dimostrare che il rilascio di composti bioattivi, seppur naturali, avvenga entro i limiti di sicurezza stabiliti, garantendo che l'interazione packaging-alimento non alteri la composizione del prodotto in modo inaccettabile. Per garantire che queste fonti non impattino negativamente sulla sicurezza alimentare o sulla biodiversità e l'ambiente, l'industria, in alcuni casi, già adotta schemi di certificazione come l'ISCC (International Sustainability and Carbon Certification) o il RSB (Roundtable on Sustainable Biomaterials) (European Bioplastics, 2026d).

Il Biopackaging Attivo da scarti e sottoprodotti agroalimentari

In questo contesto, una delle sfide più recenti e promettenti riguarda lo sviluppo di imballaggi che non siano solo passivi (di protezione), ma attivi. Storicamente, i materiali bio-based hanno infatti mostrato limiti tecnici rispetto alle plastiche fossili, come un'alta sensibilità all'umidità, permeabilità elevata e proprietà meccaniche inferiori (Petersen et al., 1999.). Tuttavia, l'utilizzo di blend polimerici (miscelazione di diversi biopolimeri di diversa origine e caratteristiche) e l'integrazione di scarti agroalimentari consentono oggi di superare molti di questi limiti, andando ad ottimizzare resistenza, flessibilità e andando a migliorare l'impermeabilità ai gas e la bagnabilità (Petersen et al., 1999). Ma cosa significa concretamente "packaging attivo"? Il packaging attivo interagisce con il prodotto e l'ambiente per estendere la *shelf-life* degli alimenti, mantenendone o migliorandone la qualità (Carvalho et al., 2021). A differenza del packaging tradizionale, che deve tendere all'inerzia chimica, il packaging attivo può comportare il rilascio intenzionale di sostanze benefiche (come antiossidanti o conservanti). Tale rilascio non deve essere evitato, ma deve avvenire nel rispetto dei limiti di migrazione specifica e delle autorizzazioni previste dalla normativa vigente (Regolamento

(CE) n. 450/2009 - deroga al regolamento 1935/2004), garantendo che le sostanze rientrino nei limiti di migrazione globale stabiliti e siano sicure per il consumatore (Reg. UE n. 1935/2004; Reg. UE n. 450/2009). È inoltre importante distinguere il packaging attivo dal packaging intelligente, che invece monitora le condizioni esterne o interne (es. indicatori di temperatura o scadenza) senza intervenire direttamente sulla degradazione (Ait Ouahioune et al., 2025). L'utilizzo di scarti agroalimentari per creare questi sistemi rappresenta un'opportunità particolarmente interessante, poiché consente di combinare sostenibilità e funzionalità. In particolare, offre diversi vantaggi:

- *Sostenibilità*: Trasforma un rifiuto in una risorsa ad alto valore aggiunto.
- *Funzionalità*: Molti scarti contengono composti naturali (polifenoli, oli essenziali, etc.) che, estratti con tecnologie mild e incorporati in matrici biodegradabili come il PHAs o in blend polimerici (come la farina di semi di carrube e la kappa-carragenina o la farina di semi di carrube e il chitosano), possono agire come agenti antimicrobici e antiossidanti (Vilela et al., 2018). Queste funzionalità sono cruciali per i prodotti alimentari freschi, dove l'uso di sostanze naturali estratte da scarti e sottoprodotti può ridurre la crescita di microrganismi patogeni e legati al *food spoilage* e rallentare l'ossidazione lipidica negli alimenti (Ait Ouahioune et al., 2025).
- *Scienza della conservazione*: La gestione della permeabilità ai gas è vitale. Se l'ossigeno scende sotto valori limite può indurre respirazione anaerobica e favorire batteri pericolosi come il *Clostridium botulinum*. Allo stesso modo, il controllo dell'umidità relativa previene la condensa superficiale che favorisce funghi e muffe (Petersen et al., 1999).
- *Sicurezza e FCM*: essendo spesso il packaging direttamente a contatto con gli alimenti, deve rispettare rigorosi standard di migrazione per evitare il trasferimento di sostanze chimiche all'alimento. L'uso di biomateriali innovativi, anche nanostrutturati, richiede quindi valutazioni attente sulla loro biosicurezza prima della commercializzazione (Ait Ouahioune et al., 2025). Questi biomateriali sono particolarmente promettenti per prodotti altamente deperibili, come ad esempio il pesce e la carne, alimenti nei quali possono ritardare i processi di degradazione enzimatica e microbica, ma necessitano di ulteriori studi scientifici e di una normativa maggiormente permissiva.

Nonostante i successi su scala di laboratorio, infatti, il settore affronta ancora sfide legate ai costi di produzione, alle proprietà meccaniche durante lo stoccaggio, il trasporto e l'utilizzo, alla permeabilità dei gas e alla necessità di rispettare rigorosi standard di migrazione per il contatto alimentare. Proprio per affrontare queste criticità, la ricerca si sta orientando verso strategie innovative, come il rilascio controllato e prolungato nel tempo di sostanze bioattive (es. oli essenziali o estratti bioattivi) o la nanostrutturazione e nanoincapsulazione, che promettono di migliorare l'efficacia del biopackaging durante l'intera vita commerciale del prodotto, aprendo la strada a un futuro in cui l'imballaggio può essere parte integrante della circolarità della materia, migliorando l'efficacia del biopackaging biodegradabile bioattivo e intelligente durante tutta la vita commerciale del prodotto (Petersen et al., 1999; Ait Ouahioune et al., 2025).

METROFOOD-IT: il contributo del Polo ENEA di Brindisi allo sviluppo del biopackaging attivo

In questo contesto, le sfide fin qui descritte trovano una risposta concreta nell'ambito dell'infrastruttura di ricerca METROFOOD-IT. Dedicata alla qualità, alla sicurezza e alla sostenibilità alimentare, l'infrastruttura vede nel Polo ENEA di Brindisi una delle sue Unità

Operative dove le attività di ricerca si concentrano sullo sviluppo di soluzioni innovative per il biopackaging attivo. Il Centro, oltre alla facility dedicata a ricerca e sperimentazione, ospita un Living Lab dedicato alle tecnologie dei biomateriali applicate all'agroindustria. In questo contesto, la ricerca non avviene in modo isolato, ma si sviluppa in stretta connessione con le esigenze del settore agroalimentare, configurandosi come un ambiente di sperimentazione e co-creazione. L'attività è focalizzata sullo sviluppo di biopackaging attivo ottenuto interamente dalla valorizzazione di scarti e sottoprodotti, promuovendo un modello di economia circolare che trasforma i residui in risorse ad alto valore aggiunto (Guillard et al., 2018). Per garantire una ricerca scientifica di alto livello e una reale scalabilità dei processi e dei prodotti, la facility è dotata di strumentazioni d'avanguardia che permettono una caratterizzazione completa dei materiali. In particolare, queste tecnologie permettono di sviluppare, analizzare e ottimizzare biomateriali con proprietà mirate per applicazioni nel packaging alimentare. La fase di sintesi e

processing si avvale di un bioreattore per la produzione controllata di biopolimeri e di un omogeneizzatore ad alta pressione per la realizzazione di emulsioni e dispersioni nanostrutturate stabili. La caratterizzazione chimica e fisico meccanica è supportata da tecniche analitiche avanzate (es.: UHPLC, GPC, IR-MS, FT-IR ATR, Texture Analyzer, permeabilimetri, reometri), che permettono di analizzare estratti bioattivi e biomateriali e di valutare proprietà fondamentali come la resistenza, la flessibilità e la permeabilità ai gas delle pellicole. Cruciali risultano inoltre le camere climatiche per gli studi di invecchiamento accelerato, che consentono di simulare le reali condizioni di conservazione degli alimenti e validare la stabilità del packaging nel tempo. Gli studi condotti hanno portato, ad esempio, alla formulazione di una pellicola innovativa (Fig. 1) che rappresenta un esempio concreto di applicazione. Il biomateriale è costituito da un blend polimerico costituito da galattomannano (estratto dalla farina di semi di carrube) e kappa-carragenina, con l'aggiunta di glicerolo in funzione di plastificante per garantirne la flessibilità (Martins et al., 2012). L'elemento distintivo è rappresentato dall'agente attivo: un estratto di buccia di melograno ottenuto tramite estrazione acquosa assistita da ultrasuoni, tecnica che preserva l'integrità dei composti (El-Hamamsy & El-khamissi, 2020; Giri et al., 2023).



Figura 1 a, b. Esempio di biopackaging attivo sviluppato con un blend polimerico costituito da farina di semi di carrube e k-carragenina con l'aggiunta di glicerolo in funzione di plastificante e attivato con estratto acquoso della buccia del melograno rosso (sinistra) e melograno nero (destra).



Figura 2. PCTO sul tema “Economia circolare e biopackaging attivo” con la classe Terza A dell’IISS ‘Egidio Lanoce’ di Maglie (LE).

Questo biofilm ha dimostrato proprietà antimicrobiche significative, inibendo non solo patogeni comuni come *E. coli* e *S. aureus*, ma risultando efficace anche contro *B. subtilis* e *P. aeruginosa*, microrganismi legati al deterioramento alimentare (*food spoilage*) (Salim et al., 2023). I test di bagnabilità hanno mostrato una variazione dell’angolo di contatto da 117° (controllo) a 105° nel film attivo, indicando l’idrorepellenza del biopackaging attivo. In termini di protezione, il valore di permeabilità al vapore acqueo (WVTR) si attesta intorno a 2 g/(m²*24h), un parametro fondamentale per la *shelf-life* dei prodotti freschi. Anche dal punto di vista ambientale, il materiale si dimostra particolarmente promettente, con una biodegradabilità totale nel suolo entro 30 giorni, offrendo un’alternativa concreta e a impatto zero rispetto alle plastiche fossili che ancora dominano il mercato con oltre il 90% della produzione globale (Geyer et al., 2017). Accanto alle attività di ricerca & sviluppo, la facility svolge anche un ruolo importante nella formazione e nella diffusione della conoscenza, oltre che come modello di co-creazione nel Living Lab. Si tratta di uno spazio aperto dove la ricerca scientifica incontra e affianca l’industria per sviluppare soluzioni che siano non solo sostenibili, ma anche economicamente competitive. Questa visione strategica si estende anche alla formazione ed alla responsabilità sociale: l’esperienza del PCTO con gli studenti del territorio sul tema

“Economia circolare e biopackaging attivo” dimostra come la facility rappresenti un catalizzatore di conoscenza, capace di preparare le nuove generazioni alle sfide tecnologiche e ambientali del futuro, trasformando la ricerca in un valore condiviso per la comunità.

Guardando al futuro, il settore sarà ulteriormente influenzato dal nuovo Regolamento UE sugli Imballaggi e Rifiuti di Imballaggio (PPWR), che introduce target ambiziosi per il 2030 (Reg. UE n. 40/2025). In questo quadro, l'integrazione tra packaging attivo, intelligente e biodegradabile potrà rappresentare uno standard emergente, capace di coniugare la protezione del consumatore con la riduzione dell'impatto ambientale. Il packaging del futuro non proteggerà soltanto il cibo: proteggerà anche le risorse del pianeta.

Bibliografia

- Ait Ouahioune, L.; Wrona, M.; Pezo, D.; Nerín, C.; Djenane, D. (2025) Sustainable and Green Strategies for Active Biopackaging: Application for Seafood Products. A Critical Review. *Food Biosci*, 63, 105647. <https://doi.org/10.1016/j.fbio.2024.105647>
- Carvalho, J.P.F.; Freire, C.S.R.; Vilela, C. (2021) Active Packaging. In *Sustainable Food Processing and Engineering Challenges*; Elsevier: Amsterdam, The Netherlands, 315–341. <https://doi.org/10.1016/b978-0-12-822714-5.00009-7>
- El-Hamamsy, S.M.A.; El-Khamissi, H.A.Z. (2020) Phytochemicals, Antioxidant Activity and Identification of Phenolic Compounds by HPLC of Pomegranate (*Punica granatum* L.) Peel Extracts. *J. Agric. Chem. Biotechnol.* 11, 79–85. <https://doi.org/10.21608/jacb.2020.95837>
- Ellen Macarthur Foundation (2017) *The New Plastics Economy: Catalysing action*. <https://www.ellenmacarthurfoundation.org/the-new-plastics-economy-catalysing-action>
- European Bioplastics (2022) *What are bioplastics? Fact Sheet 2025* https://docs.european-bioplastics.org/publications/fs/EuBP_FS_What_are_bioplastics.pdf
- European Bioplastics (2025). *Bioplastics Market Development Update 2025*. https://docs.european-bioplastics.org/publications/market_data/2025/EUBP_Market_Data_Report_2025.pdf
- European Bioplastics (2026a). *Biobased*. <https://www.european-bioplastics.org/bioplastics/materials/biobased/>
- European Bioplastics (2026b). *Biodegradable*. <https://www.european-bioplastics.org/bioplastics/materials/biodegradable/>
- European Bioplastics (2026c). *Market Development*. <https://www.european-bioplastics.org/bioplastics-market-development-update-2025/>

- European Bioplastics (2026d). *Renewable feedstock*. <https://www.european-bioplastics.org/bioplastics/feedstock/>
- Filiciotto L & Rothenberg G. (2021). Biodegradable Plastics: Standards, Policies, and Impacts. *ChemSusChem*, 14, 1, 56-72. <https://doi.org/10.1002/cssc.202002044>
- Geyer, R., Jambeck, J. R., & Law, K. L. (2017) Production, use, and fate of all plastics ever made. *Sci. Adv.*, 3, e1700782. <https://doi.org/10.1126/sciadv.1700782>
- Giri, N. A., Bhangale, A., Gaikwad, N. N., Raigond, P., Marathe, R. A. (2023). Exploring the Potential of Pomegranate Peel Extract as a Natural Food Additive: A Review. *Current Nutrition Reports*, 12, 270–289. <https://doi.org/10.1007/s13668-023-00466-z>
- Kim, M.S.; Chang, H.; Zheng, L.; Yan, Q.; Pfleger, B.F.; Klier, J.; Nelson, K.; Majumder, E.L.-W.; Huber, G.W. (2023) A Review of Biodegradable Plastics: Chemistry, Applications, Properties, and Future Research Needs. *Chem. Rev.* 123, 9915–9939. <https://doi.org/10.1021/acs.chemrev.2c00876>
- Martins, J.T.; Cerqueira, M.A.; Bourbon, A.I.; Pinheiro, A.C.; Souza, B.S.; Vicente, A.A. (2012) Synergistic Effects between kappa-Carrageenan and Locust Bean Gum on Physicochemical Properties of Edible Films Made Thereof. *Food Hydrocoll* 29, 280–289. <https://doi.org/10.1016/j.foodhyd.2012.03.004>
- Petersen, K., Væggemose Nielsen, P., Bertelsen, G., Lawther, M., Brandt Olsen, M., Nilsson, N. H., & Mortensen, G. (1999). Potential of biobased materials for food packaging. *Trends in Food Science & Technology*, 10, 52-68. Issn: 0924-2244, 1879-3053. [https://doi.org/10.1016/S0924-2244\(99\)00019-9](https://doi.org/10.1016/S0924-2244(99)00019-9)
- Regolamento UE N. 1935/2004 del Parlamento europeo e del Consiglio del 27 ottobre 2004 riguardante i materiali e gli oggetti destinati a venire a contatto con i prodotti alimentari <https://eur-lex.europa.eu/legal-content/IT/ALL/?uri=celex%3A32004R1935>
- Regolamento UE N. 450/2009 della Commissione, del 29 maggio 2009, concernente i materiali attivi e intelligenti destinati a venire a contatto con i prodotti alimentari. <https://eur-lex.europa.eu/eli/reg/2009/450/oj/ita>
- Regolamento (UE) 2025/40 del Parlamento europeo e del Consiglio, del 19 dicembre 2024, sugli imballaggi e i rifiuti di imballaggio. <https://eur-lex.europa.eu/legal-content/IT/ALL/?uri=CELEX:32025R0040>
- Robertson, G.L. (2012). *Food Packaging: Principles and Practice*, Third Edition (3rd ed.). CRC Press. <https://doi.org/10.1201/b21347>
- Salim, A.; Deiana, P.; Fancello, F.; Molinu, M.G.; Santona, M.; Zara, S. (2023) Antimicrobial and Antibiofilm Activities of Pomegranate Peel Phenolic Compounds: Varietal Screening through a Multivariate Approach. *J. Biore-sour. Bioprod.* 8, 146–161. <https://doi.org/10.1016/j.jobab.2023.01.006>
- Silva, A.C.Q.; Silvestre, A.J.D.; Vilela, C.; Freire, C.S.R. (2022) Natural Polymers-Based Materials: A Contribution to a Greener Future. *Molecules*, 27, 94. <https://doi.org/10.3390/molecules27010094>

- Vilela, C.; Kurek, M.; Hayouka, Z.; Röcker, B.; Yildirim, S.; Antunes, M.D.C.; Nilsen-Nygaard, J.; Pettersen, M.K.; Freire, C.S.R. A (2018) Concise Guide to Active Agents for Active Food Packaging. *Trends Food Sci. Technol.* 80, 212–222. <https://doi.org/10.1016/j.tifs.2018.08.006>
- Zia F, Zia KM, Zuber M, Kamal S, Aslam N. (2015) Starch based polyurethanes: A critical review updating recent literature. *Carbohydr Polym* 134:784-98. <https://www.doi.org/10.1016/j.carbpol.2015.08.034>

La firma spettroscopica del lievito naturale nel pane: spettroscopia NIR e imaging iperspettrale per l'autenticazione

Gabriele Lombardi^{1*}, Carlo Giuseppe Rizzello¹, Cesare Manetti¹

¹Dipartimento di Biologia Ambientale, Università Sapienza Roma, Italy

* Corresponding Author: gabriele.lombardi@uniroma1.it

ABSTRACT – Il mercato globale del pane a lievitazione naturale è in costante crescita, ma l'assenza di una normativa armonizzata rende difficile garantirne l'autenticità. In questo lavoro presentiamo due approcci complementari basati sulla spettroscopia nel vicino infrarosso (NIRS) e sulla chemiometria, per distinguere il pane a lievitazione naturale da quello prodotto senza batteri lattici. Il primo, pubblicato su *Food Chemistry* (Lombardi et al., 2025), utilizza uno spettrometro NIR da banco e un modello PLS-DA, ottenendo una sensibilità dell'89% e una specificità del 100% in cross-validazione: nessun pane senza lievito naturale è stato mai classificato erroneamente come sourdough; i pochi casi di errata classificazione hanno riguardato pani particolarmente poveri in lievito naturale. Il secondo, attualmente in fase di submission, estende l'analisi alla dimensione spaziale attraverso l'imaging iperspettrale (HSI-NIR), restituendo mappe chimiche della fetta di pane. Costruiti sullo stesso set sperimentale di 108 fette (18 ricette), i due approcci si rivelano complementari e offrono uno strumento promettente per la tracciabilità e l'autenticità alimentare, in linea con la missione di METROFOOD-IT.

Keywords: Pane a lievitazione naturale; Autenticazione; Spettroscopia NIR; Imaging iperspettrale; Chemiometria; METROFOOD-IT

Introduzione

Il pane a lievitazione naturale, prodotto con lievito madre, ha conosciuto negli ultimi anni un'attenzione significativa. Il suo mercato globale era

valutato a 3,52 miliardi di dollari nel 2024, con una crescita annua prevista del 6,7% fino al 2033 (Straits Research, 2024). Questa espansione ha però introdotto una sfida concreta: garantire che i prodotti etichettati come “pane a lievitazione naturale” siano effettivamente tali, in un contesto in cui non esiste ancora una definizione univoca e vincolante né a livello europeo né, a tutt’oggi, in Italia. La caratteristica che distingue il pane a lievitazione naturale dagli altri è la presenza dei batteri lattici (LAB). Durante la fermentazione, i LAB producono metaboliti caratteristici — acidi organici (lattico e acetico), amminoacidi liberi, composti aromatici — che ne determinano le proprietà sensoriali, nutrizionali e tecnologiche. I metodi tradizionali proposti per l’autenticazione — basati sulla misura di acidità o singoli metaboliti — sono però facilmente manipolabili: basta aggiungere acido lattico o acetico all’impasto per falsare il pH e l’acidità totale, mascherando pani senza LAB come pani con LAB. Un metodo affidabile deve leggere la “firma” complessiva dei LAB, non un singolo parametro. La spettroscopia nel vicino infrarosso (NIRS), combinata con la chemiometria — un insieme di strumenti matematici e statistici messi al servizio di problemi chimici, capace di estrarre informazione utile da dati complessi che da soli sarebbero illeggibili — risponde a questa esigenza: è una misura rapida, non distruttiva, senza preparazione del campione, capace di raccogliere con un’unica misura informazioni su molteplici componenti del campione e sulle relazioni tra di loro, caratteristiche che la rendono intrinsecamente più difficile da eludere rispetto a un’analisi chimica puntuale.

Materiali E Metodi

Campioni sperimentali

Sono stati prodotti sperimentalmente 18 tipi di pane, variando il tipo di agente lievitante, la quantità utilizzata e il tempo di fermentazione. I campioni includono pani con lievito di birra fresco e secco, pani con lievito naturale di tipo II (pasta madre fresca, con LAB vitali e rinfreschi regolari) e di tipo III (pasta madre essiccata, con LAB inattivati ma metaboliti preservati), e pani con biga — un pre-fermento con solo lievito di birra, privo di batteri lattici. Da ciascun tipo sono state prodotte 3 repliche di pane, da ognuna delle quali sono state ricavate 2 fette, per un totale di 6 fette per tipo e 108 campioni analizzati con entrambe le tecniche strumentali.

Tabella 1. Ricette e codici dei campioni di pane sperimentali. I lieviti naturali di tipo II utilizzati erano SDII12 (†), SDII12y (‡), SDII24 (*) e SDII24y (‡).

Sample code	Flour (g)	Water (mL)	Baker's yeast (g)	Biga (g)	Type II sourdough (g)	Type III sourdough (g)	Leavening time (h)
BY	67	33	1.5	–	–	–	2
dBY	67	33	0.5	–	–	–	2
Biga4C_40	40.2	19.8	–	40	–	–	2
BigaRT_40	40.2	19.8	–	40	–	–	2
SDII_3	67	33	1.5	–	–	3	2
SDII_6	67	33	1.5	–	–	6	2
SDII1_2_10	60.3	29.7	1.5	–	10 [†]	–	2
SDII1_2_20	53.6	26.4	1.5	–	20 [†]	–	2
SDII1_2_30	46.9	23.1	1.5	–	30 [†]	–	2
SDII1_2y_10	60.3	29.7	–	–	10 [‡]	–	4
SDII1_2y_20	53.6	26.4	–	–	20 [‡]	–	4
SDII1_2y_30	46.9	23.1	–	–	30 [‡]	–	4
SDII24_10	60.3	29.7	1.5	–	10 [*]	–	2
SDII24_20	53.6	26.4	1.5	–	20 [*]	–	2
SDII24_30	46.9	23.1	1.5	–	30 [*]	–	2
SDII24y_10	60.3	29.7	–	–	10 [‡]	–	4
SDII24y_20	53.6	26.4	–	–	20 [‡]	–	4
SDII24y_30	46.9	23.1	–	–	30 [‡]	–	4

Spettroscopia NIR da banco

La spettroscopia NIR sfrutta la luce infrarossa, invisibile all’occhio umano, per “interrogare” la composizione chimica di un materiale senza toccarlo né alterarlo. Ogni legame chimico — tra atomi di carbonio, azoto, ossigeno — assorbe la luce e vibra a lunghezze d’onda caratteristiche, come un codice a barre molecolare. Lo spettro che ne risulta è una curva che racchiude, sommati e sovrapposti, i segnali di tutti questi legami chimici associati ai componenti presenti nel campione. Da sola è difficile da interpretare; ma con gli strumenti matematici della chemiometria, quella curva diventa un’impronta digitale chimica, unica per ciascun campione.

Le fette di pane sono state misurate con uno spettrometro NIR da banco (Bruker MPA II), ottenendo uno spettro di riflettanza per campione nell’intervallo 833–2500 nm. Gli spettri così ottenuti sono stati normalizzati attraverso una fase di preprocessing per eliminare le differenze dovute non alla composizione del campione, ma al modo in cui questo viene presentato allo strumento. L’analisi chemiometrica, spiegata nel dettaglio nelle sezioni seguenti, ha compreso una fase esplorativa mediante Analisi delle Componenti Principali (PCA) e una classificatoria mediante PLS-DA, entrambe sottoposte a procedure di validazione per verificarne la robustezza.

Imaging iperspettrale NIR (HSI)

La camera iperspettrale funziona come una fotocamera, ma invece di registrare tre canali di colore (rosso, verde, blu), ne acquisisce centinaia — uno per ciascuna lunghezza d’onda nell’infrarosso. Il risultato è un “ipercubo”: ogni pixel dell’immagine contiene il proprio spettro NIR completo. Questo permette di costruire mappe chimiche della fetta di pane, vedendo non solo che due pani

sono diversi, ma dove lo sono e in che misura. La crosta e la mollica, il centro e il bordo, le alveolature e il tessuto più compatto: ciascuna zona racconta una storia chimica diversa, accessibile solo grazie alla dimensione spaziale dell'imaging.

Le stesse fette sono state acquisite anche con una camera NIR iperspettrale (SPECIM FX17, 950–1700 nm). Dopo preprocessing, un algoritmo di clustering K-means ha segmentato ogni immagine in cinque popolazioni spettrali.

Il K-means è un algoritmo di clustering — ovvero di raggruppamento automatico — che assegna ogni pixel dell'immagine a uno di k gruppi in base alla similarità del suo spettro con quello degli altri pixel. Non sa nulla di chimica né di ricette: trova semplicemente i gruppi più coerenti nei dati. Il risultato è una mappa in cui ogni pixel è colorato in base al gruppo di appartenenza, rendendo visibili le zone della fetta con composizione chimica simile. Nel nostro caso, $k=5$: cinque popolazioni spettrali, cinque 'tipi' di pixel, cinque storie chimiche diverse all'interno della stessa fetta di pane.

Le percentuali di pixel appartenenti a ciascun cluster sono state usate come nuove variabili descrittive — cinque 'ingredienti' numerici che variano da ricetta a ricetta e catturano l'eterogeneità chimica superficiale di ogni fetta. Sono state calcolate anche combinazioni tra di loro per analizzare i rapporti relativi tra i diversi cluster, producendo un dataset finale di 108 campioni $\times$ 45 variabili su cui è stato costruito un modello PLS-DA con validazione leave-one-recipe-out.

Risultati

NIRS da banco

Prima di costruire un modello per la classificazione, è buona pratica esplorare la struttura dei dati senza fornire allo strumento informazioni sulle classi di appartenenza. A questo scopo si utilizza la PCA (Analisi delle Componenti Principali).

La PCA è un metodo non supervisionato che comprime le centinaia di variabili di uno spettro NIR in poche nuove variabili sintetiche — le componenti principali — costruite in modo da rappresentare al meglio le differenze tra i campioni, eliminando il rumore e la ridondanza. Se i campioni tendono a raggrupparsi in modo coerente con la loro composizione, significa che il segnale NIR cattura in qualche modo l'informazione cercata.




Figura 1. Analisi delle Componenti Principali (PCA) applicata agli spettri NIR da banco (833–2500 nm). Score plot PC1 vs PC2 con campioni colorati per tipo di pane (A) e loading delle componenti principali (B).

Oltre alla visualizzazione della struttura dei dati, la PCA restituisce anche i loading: informazioni su quali lunghezze d'onda degli spettri hanno contribuito maggiormente alla separazione osservata, permettendo di dare un'interpretazione chimica al risultato.

Nel nostro caso, i pani si sono raggruppati in modo coerente con il tipo e la quantità di lievito utilizzato, anche senza che il modello sapesse nulla di queste informazioni. I raggruppamenti osservati hanno una spiegazione chimica precisa, il che ha confermato che la spettroscopia NIR è effettivamente informativa rispetto ai cambiamenti indotti dalla fermentazione lattica. Per ottenere una risposta classificatoria netta — presenza o assenza di lievito naturale — si è utilizzato il PLS-DA (Partial Least Squares Discriminant Analysis).

Il PLS-DA è un modello supervisionato che — a differenza della PCA che cerca la massima variabilità tra i campioni indipendentemente dalla loro classe — cerca di massimizzare la covarianza tra le osservazioni e le etichette di classe, ovvero cerca la direzione nello spazio multivariato lungo la quale i campioni delle due classi si separano il più possibile. Lo sguardo non è più solo sul campione, ma anche su quello che so del campione. Il modello lavora in due fasi. Nella prima, detta di addestramento, riceve gli spettri insieme all'etichetta di classe corretta (con o senza lievito naturale) e cerca quali parti degli spettri meglio discriminano campioni appartenenti a classi diverse. Nella seconda, detta di validazione, gli vengono presentati spettri di campioni nuovi, senza l'etichetta, e si verifica quanti vengono assegnati alla classe corretta. Analogamente alla PCA, il modello restituisce i loading, che indicano quali regioni spettrali hanno pesato maggiormente nella discriminazione tra le classi.

Nel nostro caso, non disponendo di un numero di campioni sufficiente a dividere il dataset in due sottoinsiemi indipendenti — uno per l'addestramento e uno per la validazione — la seconda fase è stata condotta tramite cross-validazione con approccio leave-one-recipe-out: il dataset viene diviso in tanti blocchi quante sono le ricette, e ad ogni iterazione un blocco diverso viene escluso dall'addestramento e usato per testare il modello. Ripetendo questo processo per tutti i blocchi si ottiene una stima affidabile delle prestazioni reali, garantendo che la valutazione sia sempre su campioni mai visti durante l'addestramento. La robustezza del modello è stata ulteriormente verificata tramite test di permutazione: le etichette di classe sono state rimescolate casualmente centinaia di volte e per ciascuna




Figura 2. Modello PLS-DA applicato agli spettri NIR da banco. (A) Class prediction plot in cross-validazione con soglia di classificazione; (B) punteggi VIP con soglia a 1; (C) matrice di confusione in cross-validazione; (D) test di permutazione (n=1000).

permutazione è stato costruito un nuovo modello. Il modello originale — costruito sulle assegnazioni corrette — si è rivelato statisticamente diverso da oltre il 99% dei modelli permutati, escludendo che i risultati siano frutto del caso. Il modello ha ottenuto una sensibilità dell'89% e una specificità del 100%: nessun pane senza lievito naturale è stato mai classificato erroneamente come sourdough; i pochi casi di errata classificazione hanno riguardato pani con le percentuali più basse di lievito madre e i tempi di fermentazione più brevi, in cui la traccia chimica dei LAB è per definizione meno pronunciata. L'analisi dei loading — coerente con quanto già emerso in fase esplorativa con la PCA — ha rivelato che le regioni spettrali che più hanno pesato nella discriminazione corrispondono ai gruppi funzionali caratteristici degli acidi organici e dei composti azotati prodotti dai batteri lattici durante la fermentazione. Il modello non solo classifica correttamente, ma lo fa per le ragioni chimiche giuste.

Imaging iperspettrale

L'analisi PCA pixel per pixel ha prodotto mappe chimiche che evidenziano differenze sistematiche tra ricette. In particolare, la prima componente principale separa chiaramente i pani con alte percentuali di lievito madre da quelli senza; la seconda componente rivela che nei pani con lievito naturale le alveolature presentano caratteristiche spettrali distinte rispetto alla mollica circostante — un'informazione accessibile solo grazie alla risoluzione spaziale dell'HSI. Il clustering K-means ha suddiviso i pixel delle fette di pane in cinque popolazioni spettrali. L'analisi dei centroidi — gli spettri medi di ciascun cluster — ha permesso di dare un'interpretazione chimica ai gruppi identificati: alcuni cluster mostrano segnali coerenti con i metaboliti della fermentazione lattica, e la loro frequenza relativa nelle fette è sistematicamente diversa tra pani con e senza lievito naturale.

Il modello PLS-DA ha ottenuto una sensibilità dell'88,1% e una specificità del 62,5%, con prestazioni inferiori rispetto al NIR da banco principalmente a causa del range spettrale più ristretto della camera: le lunghezze d'onda più discriminanti per gli acidi carbossilici si trovano oltre i 1900 nm, al di fuori del range dello strumento a disposizione. Questo non è un limite concettuale dell'approccio, ma un vincolo strumentale che indica una direzione precisa per i futuri sviluppi.




Figura 3. Analisi iperspettrale NIR (HSI, 950–1650 nm). (A) Mappe degli score di PC1 per le 108 fette di pane; (B) loading di PC1; (C) mappe di segmentazione K-means ($k=5$); (D) centroidi spettrali dei cinque cluster.

Conclusioni

Questo lavoro dimostra, per la prima volta in letteratura, la fattibilità dell'autenticazione del pane a lievitazione naturale mediante spettroscopia NIR. Il modello da banco, già pubblicato e validato, classifica con alta accuratezza; l'imaging iperspettrale aggiunge la dimensione spaziale e si conferma un approccio complementare e promettente.

La sfida principale, condivisa da entrambi i metodi, riguarda i campioni con basse percentuali di lievito madre e fermentazione breve — i casi in cui la traccia chimica dei LAB è meno pronunciata e più difficile da leggere. Questo non è un limite del metodo, ma un'indicazione preziosa: definendo con precisione le condizioni in cui il modello riconosce con certezza la presenza di lievito naturale — quantità minima, tempo minimo di fermentazione — si ottiene di fatto una specifica analitica, di modo che chi

vuole certificare il proprio prodotto sa esattamente quali condizioni deve rispettare perché possa essere riconosciuto come sourdough.

I passi successivi prevedono l'ampliamento del dataset a campioni di provenienza commerciale e artigianale, per costruire modelli più robusti e trasferibili. L'obiettivo finale è fornire uno strumento analitico affidabile che possa fungere da base per una normativa in grado di tutelare chi produce davvero pane a lievitazione naturale e chi lo sceglie sullo scaffale — in linea con la missione di METROFOOD-IT: garantire che le informazioni su ciò che mangiamo siano affidabili, verificabili e a tutela di tutti, dal campo fino alla tavola.

Ringraziamenti

Gli autori ringraziano Michela Verni (Sapienza Università di Roma; San Raffaele University, Roma), Federica Violetta Conti (Sapienza Università di Roma), Consuelo Giustizieri (Sapienza Università di Roma), Erica Pontonio (Università degli Studi di Bari "Aldo Moro"), Giuseppe Perri (Università degli Studi di Bari "Aldo Moro"), Giulia Gorla (Universidad del País Vasco UPV/EHU) e José Manuel Amigo (Universidad del País Vasco UPV/EHU; Ikerbasque, Basque Foundation for Sciences, Bilbao) per il loro fondamentale contributo alla ricerca.

Si ringrazia METROFOOD-IT (Infrastruttura Italiana di Ricerca per la Metrologia e la Tracciabilità nel Settore Agroalimentare), finanziata nell'ambito del PNRR, Missione 4, Componente 2, Investimento 3.1, dall'Unione Europea – NextGenerationEU (IR0000033). G.L. è titolare di un dottorato di ricerca finanziato da METROFOOD-IT.

Bibliografia

- Amigo, J. M., Cruz, J., Bautista, M., MasPOCH, S., Coello, J., & Blanco, M. (2008). Study of pharmaceutical samples by NIR chemical-image and multivariate analysis. *TrAC Trends in Analytical Chemistry*, 27(8), 696–713.
- Amigo, J. M., Martí, I., & Gowen, A. (2013). Hyperspectral Imaging and Chemometrics. In *Data Handling in Science and Technology* (Vol. 28, pp. 343–370). Elsevier.
- Ballabio, D., & Consonni, V. (2013). Classification tools in chemistry. Part 1: Linear models. PLS-DA. *Analytical Methods*, 5, 3790–3798.
- Barnes, R. J., Dhanoa, M. S., & Lister, S. J. (1989). Standard Normal Variate Transformation and De-Trending of Near-Infrared Diffuse Reflectance Spectra. *Applied Spectroscopy*, 43(5), 772–777.

- Gorla, G., Nielsen, F., Montague, P. B., Kösegi, N., & Amigo, J. M. (2026). Challenges and spectra interpretability in textile sorting: NIR hyperspectral images and chemometrics. *Spectrochimica Acta Part A*, 344, 126665.
- Lombardi, G., Conti, F. V., Giustizieri, C., Pontonio, E., Perri, G., Manetti, C., Rizzello, C. G., & Verni, M. (2025). Development of a novel NIR spectroscopy-based chemometric model for sourdough bread authentication. *Food Chemistry*, 493, 145758.
- Lu, Q., Huang, X., & Zhang, L. (2014). A Novel Clustering-Based Feature Representation for the Classification of Hyperspectral Imagery. *Remote Sensing*, 6(6), 5732–5753.
- Mobaraki, N., & Amigo, J. M. (2018). HYPER-Tools. A graphical user-friendly interface for hyperspectral image analysis. *Chemometrics and Intelligent Laboratory Systems*, 172, 174–187.
- Pastor, K., Ačanski, M., Vujić, D., & Rašeta, M. (2022). Sourdough fermentation – traditional process as a modern health choice. *Journal of Agronomy, Technology and Engineering Management*, 5(1), 685–700.
- Straits Research. (2024). *Sourdough Market Size, Share & Trends Analysis Report*. <https://straitsresearch.com/report/sourdough-market>
- Wold, S., Esbensen, K., & Geladi, P. (1987). Principal component analysis. *Chemometrics and Intelligent Laboratory Systems*, 2(1–3), 37–52.

Modelli di explainable artificial intelligence e machine learning per l'agroalimentare: dall'origine e qualità degli alimenti ai servizi intelligenti per gli utenti

Michele Magarelli^{1}, Pierfrancesco Novielli^{2,3}, Pierpaolo Di Bitonto², Donato Romano^{2,3}, Rameez Ahsen², Sabina Tangaro^{2,3}*

¹ Corso di Dottorato in Gestione Sostenibile del Territorio, Dipartimento di Scienze del Suolo, della Pianta e degli Alimenti (DiSSPA), Università degli Studi Aldo Moro, Bari, Italia

² Dipartimento di Scienze del Suolo, della Pianta e degli Alimenti (DiSSPA), Università degli Studi Aldo Moro, Bari, Italia

³ Istituto Nazionale di Fisica Nucleare (INFN), Sezione di Bari, Bari, Italia

* Corresponding Author: michele.magarelli@uniba.it

ABSTRACT – Nel contesto dei sistemi agroalimentari moderni, caratterizzati da elevata complessità e crescente disponibilità di dati eterogenei, l'integrazione di modelli di Machine Learning e tecniche di Explainable Artificial Intelligence (XAI) rappresenta un elemento chiave per migliorare la tracciabilità, la qualità e l'autenticità degli alimenti. Questo lavoro, sviluppato nell'ambito del progetto METROFOOD-IT, propone un approccio integrato che combina analisi avanzate dei dati, infrastrutture di calcolo ad alte prestazioni (HPC) e servizi digitali orientati all'utente. In particolare, vengono sviluppati e applicati modelli di Machine Learning per affrontare problemi complessi quali classificazione dell'origine geografica, previsione di parametri chimico-fisici, analisi di dati microbiologici e genetici, e applicazioni di computer vision. Parallelamente, l'adozione sistematica di tecniche di XAI consente di rendere i modelli interpretabili, identificando le variabili più rilevanti e supportando decisioni trasparenti e verificabili, fondamentali in ambiti critici come la sicurezza e la qualità alimentare. Un elemento centrale del lavoro è rappresentato dall'infrastruttura HPC, che abilita l'elaborazione efficiente di grandi volumi di dati e la gestione di workflow complessi, garantendo al contempo riproducibilità e scalabilità. Tale infrastruttura consente non solo lo sviluppo e la validazione dei modelli, ma anche la

loro trasformazione in servizi digitali accessibili tramite piattaforme di Virtual Access. Questi servizi permettono agli utenti, anche non esperti, di utilizzare strumenti avanzati di analisi caricando i propri dati e ottenendo risultati interpretabili in modo semplice e guidato. I risultati dimostrano come l'integrazione tra dati, modelli e servizi possa generare un ecosistema digitale in grado di supportare efficacemente la qualità, la sicurezza e la tracciabilità degli alimenti, favorendo il trasferimento tecnologico e l'adozione di soluzioni basate su intelligenza artificiale nel settore agroalimentare.

Keywords: Machine Learning, Explainable Artificial Intelligence, Infrastruttura HPC

Introduzione

Obiettivi e Contributo al Progetto METROFOOD-IT

Il progetto METROFOOD-IT nasce con l'obiettivo di rafforzare l'infrastruttura di ricerca italiana dedicata alla metrologia alimentare, ovvero alla misura e alla caratterizzazione degli alimenti in termini di qualità, sicurezza e autenticità. In un contesto in cui i sistemi agroalimentari sono sempre più complessi e globalizzati, diventa fondamentale disporre di strumenti avanzati in grado di analizzare grandi quantità di dati e supportare decisioni affidabili lungo tutta la filiera. In questo scenario, il contributo di questo lavoro si inserisce nello sviluppo e nell'applicazione di metodologie basate su intelligenza artificiale per l'analisi di dati agroalimentari complessi. In particolare, l'obiettivo principale è quello di trasformare dati eterogenei – provenienti da tecniche analitiche come spettroscopia, microbioma e imaging – in conoscenza utile, interpretabile e affidabile. Il lavoro si concentra quindi su tre aspetti fondamentali. Il primo è l'uso di modelli di machine learning per migliorare la capacità di classificare e prevedere proprietà degli alimenti, come origine geografica, qualità e presenza di contaminanti. Il secondo riguarda l'introduzione di tecniche di Explainable Artificial Intelligence, che permettono di comprendere come i modelli prendono decisioni, aumentando la trasparenza e la fiducia nei risultati. Il terzo è la gestione di queste metodologie in un contesto di calcolo scientifico su infrastruttura HPC – High Performance

Computing, in linea con gli obiettivi del progetto METROFOOD-IT. L'infrastruttura digitale di una moderna infrastruttura di ricerca non è solo un insieme di strumenti, ma deve funzionare come un sistema dinamico in cui dati, metodi e servizi si alimentano a vicenda. I dati permettono di fare analisi, le analisi producono nuova conoscenza e nuovi modelli, e questi modelli diventano strumenti utili per interpretare altri dati. Tutto questo ciclo deve poi tradursi in servizi semplici da usare, accessibili e riutilizzabili. Nel contesto di METROFOOD-IT, questo approccio è particolarmente importante. Il settore agroalimentare, infatti, è caratterizzato da una grande varietà di dati: si passa da analisi di laboratorio a dati provenienti da sensori, da immagini e spettri fino a informazioni su microbiologia, genetica e ambiente. Mettere insieme tutte queste informazioni non è semplice, e non può essere fatto in modo frammentato. Per questo motivo è nata l'infrastruttura di calcolo avanzata (HPC) e una serie di soluzioni pratiche capaci di trasformare questa complessità in un punto di forza, al fine di creare un ambiente in cui sia possibile lavorare con grandi quantità di dati in modo efficiente, senza perdere in velocità o accessibilità. In concreto, questo significa sviluppare strumenti che permettano di integrare dati diversi in modo ordinato e riproducibile, riducendo errori e incoerenze; addestrare modelli di intelligenza artificiale sfruttando la potenza del calcolo avanzato; e soprattutto rendere questi modelli comprensibili. Infatti, è fondamentale che non restino delle "scatole nere", ma diventino strumenti capaci di spiegare i risultati e supportare decisioni importanti, ad esempio sulla qualità, sicurezza e autenticità degli alimenti. Un altro aspetto importante è la trasformazione di questi strumenti in servizi concreti, chiamati e-facilities, che possono essere utilizzati direttamente dagli utenti attraverso la piattaforma. Non si tratta quindi solo di ricerca teorica, ma di soluzioni pronte per essere utilizzate. Infine, un punto chiave del lavoro è stato costruire un sistema solido e duraturo, in cui tutte le fasi — dall'addestramento dei modelli alla loro validazione e utilizzo — siano organizzate e controllate nel tempo. Questo è fondamentale perché la differenza tra un prototipo e un servizio realmente utile non dipende solo dall'algoritmo, ma da tutto il processo che lo sostiene. In questo modo, il lavoro contribuisce alla costruzione di un sistema digitale avanzato in grado di supportare la sicurezza alimentare, la tracciabilità e la qualità dei prodotti, con un impatto diretto sia sulla ricerca che sulle applicazioni industriali.

Modelli di machine learning e intelligenza artificiale spiegabile

L'intelligenza artificiale rappresenta oggi uno degli strumenti più potenti per affrontare la complessità dei dati nel settore agroalimentare. I dati prodotti dalle moderne tecnologie analitiche sono infatti caratterizzati da alta dimensionalità, eterogeneità e relazioni non lineari difficili da interpretare con metodi tradizionali. Per questo motivo, sono stati utilizzati modelli di machine learning in grado di apprendere automaticamente dai dati e individuare pattern nascosti. Questi modelli permettono di affrontare diversi tipi di problemi, tra cui classificazione (ad esempio distinguere l'origine di un alimento), regressione (prevedere una quantità, come un contaminante) e clustering (individuare gruppi simili nei dati). Tra gli algoritmi più utilizzati troviamo Random Forest, XGBoost e reti neurali. Questi modelli sono particolarmente efficaci perché riescono a catturare relazioni complesse tra le variabili, garantendo elevata accuratezza nelle previsioni. Tuttavia, proprio questa complessità rappresenta anche un limite: spesso non è immediato capire come il modello arrivi a una determinata decisione. È importante sottolineare che, nei contesti applicativi, un modello non è semplicemente un algoritmo, ma un processo completo. Questo processo include diverse fasi: la selezione, pulizia e trasformazione dei dati; la definizione delle metriche di valutazione; la suddivisione in training, validazione e test; l'ottimizzazione degli iperparametri; la valutazione della robustezza; e, infine, l'interpretazione dei risultati. All'interno del progetto, questo approccio è stato supportato in due modi complementari. Da un lato, sono state utilizzate risorse computazionali avanzate per eseguire questi workflow su dataset complessi in tempi compatibili con le esigenze applicative. Dall'altro, è stato promosso un approccio orientato alla riproducibilità, attraverso l'uso di strumenti e pratiche che permettono di standardizzare l'esecuzione delle analisi. In particolare, l'utilizzo dei container ha avuto un ruolo centrale. In un contesto collaborativo, in cui diversi gruppi lavorano sugli stessi problemi, è fondamentale garantire che i risultati siano replicabili. I container permettono di "impacchettare" codice, librerie e dipendenze, assicurando che i workflow possano essere eseguiti in modo coerente su diverse piattaforme. Questo rappresenta un passaggio chiave per trasformare un'analisi sperimentale in uno strumento riutilizzabile. Dal punto di vista applicativo, i modelli sviluppati coprono una vasta

gamma di problemi tipici del settore agroalimentare: classificazione (origine geografica, autenticità, cultivar), regressione (contenuti chimici o parametri produttivi), rilevamento (ad esempio infestanti o oggetti in immagini), analisi di pattern complessi e studi legati a variabili ambientali e climatiche. In questo contesto, le infrastrutture di calcolo ad alte prestazioni hanno svolto un ruolo fondamentale, non solo riducendo i tempi di elaborazione, ma permettendo anche di esplorare più soluzioni, confrontare modelli diversi e ottenere risultati più robusti e generalizzabili. In altre parole, non si tratta solo di “fare più veloce”, ma di fare meglio, aumentando la qualità complessiva delle analisi. Un elemento qualificante dell’attività svolta è stata la scelta di considerare l’Explainable Artificial Intelligence (XAI) come una componente strutturale e non come un semplice elemento aggiuntivo. Questo insieme di tecniche ha l’obiettivo di rendere i modelli comprensibili, spiegando quali variabili influenzano maggiormente le predizioni; infatti, molti modelli avanzati funzionano come delle “scatole nere”: forniscono risultati accurati, ma non spiegano il perché. In ambiti come la sicurezza e la qualità alimentare, la sola previsione non è sufficiente: le decisioni devono essere trasparenti e verificabili ed è necessario comprendere perché un modello produce un determinato risultato, quali variabili lo influenzano e in quali condizioni il modello può essere considerato affidabile. Questa esigenza ha una doppia natura. Da un lato è una questione scientifica: un modello che individua pattern significativi può contribuire alla comprensione di un fenomeno solo se i fattori determinanti sono interpretabili. Dall’altro lato è una questione operativa: per trasformare un modello in uno strumento utilizzabile da stakeholder come laboratori, aziende o decisori, è fondamentale che esso sia spiegabile, quindi aperto al confronto, alla verifica e, se necessario, alla revisione critica. Nel lavoro svolto, l’interpretabilità è stata affrontata attraverso strategie coerenti con la natura dei dati e dei modelli utilizzati. Nei casi in cui sono stati applicati modelli basati su tecniche multivariate e metodi statistici, l’attenzione si è concentrata sull’identificazione delle variabili più informative e sull’analisi del loro contributo al risultato. Queste pratiche, rese possibili anche grazie alla disponibilità di risorse HPC, hanno contribuito a trasformare l’intelligenza artificiale da semplice strumento predittivo a strumento di supporto alle decisioni. Le tecniche di XAI, quindi, permettono invece di aprire questa “scatola nera” e osservare il contributo delle singole variabili. Tra queste tecniche, una delle più utilizzate è SHAP (SHapley

Additive exPlanations), che consente di quantificare in modo rigoroso l'importanza di ogni variabile nel determinare il risultato del modello. SHAP si basa su concetti provenienti dalla teoria dei giochi e assegna a ciascuna variabile un valore che rappresenta quanto essa contribuisce alla predizione finale. In questo modo, è possibile capire non solo quali variabili sono rilevanti, ma anche in che direzione influenzano il risultato (ad esempio se aumentano o diminuiscono una certa predizione). Un aspetto particolarmente utile di SHAP è che permette di analizzare i modelli a due livelli. A livello locale, consente di spiegare una singola predizione, mostrando quali fattori hanno influenzato il risultato per uno specifico campione. A livello globale, invece, permette di individuare le variabili più importanti sull'intero dataset, fornendo una visione generale del comportamento del modello. Oltre a SHAP, esistono anche altre tecniche di interpretabilità, come LIME o metodi basati sull'analisi dell'importanza delle feature, che contribuiscono a rendere i modelli più spiegabili. Nel contesto agroalimentare, queste tecniche assumono un ruolo fondamentale: permettono, ad esempio, di individuare quali componenti chimiche, segnali spettrali o caratteristiche biologiche sono realmente determinanti per distinguere un alimento, valutarne la qualità o identificarne l'origine. In questo modo, l'intelligenza artificiale non si limita a fornire una risposta, ma aiuta a comprendere i fenomeni sottostanti, trasformando i dati in conoscenza utile e interpretabile. In questo senso, l'HPC non è stato solo il sistema che esegue i calcoli, ma la piattaforma che ha reso possibile sviluppare modelli analizzabili e interrogabili, consentendo cicli di sperimentazione sufficientemente ampi per esplorare in profondità anche gli aspetti legati all'interpretabilità. L'XAI rappresenta quindi un elemento chiave per aumentare la fiducia nei modelli, migliorare la loro applicabilità e supportare decisioni basate su evidenze.

Infrastruttura di Calcolo

Un elemento fondamentale per rendere operative le metodologie sviluppate è la disponibilità di un'infrastruttura di calcolo adeguata, capace di supportare sia la ricerca che l'applicazione pratica dei modelli. Nel progetto METROFOOD-IT, l'infrastruttura è ospitata presso ReCaS, il datacenter realizzato e co-gestito dall'Università degli Studi di Bari "Aldo Moro" e dall'Istituto Nazionale di Fisica Nucleare (INFN).

Essa è stata utilizzata come ambiente HPC su cui eseguire i workflow e gestire i carichi computazionali generati dalle attività di ricerca. L'aspetto più importante del lavoro svolto non è stato solo l'utilizzo delle risorse, ma soprattutto la definizione di un modo di utilizzo coerente con le esigenze di una infrastruttura di ricerca distribuita. In un progetto che coinvolge diversi partner e dati provenienti da contesti differenti, è infatti essenziale che l'ambiente di calcolo non venga visto come un sistema isolato, ma come una componente integrata con le attività sperimentali (Di Bitonto et al., 2024). In questo modo, dati e strumenti possono convergere in un unico ambiente, permettendo di ottenere risultati condivisibili e riutilizzabili. In questa prospettiva, la piattaforma HPC, rappresentata in Fig. 1, è stata pensata come uno strumento abilitante basato su tre dimensioni principali.

La prima riguarda la capacità di calcolo necessaria per addestrare modelli complessi. Le applicazioni sviluppate nel progetto includono, ad esempio, il riconoscimento di oggetti in immagini tramite deep learning, la classificazione e regressione su dati spettroscopici, l'analisi del microbioma, lo studio di dati genetici ad alta dimensionalità e la modellazione di variabili ambientali e climatiche. Tutte queste attività




Figura 1. Infrastruttura di calcolo METROFOOD-IT

richiedono risorse computazionali adeguate, non solo per eseguire i modelli, ma anche per permettere un processo iterativo di sperimentazione, che comprende la selezione delle variabili, l'ottimizzazione dei parametri, il confronto tra modelli e la validazione dei risultati. Per supportare queste esigenze, l'infrastruttura è dotata di tecnologie avanzate che permettono elevate prestazioni e flessibilità. In particolare, è presente un supporto nativo al calcolo su GPU, fondamentale per l'addestramento di modelli di deep learning, affiancato da sistemi di networking ad alte prestazioni basati su RDMA, che consentono una comunicazione veloce tra i nodi di calcolo. Le risorse hardware includono nodi con processori ad alte prestazioni, come CPU AMD multi-core e GPU NVIDIA A100 con ampia memoria dedicata, affiancati da sistemi con memoria di sistema elevata, fino a diversi terabyte, in grado di gestire dataset di grandi dimensioni.

La seconda dimensione riguarda lo storage, che non è visto semplicemente come un archivio, ma come una componente attiva del processo di calcolo. Nei workflow basati sui dati, il modo in cui i dati sono organizzati e accessibili influisce direttamente sulle prestazioni e sull'affidabilità delle analisi. L'infrastruttura utilizza sistemi di storage distribuito, tra cui soluzioni basate su NFS con supporto RDMA, che permettono accesso rapido e scalabile ai dati. Inoltre, sono disponibili servizi di archiviazione compatibili con lo standard S3, utili per gestire grandi quantità di dati in modo flessibile e condiviso. Gestire dataset complessi, come immagini iperspettrali, segnali da sensori, dati microbiologici, genetici e ambientali, significa garantire che questi siano ben organizzati, facilmente accessibili e sempre collegati al loro contesto di origine. Per questo motivo, lo storage è progettato per supportare non solo la conservazione, ma anche la tracciabilità e l'integrazione dei dati.

La terza dimensione è quella dell'operatività, cioè la capacità di trasformare gli esperimenti in servizi concreti. Questo è reso possibile grazie a una piattaforma di data science cloud-native, che integra diversi strumenti per la gestione e l'esecuzione delle attività. Tra questi troviamo sistemi di gestione delle identità e degli accessi, interfacce web per il monitoraggio e il controllo delle attività degli utenti, e ambienti di lavoro interattivi multiutente basati su Jupyter Notebook, che permettono di sviluppare e condividere analisi in modo semplice. I workload vengono gestiti in modo containerizzato, garantendo riproducibilità e isolamento delle applicazioni, mentre un pianificatore

batch consente di organizzare ed eseguire i job in modo efficiente. Inoltre, sono presenti sistemi di elaborazione dati distribuiti che permettono di scalare le analisi su grandi dataset. Uno degli aspetti più critici per qualsiasi piattaforma di intelligenza artificiale nel dominio agroalimentare riguarda la natura dei dati, in particolare in termini di diversità strutturale e semantica. I dati utilizzati provengono infatti da fonti e formati molto diversi tra loro, ciascuno con esigenze specifiche di pre-processing e interpretazione. Alcuni dataset sono basati su immagini e richiedono operazioni legate all'annotazione, alla gestione della risoluzione, dei canali e dei metadati strumentali. Altri sono costituiti da segnali, dati spettroscopici o profili fisico-chimici, che necessitano di normalizzazione, correzione del rumore, estrazione dei picchi o trasformazioni spettrali. Altri ancora derivano da ambiti "omics" e genetici, dove l'elevata dimensionalità e la forte correlazione tra variabili rendono necessarie strategie particolarmente attente di selezione delle feature e di interpretabilità. In questo contesto, la realizzazione di un ambiente HPC per l'archiviazione e l'integrazione dei dati ha richiesto un'attenzione specifica ad alcuni principi fondamentali. Innanzitutto, i dati devono essere organizzati in modo da supportare workflow riproducibili. Questo significa che l'infrastruttura deve distinguere chiaramente tra dati grezzi, dati preprocessati e risultati intermedi e finali. Un errore comune nei progetti basati sui dati è quello di confondere questi livelli, rendendo difficile ricostruire le operazioni effettuate e i parametri utilizzati. In secondo luogo, l'integrazione dei dati non riguarda solo la compatibilità dei formati, ma anche la coerenza semantica. Quando si "armonizzano" dati prodotti da partner diversi, l'obiettivo è costruire una base comune che consenta confronti, aggregazioni e analisi multi-sorgente. Questo implica lavorare su standard di rappresentazione, definire convenzioni per le variabili e costruire un contesto di metadati esplicativo. Anche quando i dati non sono fisicamente centralizzati, l'infrastruttura deve comunque garantire un riferimento coerente e meccanismi che permettano alle pipeline di accedere ai dati corretti nel modo corretto. Infine, la gestione dei dati deve essere bilanciata con le esigenze di sicurezza e controllo degli accessi. In un ambiente pensato per offrire servizi a una comunità più ampia, non tutti i dati possono essere considerati pubblici e liberamente scaricabili. Alcuni dataset possono essere sensibili o soggetti a vincoli di utilizzo. Per questo motivo, la piattaforma HPC e le procedure operative devono essere coerenti con le politiche di accesso e le misure

di protezione definite all'interno del progetto, in coordinamento con le attività di data management. In sintesi, l'infrastruttura non rappresenta solo un supporto tecnico, ma un elemento centrale che consente di integrare dati, modelli e servizi in un unico ecosistema, rendendo possibile un approccio moderno, scalabile e condiviso all'analisi dei dati nel settore agroalimentare.

Applicazioni

Durante l'attività sono stati sviluppati e validati 14 modelli di machine learning e deep learning, coprendo un'ampia gamma di casi d'uso e riflettendo la diversità delle fonti di dati, degli approcci metodologici e dei domini applicativi affrontati all'interno di METROFOOD-IT. Nel loro insieme, queste applicazioni dimostrano come la piattaforma HPC e il framework di intelligenza artificiale abbiano supportato non solo lo sviluppo di modelli predittivi, ma anche la loro validazione in contesti concreti agroalimentari, biologici e ambientali. Per fornire una visione più immediata delle principali aree di risultato, dei domini applicativi, dei tipi di dati e degli impatti attesi, la Tabella 1 riassume le principali famiglie di applicazioni di AI sviluppate e validate durante l'attività.

Una prima area di risultati riguarda la tracciabilità e l'autenticazione, con particolare attenzione agli approcci basati su microbioma e profili microbici. L'analisi del microbioma della Mozzarella di Bufala Campana DOP, finalizzata alla discriminazione dell'origine geografica e all'autenticazione del prodotto (DOP/non DOP), rappresenta un esempio di come i modelli di machine learning possano sfruttare segnali biologici complessi per rispondere a esigenze concrete di tutela della qualità (Magarelli et al., 2024). In questi casi, la sfida non è solo ottenere predizioni accurate, ma anche interpretare quali componenti del profilo microbico contribuiscono alla discriminazione, rafforzando così la credibilità dei risultati. Una seconda area riguarda l'analisi fisico-chimica e spettroscopica. La previsione del contenuto di esteri etilici negli oli extravergini di oliva a partire da spettri FT-IR, realizzata tramite modelli di regressione basati su tecniche avanzate di machine learning, dimostra come l'AI possa supportare metodi rapidi e basati sui dati per la valutazione della qualità (Magarelli et al., 2025). In queste applicazioni, la combinazione tra preprocessing spettrale, modelli di regressione e interpretazione del-

Tabella 1. Tabella riassuntiva delle applicazioni AI validate durante l'attività, descritte da area di applicazione, caso d'uso, tipo di dato e valore aggiunto al progetto.

Area di applicazione	Caso d'uso rappresentativo	Tipo/i principale di dati	Principale valore aggiunto
Tratracciabilità e autenticazione	Discriminazione geografica e autenticazione della Mozzarella di Bufala Campana DOP	Microbiome and microbial profiles	Supporta l'autenticazione e la tracciabilità del prodotto, migliorando la fiducia attraverso segnali biologici interpretabili
Analisi fisico-chimica e spettroscopica	Previsione del contenuto di esteri etilici negli oli extravergini d'oliva	Spettri FT-IR	Consente una valutazione rapida e basata sui dati della qualità con caratteristiche spettrali interpretabili
Computer vision and deep learning	Valutazione della maturazione dei pomodori; Rilevamento automatico delle erbacce dalle immagini di campo	Immagini digitali	Automatizza le ispezioni visive e beneficia dell'HPC per l'addestramento, l'ottimizzazione e l'analisi della robustezza
Classificazione geografica e varietale	Classificazione dell'origine del grano; Discriminazione delle cultivar (Antalis, Iride, Platone)	Imaging iperspettrale NIR, spettri Raman	Consente la discriminazione dell'origine geografica e delle cultivar attraverso l'estrazione di caratteristiche informative dai dati spettroscopici
Genetica, fenotipi e produttività	Previsione della resa nelle cultivar di mandorle; previsione del numero di foglie e del tempo di fioritura in <i>Arabidopsis thaliana</i>	Dati genetici e fenotipici	Supporta l'allevamento e la selezione consentendo la previsione precoce e l'identificazione dei marcatori
Qualità e nutrizione nei prodotti di origine animale	Analisi della carne di pollo in relazione alla dieta a base di camelina e alla composizione degli acidi grassi	Dati composizionali e nutrizionali	Aiuta a collegare gli input alimentari alla composizione del prodotto, supportando strategie alimentari più sane e sostenibili

Area di applicazione	Caso d’uso rappresentativo	Tipo/i principale di dati	Principale valore aggiunto
Ambiente e clima	Risposta respiratoria del suolo ai cambiamenti climatici; identificazione di gruppi di suolo ad alto rischio; Studi sul deterioramento del formaggio basati sui microbiomi	Dati di sensibilità microbica, ambientale e termica	Aiuta a collegare gli input alimentari alla composizione del prodotto, supportando strategie alimentari più sane e sostenibili

le caratteristiche spettrali è fondamentale per garantire che il modello non sia solo correlativo, ma un supporto affidabile per le valutazioni. Una terza area riguarda la computer vision e il deep learning, con applicazioni che spaziano dalla valutazione della maturazione del pomodoro tramite object detection (ad esempio con modelli YOLO) fino al riconoscimento automatico di infestanti da immagini acquisite in campo (Ahsen et al., 2025a,b). Questi scenari evidenziano la necessità di risorse HPC, poiché l’addestramento di reti neurali profonde — soprattutto quando richiede sperimentazione su architetture, tecniche di data augmentation e ottimizzazione — è computazionalmente molto impegnativo. Inoltre, trasformare questi modelli in strumenti utilizzabili implica considerare aspetti come prestazioni, tempi di inferenza, robustezza in condizioni variabili e capacità di spiegare le decisioni del modello, ad esempio attraverso l’analisi delle regioni informative dell’immagine. Una quarta area riguarda la classificazione geografica e varietale dei prodotti agricoli utilizzando dati avanzati, come l’imaging iperspettrale nel vicino infrarosso e segnali combinati provenienti da naso elettronico e gascromatografia. I modelli sviluppati per classificare l’origine geografica del grano (Nord/Centro/Sud Italia) e distinguere diverse cultivar (Antalis, Iride, Platone) dimostrano la capacità del framework di integrare dati sensoriali complessi, estrarre descrittori significativi e costruire modelli discriminanti. Anche in questi casi, l’interpretabilità è fondamentale: individuare quali bande spettrali o componenti del segnale guidano la classificazione permette di comprendere meglio i fenomeni e migliorare la robustezza dei modelli. Una quinta area riguarda le previsioni legate a genetica, fenotipi e produttività. La previsione della resa (shelling fraction) in cultivar di mandorlo a partire da dati genetici, con

L'identificazione di marcatori associati alla produttività, rappresenta un esempio emblematico di utilizzo dell'AI a supporto del miglioramento genetico e della selezione. Analogamente, la previsione di tratti fenotipici complessi in *Arabidopsis thaliana* (come il numero di foglie e i giorni alla fioritura) a partire da dati genetici mostra come i modelli possano contribuire a una previsione precoce di caratteristiche chiave, riducendo tempi e costi sperimentali e migliorando l'adattamento a diversi scenari climatici (Novielli et al., 2024a; Novielli et al., 2025a). In entrambi i casi, il valore aggiunto non risiede solo nella previsione, ma anche nella capacità di individuare i marcatori più rilevanti, fornendo indicazioni utili per decisioni e pianificazione sperimentale. Una sesta area riguarda la qualità e la nutrizione nei prodotti di origine animale, come l'analisi della carne di pollo mediante machine learning per studiare la relazione tra il contenuto di acidi grassi nei tessuti e una dieta basata su camelina. In questo contesto, il machine learning diventa uno strumento per collegare input alimentari e risultati composizionali, supportando la definizione di strategie nutrizionali più sane e sostenibili. Anche in questo caso, l'interpretabilità è essenziale per comprendere quali variabili influenzano maggiormente i risultati. Infine, una settima area riguarda la dimensione ambientale e climatica. I modelli predittivi della respirazione del suolo in risposta ai cambiamenti climatici, che integrano variabili microbiche e ambientali, così come i modelli di machine learning per l'identificazione di cluster di suolo ad alto rischio basati sulla sensibilità Q10 alla temperatura, mostrano come l'infrastruttura e il framework di AI siano stati applicati anche a fenomeni complessi che richiedono l'integrazione di più fonti informative e l'interpretazione di relazioni non lineari (Novielli et al., 2024b; Novielli et al., 2025b; Romano et al., 2025). In questi casi, l'AI non è solo uno strumento di classificazione, ma un supporto per comprendere la vulnerabilità dei sistemi e sviluppare strategie di mitigazione e adattamento. In modo complementare, l'analisi del microbioma dei formaggi per lo studio del deterioramento rappresenta un'ulteriore applicazione significativa. Attraverso modelli di machine learning è stato possibile identificare i batteri associati al deterioramento, prevedere il grado di spoilage a partire dai profili microbici e individuare marcatori microbiologici utili per il controllo qualità e l'estensione della shelf-life. In questo contesto, la combinazione tra accuratezza e interpretabilità è fondamentale per ottenere risultati utilizzabili in ambito industriale. Questi esempi dimostrano come l'integrazione

tra AI e dati analitici permetta di affrontare problemi complessi in modo efficace, fornendo risultati affidabili e interpretabili.

Servizi per gli Utenti

Un passaggio fondamentale all'interno dell'attività riguarda la trasformazione dei risultati computazionali in servizi. In un contesto infrastrutturale, questo processo, spesso definito "servitizzazione", significa rendere un algoritmo utilizzabile da altri in modo affidabile, attraverso un'interfaccia chiara, un contesto di utilizzo ben definito e procedure che ne garantiscano continuità e manutenzione nel tempo. Questa transizione non è automatica, ma richiede sia scelte tecniche che organizzative. È necessario definire cosa significa che un modello è "operativo", stabilire come gestire versioni e aggiornamenti, progettare le modalità

di accesso e assicurare le risorse necessarie per sostenere l'utilizzo nel tempo. All'interno del progetto, la piattaforma METROFOOD-IT presso ReCaS ha permesso di addestrare i modelli e di renderli disponibili in modo coordinato, facilitando la creazione di servizi digitali. Tuttavia, non tutti i modelli sviluppati sono immediatamente adatti a diventare servizi. Alcuni rappresentano risultati di ricerca molto specifici, utili per validare metodologie e produrre nuova conoscenza, ma non ancora pronti per un utilizzo generalizzato. Altri modelli, invece, possiedono caratteristiche che ne facilitano la trasformazione in servizi: dataset ben definiti, pipeline consolidate, risultati facilmente interpretabili, applicazioni immediate e requisiti di input gestibili. Questo numero non rappresenta semplicemente modelli funzionanti, ma workflow che hanno raggiunto un livello sufficiente di stabilità, integrazione e maturità per essere considerati veri e propri servizi digitali. Questi servizi sono in grado di eseguire analisi direttamente sull'infrastruttura, gestire in modo coerente input e output in linea con la piattaforma dati e garantire prestazioni adeguate. Il risultato è particolarmente significativo perché dimostra la capacità del progetto di passare dalla fase sperimentale alla realizzazione di servizi concreti, accessibili agli utenti. Inoltre, rappresenta un importante indicatore di sostenibilità: un'infrastruttura di ricerca digitale genera impatto reale non solo attraverso pubblicazioni scientifiche, ma soprattutto rendendo disponibili strumenti utilizzabili dalla comunità, rappresentata non solo ai ricercatori, ma anche a imprese, laboratori e altri stakeholder del settore agroalimentare. I servizi

CSV Template

Scarica questo template CSV e usalo come base per costruire i tuoi dati di input.

synthetic_data

Try Our AI Model Test AI Model

Almond Genotype-to-Phenotype Prediction

Strengthening of the Italian Research Infrastructure for Monitoring and Open Access Data in support to the Agrifood

Almond Genotype-to-Phenotype Prediction

L'applicazione utilizza modelli di Machine Learning per analizzare varianti genetiche (SNP) e prevedere un tratto fenotipico fondamentale per la qualità industriale della mandorla. Grazie all'integrazione di tecniche di Explainable AI (XAI) tramite valori SHAP, l'utente può comprendere l'importanza di ogni singola variante genetica nella predizione effettuata.

Formato dati input

L'applicazione accetta file in formato CSV contenenti dati genetici codificati come segue:

- 0: Omozigote per l'allele di riferimento.
- 1: Eterozigote.
- 2: Omozigote per l'allele alternativo.
- NA-: Dato mancante.

Le colonne devono seguire il formato S<chromosoma>_<posizione> (es. S1_20155).

Predizioni

Un file con il valore medio di "Shelling Percentage" e la relativa deviazione standard calcolata tra i modelli caricati.

Spiegabilità delle predizioni: Grafici a barre (SHAP bar plots) che mostrano l'impatto dei geni principali per ogni campione analizzato.

Riferimento scientifico

Novelli, P., Romano, D., Pavesi, S., Lecciale, P., Staffoloni, A. M., Diacono, D., ... & Tangari, S. (2024). Explainable artificial intelligence for genotype-to-phenotype prediction in plant breeding: a case study with a dataset from an almond germplasm collection. *Frontiers in Plant Science*, 15, 1434229.

Figura 2. Interfaccia del Access point riferito all'analisi predittiva dei dati genotipo-fenotipo del mandorlo.

sono accessibili tramite piattaforme digitali, in particolare attraverso sistemi di Virtual Access, che rappresentano uno degli elementi più innovativi dell'infrastruttura. Questo approccio consente agli utenti di utilizzare strumenti avanzati senza dover installare software complessi o disporre direttamente di risorse computazionali elevate. L'accesso avviene tramite un portale dedicato attraverso il quale l'utente può selezionare la tipologia di matrice di interesse, ad esempio alimenti, suolo o altri campioni ambientali. In base alla scelta effettuata, il sistema indirizza automaticamente verso il servizio più adatto, già configurato per gestire quel tipo di dati e di analisi. Una volta effettuato l'accesso, l'utente può caricare i propri dati, che possono essere di natura diversa, come immagini, spettri, dati chimici o microbiologici. In Fig. 2 è possibile apprezzare l'interfaccia del Access point riferito all'analisi predittiva dei dati genotipo-fenotipo del mandorlo.

A questo punto entra in gioco l'infrastruttura: i dati vengono elaborati attraverso pipeline automatizzate che includono tutte le fasi necessarie, dal preprocessing fino all'applicazione dei modelli di intelligenza artificiale. Un aspetto fondamentale è che l'utente non deve conoscere nel dettaglio il funzionamento dei modelli o delle tecniche utilizzate. L'intero processo è progettato per essere semplice e guidato, mentre la complessità rimane "dietro le quinte", gestita dall'infrastruttura. Al termine dell'analisi, il sistema restituisce i risultati in modo strutturato e comprensibile. Non si tratta solo di numeri o previsioni, ma anche di informazioni aggiuntive che aiutano a interpretare i risultati, grazie all'integrazione di tecniche di explainable AI. Ad esempio, è possibile evidenziare quali variabili o caratteristiche del campione hanno influenzato maggiormente il risultato ottenuto. Questo approccio ha un impatto molto importante, perché rende accessibili strumenti avanzati anche a utenti che non hanno competenze specifiche in machine learning o data science. Allo stesso tempo, garantisce che le analisi siano eseguite in modo standardizzato, riproducibile e affidabile. In sintesi, i sistemi di Virtual Access permettono di trasformare modelli complessi e infrastrutture avanzate in servizi concreti e facilmente utilizzabili, favorendo il trasferimento tecnologico e l'adozione di soluzioni basate su intelligenza artificiale nel settore agroalimentare. Questo approccio consente di colmare il divario tra ricerca e applicazione, favorendo l'innovazione e migliorando la qualità dei processi nel settore agroalimentare.

Conclusioni

Il lavoro svolto all'interno del progetto METROFOOD-IT dimostra come l'integrazione tra intelligenza artificiale, infrastrutture digitali avanzate e approcci orientati all'interpretabilità rappresenti un elemento chiave per affrontare la crescente complessità dei sistemi agroalimentari. Uno degli aspetti più rilevanti emersi è la necessità di considerare dati, modelli e servizi non come elementi separati, ma come parti di un unico sistema integrato. I dati generano analisi, le analisi producono modelli, e i modelli, a loro volta, diventano strumenti operativi che possono essere messi a disposizione degli utenti attraverso servizi digitali. Questo ciclo rappresenta il cuore di una moderna infrastruttura di ricerca e costituisce il principale contributo del lavoro

svolto. Dal punto di vista metodologico, l'adozione di tecniche di machine learning ha permesso di affrontare problemi complessi in diversi ambiti, dalla tracciabilità degli alimenti alla qualità, dalla genetica alla dimensione ambientale. Tuttavia, il vero valore aggiunto non risiede solo nella capacità predittiva dei modelli, ma nella possibilità di interpretarli. L'integrazione sistematica di tecniche di Explainable Artificial Intelligence ha infatti consentito di trasformare modelli complessi da semplici "scatole nere" a strumenti di supporto alle decisioni, in grado di fornire informazioni utili e comprensibili. Un altro elemento fondamentale è stato il ruolo dell'infrastruttura HPC, che ha reso possibile non solo l'esecuzione efficiente dei modelli, ma anche l'intero processo di sviluppo, validazione e sperimentazione. L'HPC ha permesso di lavorare su dataset eterogenei e ad alta dimensionalità, di confrontare soluzioni alternative e di migliorare la qualità complessiva dei risultati. In questo senso, l'infrastruttura non rappresenta solo un supporto tecnico, ma un vero e proprio abilitatore dell'innovazione. Le numerose applicazioni sviluppate dimostrano la versatilità dell'approccio adottato. Dalla mozzarella all'olio extravergine, dal grano ai dati genetici, fino agli studi ambientali, l'intelligenza artificiale si è dimostrata uno strumento efficace per estrarre valore da dati complessi. In tutti questi casi, la combinazione tra accuratezza e interpretabilità ha permesso di ottenere risultati affidabili e utilizzabili in contesti reali. Un aspetto particolarmente significativo riguarda la trasformazione dei modelli in servizi digitali. Il passaggio dalla sperimentazione alla cosiddetta "servitizzazione" rappresenta infatti uno degli elementi più concreti del progetto. Attraverso i sistemi di Virtual Access, i modelli sono stati resi accessibili a utenti diversi, anche non esperti, contribuendo a ridurre il divario tra ricerca e applicazione. Questo dimostra come un'infrastruttura di ricerca possa generare impatto reale solo quando riesce a rendere disponibili strumenti utilizzabili dalla comunità. Infine, il lavoro evidenzia l'importanza della riproducibilità, della standardizzazione e della sostenibilità nel tempo. L'adozione di workflow strutturati, l'uso di container e la gestione del ciclo di vita dei modelli rappresentano elementi fondamentali per garantire che le soluzioni sviluppate non rimangano prototipi isolati, ma possano evolvere in servizi affidabili e duraturi. In conclusione, l'integrazione di questi metodi all'interno del progetto METROFOOD-IT mostra come sia possibile costruire un ecosistema digitale integrato, in cui dati, modelli e servizi cooperano per supportare qualità, sicurezza e tracciabilità degli alimenti. Questo ap-

proccio rappresenta un passo importante verso sistemi agroalimentari sempre più digitali, trasparenti e basati sui dati, in grado di rispondere alle sfide future in modo efficace e sostenibile.

Bibliografia

- Ahsen, R., Di Bitonto, P., Magarelli, M., Romano, D., Novielli, P., & Tangaro, S. (2025a). Deep Learning for Tomato Ripeness Detection: A YOLO-Based Approach. In *International Conference on Image Analysis and Processing* (pp. 505-512). Cham: Springer Nature Switzerland. https://doi.org/10.1007/978-3-032-11381-8_42
- Ahsen, R., Di Bitonto, P., Novielli, P., Magarelli, M., Romano, D., Diacono, D., ... & Tangaro, S. (2025b). Harnessing digital twins for sustainable agricultural water management: a systematic review. *Applied Sciences*, 15(8), 4228. <https://doi.org/10.3390/app15084228>
- Di Bitonto, P., Magarelli, M., Novielli, P., Romano, D., Diacono, D., De Trizio, L., ... & Tangaro, S. (2024). From data to nutrition: the impact of computing infrastructure and artificial intelligence. *Exploration of Foods and Foodomics*, 2, 810-829. <https://hdl.handle.net/11696/84459>
- Magarelli, M., Grassi, S., Squeo, G., Novielli, P., Bellotti, R., Caponio, F., ... & Tangaro, S. (2025). Unlocking extra virgin olive oil identification: predicting ethyl esters with explainable AI on IR spectra. *Food Chemistry*, 147013. <https://doi.org/10.1016/j.foodchem.2025.147013>
- Magarelli, M., Novielli, P., De Filippis, F., Magliulo, R., Di Bitonto, P., Diacono, D., ... & Tangaro, S. (2024). Explainable artificial intelligence and microbiome data for food geographical origin: the Mozzarella di Bufala Campana PDO Case of Study. *Frontiers in Microbiology*, 15, 1393243. <https://doi.org/10.3389/fmicb.2024.1393243>
- Novielli, P., Magarelli, M., Romano, D., De Trizio, L., Di Bitonto, P., Monaco, A., ... & Tangaro, S. (2024b). Climate change and soil health: Explainable artificial intelligence reveals microbiome response to warming. *Machine Learning and Knowledge Extraction*, 6(3), 1564-1578. <https://doi.org/10.3390/make6030075>
- Novielli, P., Nazzicari, N., Pavan, S., Delvento, C., Diacono, D., Zoani, C., ... & Tangaro, S. (2025a). Leveraging Explainable Artificial Intelligence for Genotype-to-Phenotype Prediction: A Case Study in Arabidopsis thaliana. *Applied System Innovation*, 8(6), 164. <https://doi.org/10.3390/asi8060164>
- Novielli, Pierfrancesco, et al. "Leveraging explainable AI to predict soil respiration sensitivity and its drivers for climate change mitigation". *Scientific Reports* 15.1 (2025b): 12527. <https://doi.org/10.1038/s41598-025-96216-y>
- Novielli, P., Romano, D., Pavan, S., Losciale, P., Stellacci, A. M., Diacono, D., ... & Tangaro, S. (2024a). Explainable artificial intelligence for genotype-to-

phenotype prediction in plant breeding: a case study with a dataset from an almond germplasm collection. *Frontiers in Plant Science*, 15, 1434229. <https://doi.org/10.3389/fpls.2024.1434229>

Romano, D., Magarelli, M., Novielli, P., Diacono, D., Di Bitonto, P., Amoroso, N., ... & Tangaro, S. (2025). Predictive and explainable machine learning models for endocrine, nutritional, and metabolic mortality in Italy using geolocalized pollution data. *Applied System Innovation*, 8(2), 48. <https://doi.org/10.3390/asi8020048>

Dal suolo al pomodoro: l'impronta geochimica per l'autenticazione di prodotti agroalimentari.

Tracciabilità geochimica suolo–pomodoro

Raffaella Ofano^{1}, Luigi Ruggiero¹, Diana Agrelli¹, Carmine Amalfitano¹, Paola Adamo¹*

¹Dipartimento di Agraria, Università degli Studi di Napoli Federico II

*Corresponding Author: raffaella.ofano@unina.it

ABSTRACT – Lo studio valuta l'applicabilità dell'analisi multielementare per l'autenticazione geografica del Pomodorino del Piennolo del Vesuvio con Denominazione di Origine Protetta (DOP). In particolare, è stato esplorato il legame tra la composizione multielementare del prodotto e quella dei suoli di coltivazione, considerando quattro aziende all'interno dell'areale di produzione DOP e quattro esterne ad esso. I profili multielementari sono stati determinati, sia nei frutti che nelle frazioni prontamente e potenzialmente biodisponibili estratte dai suoli, mediante spettrometria di massa con plasma accoppiato induttivamente (ICP-MS). I dati ottenuti sono stati elaborati attraverso approcci di statistica multivariata, includendo l'Analisi delle Componenti Principali (PCA) e l'Analisi Discriminante Lineare (LDA) e la correlazione di Spearman. I risultati evidenziano una chiara discriminazione dei campioni in funzione dell'origine geografica, con pattern di clustering distinti sia per i pomodori sia per i suoli. Inoltre, le correlazioni statisticamente significative tra specifici elementi nelle due matrici, frutto e frazioni biodisponibili del suolo, sottolineano l'influenza delle caratteristiche pedoclimatiche sul profilo multielementare del pomodoro. L'approccio proposto si dimostra promettente come strumento per la tracciabilità e l'autenticazione su base scientifica del Pomodorino del Piennolo del Vesuvio DOP, risultando utile alla valorizzazione e tutela del prodotto.

Keywords: Tracciabilità geografica, Autenticazione, DOP, Profilo multielementare, Pomodoro, Suolo

Introduzione

Negli ultimi decenni, i sistemi di qualità certificata, quali le Denominazioni di Origine Protetta (DOP) e le Indicazioni Geografiche Protette (IGP), hanno assunto un ruolo centrale nella valorizzazione delle produzioni agroalimentari tipiche e nella tutela della loro identità territoriale (Belletti et al., 2007). Tali certificazioni garantiscono il rispetto di specifici disciplinari e sanciscono il legame tra prodotto e area geografica di origine, contribuendo alla protezione delle tipicità locali e al rafforzamento della fiducia dei consumatori. Tuttavia, i sistemi di tracciabilità risultano prevalentemente di natura documentale fondata su registri di produzione, verifiche lungo la filiera e controlli amministrativi. Sebbene indispensabili, tali approcci possono presentare criticità nella dimostrazione oggettiva dell'origine geografica, ne consegue la necessità di integrarli con metodi analitici basati su evidenze scientifiche. In questo contesto si inserisce il crescente interesse verso strategie analitiche in grado di associare ai prodotti agroalimentari una “firma” geochimica riconducibile al territorio di produzione. La composizione chimica dei prodotti agricoli è il risultato dell'interazione tra fattori genetici, condizioni pedoclimatiche e pratiche agronomiche, tale da consentire la possibile identificazione di marcatori chimici discriminanti legati all'origine geografica (Lu et al., 2026).

Tra le diverse matrici agroalimentari il pomodoro è di particolare interesse essendo uno dei prodotti più consumati a livello globale. Esso è coltivato in molteplici aree del mondo e in alcune realtà di elevato pregio ambientale e socioeconomico tra cui le pendici del Vesuvio in Campania, dove è esclusiva la produzione del Pomodorino del Pienno del Vesuvio DOP. Tale prodotto è caratterizzato da varietà autoctone e da un tradizionale metodo di confezionamento manuale in grappoli (*piennoli*), che ne consente una prolungata conservabilità anche in condizioni ambientali non controllate. Il Pomodorino del Pienno del Vesuvio ha ottenuto il riconoscimento DOP nel 2009 ed è coltivato nell'area del complesso vulcanico Somma-Vesuvio, caratterizzata da peculiari condizioni pedoclimatiche. La natura vulcanica dei suoli, in combinazione con fattori climatici e pratiche tradizionali di coltivazione e conservazione, influenza in modo significativo le caratteristiche morfologiche e qualitative del prodotto, conferendogli specifiche proprietà organolettiche ed elevata conservabilità. Il presente studio è stato sviluppato nell'ambito della partecipazione del Consorzio di Tutela del

Pomodorino del Piennolo del Vesuvio DOP alla open call di METRO-FOOD-IT “Open data per l'autenticità e la rintracciabilità degli alimenti”, che ha consentito l'accesso ai servizi analitici forniti dalla facility del Dipartimento di Agraria dell'Università degli Studi di Napoli Federico II. Tale collaborazione si inserisce nelle iniziative volte a promuovere l'adozione di approcci scientifici avanzati a supporto dei sistemi di autenticazione e tracciabilità nel settore agroalimentare. In questo ambito, l'analisi multielementare, mediante spettrometria di massa con plasma accoppiato induttivamente (ICP-MS), si configura come uno strumento efficace per la determinazione della provenienza geografica (Wang et al., 2021). La distribuzione degli elementi minerali nelle piante riflette infatti, in larga misura, la composizione geochimica dei suoli di coltivazione e le condizioni ambientali, consentendo di stabilire relazioni tra prodotto e territorio. Tale approccio consente inoltre di valutare aspetti qualitativi e di sicurezza del prodotto, attraverso la determinazione degli elementi essenziali e la verifica della presenza di eventuali contaminanti, come i metalli pesanti. Ciò contribuisce non solo alla tutela del consumatore, ma anche al rispetto delle normative vigenti in materia di sicurezza alimentare. Il contesto produttivo del Pomodorino del Piennolo del Vesuvio DOP è ben consolidato e caratterizzato da una limitata variabilità annuale nel numero di aziende registrate, le quali garantiscono il rispetto dei disciplinari attraverso sistemi di controllo pre e post-produzione. Un'indagine condotta su un campione di aziende aderenti al Consorzio (circa il 45% del totale nella stagione colturale 2022) ha evidenziato che il 41% delle aziende coltiva una sola varietà locale, mentre il restante 59% ne coltiva da 2 a 4 contemporaneamente. Le varietà locali più frequentemente impiegate per la produzione del Pomodorino del Piennolo del Vesuvio DOP sono *Acampora* (55%), *Principe Borghese* e *Cozzolino* (41%), *Patanara* (24%), *Lucariello* (21%), *Riccia di San Vito* (10%), *De Luca* e *Lampadina* (entrambi con meno del 5%). La scelta varietale è influenzata da diversi fattori, tra cui l'adattamento alle specifiche condizioni pedoclimatiche, le opportunità di commercializzazione (prodotto fresco, *piennolo* e trasformati), la disponibilità del materiale di propagazione e l'utilizzo di piantine autoprodotte (in linea con il ruolo di “custodi” attribuito alle aziende dal disciplinare di produzione, art.5). In questo scenario, lo studio si propone di investigare l'applicabilità dell'analisi multielementare per la caratterizzazione e la discriminazione geografica del Pomodorino del Piennolo del Vesuvio DOP. A tal fine, sono stati analizzati campioni di suolo e di pomodoro

provenienti da aziende localizzate sia all'interno sia all'esterno dell'areale di produzione, con l'obiettivo di individuare una specifica firma multielementare associata al territorio e sviluppare un approccio analitico in grado di supportare i sistemi di tracciabilità esistenti.

Materiali e Metodi

Area di studio

La produzione del Pomodorino del Piennolo del Vesuvio DOP è concentrata nell'area del complesso vulcanico Somma-Vesuvio. Le aziende agricole ricadenti nell'areale, prevalentemente distribuite a nord del complesso vulcanico, al confine con la Piana Campana (Fig. 1a), si collocano a diverse quote altimetriche (Fig. 1b) e su versanti con differenti esposizioni (Fig. 1c).

Tale configurazione determina un'elevata variabilità microclimatica che, unitamente alla marcata eterogeneità geologica e pedologica, contribuisce a rendere l'ambiente culturale fortemente frammentato dal punto di vista pedoclimatico. I suoli del complesso vulcanico Somma-Vesuvio sono il risultato di processi pedogenetici avvenuti su depositi di cenere, lapilli e scorie, colate piroclastiche e lave di età storica (Arnalds et al., 2007). In particolare, la variabilità pedologica dell'areale comprende (Fig. 2, Di Gennaro & Terribile, 1999):

- suoli con differenziazione del profilo da debole a moderata e proprietà antiche che vanno da debolmente a moderatamente espresse, correlate alle attività del vetro vulcanico primario;
- suoli calcarei che si sviluppano su depositi piroclastici contenenti carbonato di calcio;
- suoli debolmente sviluppati su lapilli e cenere dell'eruzione del 1944.

A tale variabilità pedologica (Fig. 2), si associa una differenziazione nell'uso del suolo. I suoli dei versanti alti, sia del Vesuvio (area marrone) sia del monte Somma (area azzurra), sono prevalentemente destinati all'uso forestale con boschi di caducifoglie mesofile, leccio e pinete antropiche. In particolare, sui versanti alti del Vesuvio, oltre ai boschi, sono presenti aree nude su ceneri e lave; sui versanti alti del monte Somma si riscontrano boschi di castagno, orti arborati e vigneti. I suoli dei versanti bassi a Sud e Ovest del Vesuvio (area viola) e a Nord e a




Figura 1. Distribuzione delle aziende nell'areale di produzione DOP (a), per fasce altimetriche (b), per esposizione dei versanti (c).




Figura 2. Carta dei suoli 1:75000 dell'areale di produzione DOP (modificata da Di Gennaro & Terribile, 1999).

Est del monte Somma (area verde) sono principalmente destinati ad un uso agricolo, con orti arborati e vitati, arboreti da frutto, colture orto-floricole protette. L'areale di produzione del Pomodorino del Pienolo del Vesuvio DOP coincide in larga parte con l'intera estensione del complesso Somma-Vesuvio. Essa comprende i territori comunali di Boscoreale, Boscotrecase, Cercola, Ercolano, Massa di Somma, Ottaviano, Pollena Trocchia, Portici, Sant'Anastasia, San Giorgio a Cremano, San Giuseppe Vesuviano, San Sebastiano al Vesuvio, Somma Vesuviana, Terzigno, Torre Annunziata, Torre del Greco, Trecase, e parte del comune di Nola. Secondo il sesto Censimento generale dell'agricoltura, la superficie agricola utilizzata (SAU) dell'area è pari a 2500 ha e comprende circa 1992 aziende agricole. Di questi, 48 ha (1,9 % nel 2021) sono destinati alla coltivazione del Pomodorino del Pienolo del Vesuvio DOP. Nel 2022, 58 aziende risultavano iscritte al sistema dei controlli della DOP, rappresentando il 2.9 % del totale.

Raccolta dei campioni e preparazione

Nel lavoro svolto in sinergia con il consorzio, sono stati raccolti campioni di pomodoro della varietà locale *Acampora* e campioni di suolo di coltivazione presso otto aziende agricole, di cui quattro localizzate all'interno dell'areale DOP (AZ da 1 a 4) e quattro esterne (AZ da 5 a 8) (Fig. 3). Per ciascuna azienda sono state prelevate tre repliche di campo, al fine di rappresentare adeguatamente la variabilità intra-

azienda, sia per la matrice vegetale sia per il suolo, per un totale complessivo di 24 campioni di pomodoro e 24 campioni di suolo.

I campioni di pomodoro (6 frutti per campione) sono stati sottoposti a un accurato lavaggio per rimuovere eventuali contaminanti superficiali, frullati per ottenere una polpa omogenea, essiccati in liofilizzatore e finemente polverizzati. Due aliquote da 0,2 g di ciascun campione sono state sottoposte a digestione acida in tubi in Teflon (2,5 mL HNO_3 14M e 0,5 mL HCl 3 M) mediante digestore a microonde. L'accuratezza del metodo è stata verificata mediante analisi di un materiale di riferimento certificato (CRM) di foglia di pomodoro (LGC Standards, NCS ZC 85006). I campioni di suolo (1 kg ciascuno, 3 per azienda) sono stati prelevati a una profondità di 20–30 cm nelle interfile, essiccati all'aria e setacciati a 2 mm. Le frazioni biodisponibili sono state estratte in duplicato: la frazione prontamente biodisponibile con NH_4NO_3 1 M (ISO 19730:2008) e quella potenzialmente biodisponibile con EDTA 0,05 M (ISO 22190:2020).




Figura 3. Aziende per lo studio nell'areale DOP (rosso) e non DOP (blu)

Analisi ICP-MS

Le soluzioni ottenute dalla digestione dei pomodori e quelle estratte dal suolo, opportunamente centrifugate e filtrate, sono state diluite con acido nitrico e cloridrico (0.5% v/v) 1:1 e analizzate mediante ICP-MS (Thermo Fisher Scientific, iCAP-Q). I limiti di rilevabilità (LOD) sono stati calcolati secondo le linee guida IUPAC come tre volte la deviazione standard dei bianchi procedurali (soluzioni di acidi processate con le stesse procedure adottate per i campioni in parallelo). Le concentrazioni inferiori al LOD non sono state considerate nelle elaborazioni successive.

Analisi statistica

L'analisi statistica è stata condotta utilizzando i software SPSS (versione 23.0) e XLSTAT. Prima delle analisi multivariate i dati sono stati sottoposti a trasformazione logaritmica allo scopo di ridurre l'influenza dei valori estremi e migliorare la comparabilità tra variabili (Lee, 2020). Sui dati relativi ai campioni di pomodoro sono state applicate l'Analisi delle Componenti Principali (PCA) e l'Analisi Discriminante Lineare (LDA). In particolare, la PCA riduce la dimensionalità del dataset ma preserva tutte le informazioni relative ai dati, al fine di esplorare la distribuzione dei campioni in funzione dell'origine geografica (Ruggiero et al., 2021). La LDA costruisce una combinazione lineare delle variabili selezionate al fine di ottenere la massima separazione tra i gruppi e la massima compattezza all'interno degli stessi (Pellerano et al., 2008), assumendo che le matrici di varianza-covarianza dei diversi gruppi siano omogenee. Infine, per indagare le relazioni tra la composizione elementare dei pomodori e quella della frazione biodisponibile dei suoli, è stata effettuata un'analisi di correlazione ($p < 0,05$), consentendo di valutare l'intensità e direzione delle associazioni tra le due matrici a supporto dell'ipotesi dell'influenza delle caratteristiche geochimiche del suolo sul profilo multielementare del prodotto (Damak et al., 2021).

Risultati

Nei campioni di pomodoro sono stati determinati 23 elementi (Al, B, Ba, Ca, Cd, Co, Cr, Cs, Cu, Fe, K, Mg, Mn, Mo, Na, Nd, Ni, P, Pb, Rb, Sr, Ti, Zn). Le concentrazioni medie dei macroelementi seguono il seguente ordine decrescente: K (32.1 g/kg) > P (3,3 g/kg)




Figura 4. Score plot della PCA relativa al profilo elementare dei campioni di pomodoro (cerchi per le aziende DOP e triangoli per le aziende non DOP).

> Mg (1.5 g/kg) > Ca (0.9 g/kg) > Na (0.2 g/kg). Per quanto riguarda i microelementi, l'ordine decrescente è: Fe > Zn > Mn > B > Cu > Al > Sr > Mo > Ba > Ti > Ni > Cs > Co > Cd > Pb > Cr > Ce > La > Nd > Sb. L'analisi esplorativa mediante Analisi delle Componenti Principali (PCA), condotta su 24 campioni, ha consentito di identificare cinque componenti principali significative (autovalori >1), che spiegano complessivamente l'81% della varianza totale. In particolare, i principali contributi alle componenti principali sono risultati: su PC1 Fe, Na, Mg, e Nd; su PC2 Ca, P, Sr, K e Ti; su PC3 Cs, Rb, Mo e Ba; su PC4 Co e Cd; su PC5 Cd, Al e Ti. La distribuzione dei campioni nel grafico degli score (Fig. 4) evidenzia un raggruppamento per azienda di provenienza nel piano PC1-PC2, sebbene alcune aziende mostrino una maggiore variabilità intra-azienda (AZ-1 e AZ-4). Si osserva inoltre una chiara separazione (Fig. 4) tra le aziende con una tendenza dei campioni DOP e non DOP a collocarsi in quadranti distinti, ad eccezione di un caso (AZ-5).




Figura 5 a, b. Score plot della PCA relativa alla frazione prontamente (a) e potenzialmente (b) biodisponibile degli elementi nei campioni di suolo (cerchi per le aziende DOP e triangoli per non DOP).

Analogamente, l'analisi PCA condotta sulle frazioni biodisponibili del suolo (prontamente biodisponibili: Al, As, B, Ba, Be, Ca, Cd, Ce, Co, Cr, Cs, Cu, Fe, K, La, Li, Mg, Mn, Mo, Na, Nd, Ni, P, Pb, Rb, Sb, Se, Si, Sr, Ti, Tl, V, Zn; potenzialmente biodisponibili: Al, As, B, Ba, Be, Ca, Cd, Ce, Co, Cr, Cs, Cu, Dy, Er, Fe, Ga, Gd, Ho, K, La, Li, Lu, Mg, Mn, Mo, Na, Nd, Ni, P, Pb, Rb, Sb, Se, Si, Sm, Sr, Ti, Tl, Tm, U, V, Zn) evidenzia una chiara separazione dei campioni in funzione dell'origine geografica (Fig. 5a e 5b). I grafici degli score mostrano inoltre una distribuzione distinta tra aziende DOP e non DOP, coerente con una differenza geochemica dei suoli nonostante la relativa prossimità geografica delle aree campionate e la comune influenza dei materiali parentali di origine vulcanica.

Le relazioni tra il contenuto degli elementi nei suoli (frazioni biodisponibili) e nei pomodori, valutate mediante correlazione di Spearman, evidenziano correlazioni statisticamente significative ($p < 0.05$) per diversi elementi, sia macro che micro. Tali relazioni risultano in gran parte comuni tra frazione prontamente e potenzialmente biodisponibile, con alcune eccezioni: il bario mostra correlazione significativa solo nella frazione potenzialmente biodisponibile, mentre lo zinco solo per quella prontamente biodisponibile (Tab. 1).

L'Analisi Discriminante Lineare (LDA) applicata al profilo multielementare dei pomodori mostra una perfetta discriminazione dei campioni provenienti da aziende DOP e non DOP, con un'accuratezza di classificazione del 100% (Tab. 2). Gli elementi significativamente discriminanti risultano, in ordine decrescente $\text{Mo} > \text{Rb} > \text{P} > \text{Co} > \text{Cs} > \text{Sr} > \text{Mg}$.

Discussione

L'analisi del profilo multielementare dei campioni di pomodoro evidenzia una distribuzione delle concentrazioni dei macroelementi coerente con quanto riportato in letteratura per matrici vegetali. In particolare, il K risulta l'elemento predominante, svolgendo un ruolo fondamentale nei processi osmoregolatori, nella regolazione stomatica e nell'attività enzimatica, seguito dal P, essenziale nel metabolismo energetico (Lester et al., 2010). I risultati della PCA mostrano una chiara separazione dei campioni in funzione dell'origine geografica, indicando che il profilo multielementare può essere considerato un efficace indicatore discriminante. Gli elementi Fe, Na, Mg, Nd, Ca, P, Sr, K e Ti emergono come principali contributori alla differenziazione dei campioni. La presenza di cluster distinti per azienda suggerisce un'influenza significativa delle condizioni pedoclimatiche e delle pratiche agronomiche locali sul profilo multielementare dei pomodori. A sua volta, l'analisi PCA degli elementi delle frazioni biodisponibili del suolo evidenzia una chiara separazione tra aziende DOP e non DOP, indicando una distinta impronta geochimica dei suoli dell'areale DOP esaminato. La distribuzione dei campioni nei grafici degli score mostra una coerenza, almeno parziale, con quella osservata per i pomodori, supportando l'ipotesi dell'esistenza di una firma geochimica trasferibile dal suolo alla pianta. L'analisi di correlazione suolo-pomodoro conferma tale ipotesi, evidenziando relazioni significative per diversi elementi (Na, K, Cu, Zn, Rb, Cd, Ba), che possono essere considerati potenziali marcatori per la tracciabilità geografica. L'analisi LDA applicata ai campioni di pomodoro ha individuato un set di elementi in grado di discriminare le aziende DOP da quelle non DOP (Mo, Rb, P, Co, Cs, Sr, Mg). Tra questi il Rb emerge come particolarmente promettente, in considerazione della sua correlazione con le frazioni biodisponibili del suolo. Un ampliamento del numero di aziende campionate all'interno dell'areale DOP potrà rafforzare ulteriormente la robustezza del modello discriminante e la validità dei marcatori individuati. Nel

Tabella 1. Coefficienti di correlazione di Spearman per gli elementi che mostrano relazioni significative ($p < 0,05$) tra le quantità biodisponibili estratte dal suolo e le quantità accertate nei pomodori.

	Prontamente biodisponibili	Potenzialmente biodisponibili
Na	0,707	0,725
K	0,704	0,647
Cu	0,780	0,925
Zn	0,469	n.s.
Rb	0,645	0,681
Cd	0,472	0,429
Ba	n.s.	0,870

Tabella 2. Matrici di confusione (LDA) per il campione di stima (sopra) e per i risultati della validazione incrociata (sotto).

da \ a	PDO	non-PDO	Totale	% corr. Cal.
PDO	20	0	20	100,00%
non-PDO	0	20	20	100,00%
Totale	20	20	40	100,00%

da \ a	PDO	non-PDO	Totale	% corr. Val.
PDO	20	0	20	100,00%
non-PDO	0	20	20	100,00%
Totale	20	20	40	100,00%

complesso, i risultati ottenuti supportano l’impiego dell’analisi multielementare come strumento per l’autenticazione geografica del Pomodorino del Piennolo del Vesuvio DOP, evidenziando il ruolo chiave delle caratteristiche geochimiche del suolo nel determinare il profilo elementare del prodotto finale.

Conclusioni

La composizione multielementare, ovvero l’impronta geochimica, del Pomodorino del Piennolo del Vesuvio DOP (varietà *Acampora*), fornito da aziende ricadenti nell’areale di produzione e selezionate dal Consorzio di Tutela, è stata confrontata mediante metodi statistici con quella di pomodori della stessa varietà coltivati in aziende della medesima Regione ma esterne all’areale DOP. I risultati del confronto hanno evidenziato una buona capacità discriminante dell’impronta geochimica nel distinguere le produzioni DOP da quelle non DOP. Numerosi elementi determinati nel frutto mostrano una correlazione significativa con la frazione biodisponibile del suolo e si rivelano efficaci marcatori geografici quando analizzati mediante approcci multivariati, in particolare mediante Analisi Lineare Discriminante (LDA). Tuttavia, tali metodologie richiedono dataset ampi e rappresentativi, in grado di includere l’intera variabilità delle realtà aziendali presenti nell’areale DOP, al fine di definire una firma multielementare robusta e validata su scala territoriale. In questo contesto, l’estensione del dataset a più annate produttive e a differenti varietà rappresenta un aspetto

cruciale per valutare la variabilità stagionale e varietale dell'impronta geochemica, anche in relazione alle fluttuazioni ambientali, sia climatiche sia agronomiche. La disponibilità di una banca dati ampia e consolidata sul profilo multielementare del prodotto, di cui possa dotarsi il Consorzio di Tutela, potrebbe in prospettiva consentire la verifica dell'origine geografica e l'individuazione di eventuali frodi. Mediante l'applicazione di modelli statistici multivariati, sarebbe infatti possibile accertare attraverso la sola analisi multielementare di campioni sospetti, la loro appartenenza o meno al gruppo DOP. Il grado di affidabilità di tali accertamenti dipende direttamente dall'ampiezza e dalla qualità della base dati di riferimento. Pertanto, l'implementazione di un programma sistematico di acquisizione di dati multielementari, in sinergia con i metodi tradizionali di controllo, potrebbe fornire uno strumento oggettivo e scientificamente fondato per la tracciabilità geografica del prodotto.

Ringraziamenti

Gli autori ringraziano il progetto METROFOOD-IT per il supporto alle attività di ricerca e il Consorzio di Tutela del Pomodorino del Pienolo del Vesuvio DOP per la collaborazione e il supporto forniti nello svolgimento dello studio.

Bibliografia

- Arnalds, Ó., Bartoli, F., Buurman, P., García-Rodeja, E., Óskarsson, H., & Stoops, G. (Eds.). (2007). *Soils of volcanic regions in Europe* (p. 644). Heidelberg: Springer.
- Belletti, G., Burgassi, T., Manco, E., Marescotti, A., Pacciani, A., & Scaramuzzi, S. (2007). The roles of geographical indications (PDO and PGI) on the internationalisation process of agro-food products. In *International Marketing and International Trade of Quality Food Products* (pp. 517-540). Avenue Media (Bologna).
- Damak, F., Bougi, M. S. M., Araoka, D., Baba, K., Furuya, M., Ksibi, M., & Tamura, K. (2021). Soil geochemistry, edaphic and climatic characteristics as components of Tunisian olive terroirs: Relationship with the multielemental composition of olive oils for their geographical traceability. *Euro-Mediterranean Journal for Environmental Integration*, 6(1), 37.
- Di Gennaro, A., & Terribile, F. (1999). I suoli della provincia di Napoli: Carta 1: 75.000 e legenda.

- Lee, D. K. (2020). Data transformation: a focus on the interpretation. *Korean journal of anesthesiology*, 73(6), 503-508.
- Lester, G. E., Jifon, J. L., & Makus, D. J. (2010). Impact of potassium nutrition on food quality of fruits and vegetables: A condensed and concise review of the literature. *Better Crops*, 94(1), 18-21.
- Lu, Y., Doerr, C., & Sebilo, M. (2026). Geochemical fingerprinting and machine learning for authenticating sparkling wine origins. *npj Science of Food*.
- Pellerano, R. G., Mazza, S. S., Marigliano, R. A., & Marchevsky, E. J. (2008). Multielement analysis of Argentinean lemon juices by instrumental neutron activation analysis and their classification according to geographical origin. *Journal of Agricultural and Food Chemistry*, 56(13), 5222-5225.
- Ruggiero, L., Fontanella, M. C., Amalfitano, C., Beone, G. M., & Adamo, P. (2021). Provenance discrimination of Sorrento lemon with Protected Geographical indication (PGI) by multi-elemental fingerprinting. *Food chemistry*, 362, 130168.
- Wang, Y., Yuan, X., Liu, L., Ma, J., Fan, S., Zhang, Y., & Li, Q. (2021). Multielement Principal Component Analysis and Origin Traceability of Rice Based on ICP-MS/MS. *Journal of Food Quality*, 2021(1), 5536241.

La volatilomica per la sicurezza alimentare

Maurizio Piergiovanni¹, Chiara Giliberti¹, Cristian Maffezzoni^{1}, Davide Errico¹,
Massimo Blandino², Chiara Dall'Asta³, Monica Mattarozzi¹, Federica Bianchi¹,
Marco Giannetto¹, Maria Careri¹*

¹Dipartimento di Scienze Chimiche, della Vita e della Sostenibilità Ambientale, Università di Parma, Italia;

²Dipartimento di Scienze Agrarie, Forestali e Alimentari, Università di Torino, Italia;

³Dipartimento di Scienze dell'Alimentazione e Farmaceutiche, Università di Parma, Italia

* Corresponding author: cristian.maffezzoni@unipr.it

ABSTRACT – In questo studio si è valutato l'uso della tecnologia del naso elettronico abbinata a tecniche di Machine Learning per il riconoscimento rapido e precoce della contaminazione fungina da *Claviceps purpurea* nel grano a livelli di interesse secondo la normativa europea, a seguito della formazione di composti volatili dagli alcaloidi dell'ergot, una classe di micotossine emergenti che rappresentano un rischio per la sicurezza alimentare. Inoltre, tecniche avanzate basate sulla gascromatografia-spettrometria di massa ad alta risoluzione Orbitrap ed analisi dei big data del volatiloma di campioni di grano contaminati mediante algoritmi di Machine Learning hanno permesso di identificare specifici marcatori chimici legati alla contaminazione, offrendo nuovi strumenti per migliorare i controlli di qualità a supporto della sicurezza alimentare per la tutela del consumatore.

Keywords: Naso elettronico; HS-SPME; GC-Orbitrap HRMS; Metabolomica untarget; Analisi dei dati multivariata; Machine learning; Alcaloidi dell'ergot; Volatilomica.

Introduzione

Garantire che gli alimenti siano di qualità e sicuri è di fondamentale importanza sia per i produttori sia per i consumatori. Tra le principali minacce alla sicurezza dei prodotti alimentari vi sono le micotossine, sostanze tossiche prodotte da specie fungine che si sviluppano sulle colture agricole. Negli ultimi anni hanno destato particolare preoccupazione gli alcaloidi dell'ergot, micotossine emergenti prodotte dalla specie *Claviceps purpurea*, diffusa soprattutto in Europa. Questo microrganismo può contaminare cereali come il grano, formando sui chicchi delle strutture scure chiamate sclerozi, o "ergot" (Piergiovanni et al., 2025). Per proteggere la salute pubblica, l'Unione Europea ha stabilito limiti sulle quantità massime di alcaloidi dell'ergot (EA) nei prodotti derivati dai cereali, come farine e semole, imponendo un monitoraggio delle materie prime atto a garantire che i livelli di contaminazione restino sotto la soglia di sicurezza (Regolamento (UE 2023/915). La determinazione delle micotossine, in particolare in matrici complesse come materie prime o prodotti alimentari, viene effettuata utilizzando metodi basati principalmente su tecniche di cromatografia liquida-spettrometria di massa, che richiedono fasi laboriose di preparazione del campione, personale altamente specializzato, strumentazione costosa e tempi di analisi lunghi (Carbonell-Rozas et al., 2022). Per questo motivo, la ricerca si sta orientando verso metodi più rapidi e meno costosi. Tra le soluzioni più all'avanguardia stanno emergendo quelle offerte dalla tecnologia del "naso elettronico" (e-nose). Questa tecnologia sensoristica utilizza dispositivi "intelligenti" ispirati all'olfatto umano che, anziché analizzare direttamente le micotossine, rilevano i composti organici volatili (VOC) che si sviluppano come metaboliti secondari in seguito ad infezione fungina. Per ogni campione si viene quindi a determinare una sorta di "impronta odorosa" o "pattern olfattivo" unico, che si modifica in presenza dell'infezione da *Claviceps purpurea* o, più in generale, da specie tossinogene. Il naso elettronico si basa su array di diversi tipi di sensori chimici a gas che rispondono a caratteristiche specifiche di molecole volatili, simulando il sistema olfattivo umano, generando segnali elettronici. Questi dati vengono poi elaborati tramite algoritmi avanzati di Machine Learning (ML), come reti neurali o modelli statistici, in grado di classificare i campioni che si contraddistinguono per un definito pattern olfattivo. In questo modo, il dispositivo può distinguere rapidamente tra campioni

di cereali contaminati e non contaminati (Tan & Xu, 2020). Parallelamente, si è sviluppato anche un altro filone di ricerca molto promettente per analizzare e identificare i caratteristici marcatori molecolari prodotti a seguito di infezioni fungine: la volatilomica, branca della metabolomica che studia l'insieme dei metaboliti volatili prodotti da un organismo o da un alimento. Grazie a tecnologie avanzate come la spettrometria di massa ad alta risoluzione abbinata anche in questo caso a tecniche di Machine Learning, è possibile identificare con elevata affidabilità i "marcatori" della contaminazione fungina (Paiva et al., 2024). In questo contesto di continua evoluzione delle metodologie analitiche per la sicurezza alimentare, il presente lavoro ha l'obiettivo di valutare soluzioni innovative che permettano un monitoraggio delle micotossine più rapido, accessibile ed efficace. In particolare, lo studio si propone di verificare il potenziale del naso elettronico come tecnica di screening per distinguere campioni di frumento contaminati da quelli conformi ai limiti di legge, offrendo così un supporto concreto alle attività di controllo lungo la filiera. Un ruolo chiave è svolto dall'infrastruttura di ricerca METROFOOD-IT, all'interno della quale si colloca questo studio. METROFOOD-IT mira a rafforzare le capacità scientifiche e tecnologiche nel settore agroalimentare italiano. In questo quadro, il lavoro contribuisce allo sviluppo di strumenti analitici più sostenibili ed economicamente vantaggiosi, favorendone l'applicazione anche direttamente nei contesti produttivi.

Materiali e Metodi

I campioni analizzati, derivanti dal genotipo *Triticum aestivum* "Bologna", sono stati coltivati nel 2023 a Cigliano (TO, Italia) in un campo sperimentale seguendo pratiche agronomiche standard. L'infezione da *Claviceps purpurea* è stata indotta artificialmente in fase di fioritura. Dopo la raccolta, i chicchi sono stati liofilizzati, macinati e conservati a -80°C fino all'analisi. I campioni così ottenuti sono stati classificati sulla base della concentrazione totale di EA determinata mediante HPLC-MS/MS: 1) campioni di controllo (assenza di EA), 2) campioni con livelli inferiori e 3) superiori ai limiti normativi europei (Carbonell-Rozas et al., 2022). L'infrastruttura di METROFOOD-IT ha permesso di impiegare per l'analisi dei VOC la facility rappresentata dal naso elettronico PEN3 (Airsense Analytics GmbH), dotato di un array di 10 sensori MOS e accoppiato

a un sistema di preconcentrazione (EDU3) con adsorbente Tenax TA®. Ciascun campione è stato analizzato in triplicato utilizzando aliquote di $1,0 \pm 0,1$ g poste in vial da 20 mL, sigillate e incubate a 30°C per 24 h per consentire l'equilibrio dei VOC nello spazio di testa. La risposta dei sensori, espressa come rapporto di conducibilità (G/G_0), è stata registrata nel tempo e acquisita tramite il software dedicato WinMuster. I segnali ottenuti (sensogrammi, di cui è riportato un esempio in Fig. 1 sono stati elaborati mediante analisi statistica e Machine Learning.

L'analisi preliminare è stata condotta mediante ANOVA per verificare differenze significative tra le classi di contaminazione. Successivamente, tecniche non supervisionate come la Principal Component Analysis (PCA) sono state utilizzate per esplorare la struttura dei dati. Modelli ML supervisionati come Partial Least Squares-Discriminant Analysis (PLS-DA) e Support Vector Machines (SVM) sono stati applicati per la classificazione dei campioni. I modelli sono stati validati mediante cross-validation e test set esterno, valutando l'accuratezza di classificazione.

L'analisi volatilomica "untargeted" è stata effettuata mediante microestrazione in fase solida nello spazio di testa (HS-SPME) seguita da separazione gascromatografica (GC) accoppiata a spettrometria di massa Orbitrap HRMS. A tal scopo è stata utilizzata la facility dell'infrastruttura METROFOOD-IT Thermo Scientific™ TRACE™ 1610 Series Gas Chromatograph coupled to a Thermo Scientific™ Orbitrap™ Exploris™ GC 240 Mass Spectrometer. I campioni ($1,5 \pm 0,1$ g) sono stati incubati a 50°C e sottoposti a estrazione con fibra DVB/Carbon WR/PDMS, seguita da desorbimento nel sistema GC. La separazione




Figure 1. Sensogrammi registrati mediante e-nose rappresentativi di un campione di grano contaminato (a) “al di sopra del limite legale” e (b) “al di sotto del limite legale”.

cromatografica è stata ottenuta utilizzando la colonna Thermo Scientific™ TraceGOLD TG-5SilMS (30 m × 0.25 mm i.d., 0.25 µm) con il seguente programma di temperatura: 40°C (3 min), gradiente di 10°C/min fino a 250 °C, gradiente di 30°C/min fino a 300 °C. La rivelazione è stata effettuata mediante spettrometria di massa ad alta risoluzione in modalità EI e PCI nel range 35–350 Da per EI; 50–600 Da per PCI con una risoluzione di 60,000 FWHM a 200 *m/z*. I dati acquisiti mediante software Thermo Scientific™ Xcalibur™ v. 4.5 sono stati elaborati tramite la versione 3.3. del software Thermo Scientific™ Compound Discoverer™ per la deconvoluzione, identificazione e normalizzazione dei segnali. Infine, i dati metabolomici sono stati sottoposti a workflow statistico che ha incluso diverse fasi di pre-elaborazione tra le quali la sottrazione del background e la normalizzazione su campioni di controllo qualità (QC), seguiti da analisi PCA e PLS-DA per l'identificazione di marcatori volatili associati alla contaminazione fungina e identificazione putativa dei composti mediante libreria NIST 17.

Risultati e discussione

Nella fase di sviluppo del metodo basato sull'impiego del naso elettronico, l'ottimizzazione delle condizioni operative mediante tecniche di disegno sperimentale si è rivelata cruciale. In particolare, è emerso che la temperatura e il tempo di campionamento influenzano in modo significativo i risultati ottenuti in termini di efficienza di estrazione dei composti volatili e di sensibilità di risposta di alcuni sensori. Le condizioni ottimali, calcolate secondo un approccio di Quality by Design (Bianchi et al., 2021) sono state individuate a 30 °C con 10 minuti di campionamento. Sui dati ottenuti dal naso elettronico PEN3 è stato valutato un modello di classificazione al fine di ottenere un metodo di screening adeguato alla rivelazione precoce della contaminazione da EA per prevedere la conformità al regolamento UE 2023/915 (Regolamento (UE) 2023/915, 2023). I campioni sono stati suddivisi in due classi: i) campioni con contenuto di EA inferiore al limite normativo europeo (inclusi i campioni di controllo) e ii) campioni con concentrazioni superiori al limite di legge. L'analisi mediante PCA ha consentito di esplorare la struttura del dataset. Il modello, costituito da cinque componenti principali, ha spiegato il 94,3% della varianza totale. In particolare, è stato possibile evidenziare il contributo predominante dei

sensori R7 e R9 come i più sensibili ai VOC associati alla contaminazione fungina. Per migliorare il potere discriminante, sono stati applicati i modelli ML supervisionati PLS-DA e SVM. Il modello PLS-DA ha mostrato un’alta capacità di classificazione, distinguendo efficacemente i campioni delle due classi. Il modello presenta elevate prestazioni, sia sul training set sia sul test set indipendente, con 43 osservazioni correttamente classificate su 45 ($\approx 95,5\%$) (Table1). I parametri di valutazione (sensibilità, specificità, precisione e non-error rate) hanno evidenziato valori superiori a 0,94, confermando l’affidabilità del modello.

Il modello SVM ha fornito risultati comparabili, con una capacità di classificazione leggermente inferiore ($\approx 93,3\%$), confermando comunque la robustezza dell’approccio di Pattern Recognition adottato. Sui medesimi campioni di grano, l’analisi volatilomica condotta mediante GC-Orbitrap HRMS ad alta risoluzione ha permesso di estrarre 590 feature. Al fine di estrarre le feature significative per la classificazione è stato applicato un approccio di analisi statistica multivariata e univariata.. L’impiego della tecnica PLS-DA ha consentito di costruire un

Table 1. Matrici di confusione per i modelli di Machine Learning PLS-DA e SVM nella previsione del set di test per l’analisi mediante e-nose.

PLS-DA		
Capacità di predizione		
Categorie vere	Sotto il limite di legge	Sopra il limite di legge
Sotto il limite di legge	26	1
Sopra il limite di legge	1	17
Capacità di classificazione totale = 95.5%		
SVM		
Capacità di predizione		
Categorie vere	Sotto il limite di legge	Sopra il limite di legge
Sotto il limite di legge	24	3
Sopra il limite di legge	0	18
Capacità di classificazione totale = 93.3%		
45 osservazioni totali (5 campioni con 3 misurazioni replicate, 3 caratteristiche comprese tra 97 e 99 s per ciascun sensogramma)		




Figure 2. Score plot dell'analisi PCA basata sulle 19 feature significative identificate mediante tecnica GC-HRMS. Campioni di controllo (blu), campioni con un livello di EA inferiore al limite massimo consentito dall'UE (verde), campioni con un livello di EA superiore al limite massimo consentito dall'UE (rosso); l'asterisco identifica i campioni di controllo qualità.

modello dal quale sono stati calcolati i valori di VIP (Variable Importance in Projection), utilizzati per quantificare il contributo di ciascuna variabile alla capacità discriminante del modello. Parallelamente, è stato applicato un test ANOVA univariato per valutare la significatività statistica delle differenze tra gruppi. Sono state considerate significative quelle feature con valore $VIP > 1,5$ e $p < 0,05$ ottenendo così un dataset ridotto a 19 metaboliti significativi. Le feature selezionate sono state infine annotate mediante confronto con il database di spettri di massa NIST 17. L'applicazione combinata di PCA, il cui score plot è illustrato in Fig. 2, e metodi supervisionati sul dataset ridotto ha evidenziato una evidente separazione tra le tre classi considerate.

Conclusioni

Il presente lavoro dimostra, per la prima volta a livello di *proof-of-concept*, le potenzialità del naso elettronico quale tecnica di screening per l'individuazione della contaminazione da alcaloidi dell'ergot in campioni di frumento. Questa potenzialità può consentire di ridurre il numero di campioni da sottoporre ad analisi con tecniche più costose. I pattern dei sensogrammi hanno consentito una chiara discriminazione tra campioni

con concentrazioni di EA superiori e inferiori al limite normativo con elevate prestazioni di classificazione (accuratezza del 95,5%).

L'approccio volatilomico untargeted basato sulla tecnica GC-Orbitrap-HRMS, applicato per la prima volta su campioni di grano tenero, ha permesso di caratterizzare l'evoluzione del profilo volatile e identificare marcatori discriminanti associati alla contaminazione fungina. Per consolidare la robustezza del modello e approfondire le dinamiche del metabolismo del cereale a seguito della contaminazione saranno necessari ulteriori studi che includeranno un numero più elevato di campioni e l'ottimizzazione delle strategie di estrazione delle feature, estendendo questo approccio ad altri cereali colpiti da *Claviceps purpurea*.

Ringraziamenti

Questo studio è stato supportato dal progetto METROFOOD-IT, finanziato dall'Unione Europea-NextGenerationEU, PNRR-Missione 4 "Istruzione e ricerca" Componente 2: dalla ricerca all'impresa, Investimento 3.1: Fondo per la realizzazione di un sistema integrato di infrastrutture per la ricerca e l'innovazione—IR0000033 (D.M. (Decreto Ministeriale) Prot. n. 120 del 21 giugno 2022).

Bibliografia

- Bianchi, F., Fornari, F., Riboni, N., Spadini, C., Cabassi, C. S., Iannarelli, M., Carraro, C., Mazzeo, P.P., Bacchi, A., Orlandini, S., Furlanetto, S., Careri, M. (2021). Development of novel cocrystal-based active food packaging by a quality by design approach. *Food Chemistry*, 347, Article 129051. <https://doi.org/10.1016/j.foodchem.2021.129051>
- Carbonell-Rozas, L., Hernández-Mesa, M., Righetti, L., Monteau, F., Lara, F. J., Gámiz-Gracia, L., Bizec, B. L., Dall'Asta, C., García-Campaña, A. M., & Dervilly, G. (2022). Ion mobility-mass spectrometry to extend analytical performance in the determination of ergot alkaloids in cereal samples. *Journal of Chromatography A*, 1682, 463502. <https://doi.org/10.1016/j.chroma.2022.463502>
- Paiva, A. C., Teixeira, C. A., & Hantao, L. W. (2024). Exploring accurate mass measurements in pixel-based chemometrics: Advancing coffee classification with GC-HRMS—A proof of concept study. *Journal of Chromatography A*, 1731, 465171. <https://doi.org/10.1016/j.chroma.2024.465171>
- Piergiovanni, M., Giliberti, C., Maffezzoni, C., Errico, D., Blandino, M., Dall'Asta, C., Mattarozzi, M., Bianchi, F., Giannetto, M., & Careri, M. (2025). Electronic nose technology for the detection of ergot alkaloid in soft wheat and

identification of the relevant volatile compounds by solid phase microextraction/gas chromatography-high resolution Orbitrap-mass spectrometry coupled to chemometrics. *Food Chemistry*, 484, 144455. <https://doi.org/10.1016/j.foodchem.2025.144455>

Regolamento (UE) 2023/915, UE 915/2023 (2023).

Tan, J., & Xu, J. (2020). Applications of electronic nose (e-nose) and electronic tongue (e-tongue) in food quality-related properties determination: A review. *Artificial Intelligence in Agriculture*, 4, 104–115. <https://doi.org/10.1016/j.aiia.2020.06.003>.

Report tecnico-istituzionale piattaforma open data e infrastruttura blockchain per la tracciabilità e la fiducia nei sistemi agroalimentari

Francesco Salzano ^{1}, Remo Pareschi ¹*

¹University of Molise – Department of Biosciences and Territory – Stake Lab

* Corresponding Author: francesco.salzano@unimol.it

ABSTRACT – La piattaforma METROFOOD-IT integra componenti digitali avanzate per supportare tracciabilità, trasparenza e fiducia nei sistemi agroalimentari. Al centro dell'architettura si colloca una Piattaforma Open Data basata su un modello federato, nel quale gli asset informativi restano presso gli originatori nei rispettivi formati nativi, mentre i metadati vengono armonizzati, indicizzati e resi interrogabili attraverso uno schema strutturato dedicato al dominio agroalimentare e metrologico. A questo livello dati si affianca un'infrastruttura di notarizzazione basata su tecnologie blockchain e Distributed Ledger Technology, finalizzata a garantire integrità, provenienza e verificabilità degli asset mediante ancoraggio on-chain selettivo degli hash crittografici. L'architettura adotta principi di scalabilità, agnosticismo tecnologico e non-intrusività per l'utente, consentendo l'impiego di soluzioni diverse, quali Ethereum e IOTA Tangle, in funzione dei requisiti operativi dei casi d'uso. L'integrazione con il livello AI/ML consente inoltre di trasformare dati validati e notarizzati in conoscenza predittiva, interpretabile e azionabile. Nel complesso, la soluzione proposta definisce un modello digitale replicabile per ecosistemi informativi data-intensive e trust-sensitive nel settore agroalimentare.

Keywords: METROFOOD-IT; Open Data Platform; Blockchain; Notarizzazione digitale; Tracciabilità agroalimentare;

Introduzione

Il presente documento descrive l'architettura e le funzionalità del nucleo digitale della piattaforma METROFOOD-IT, con particolare riferimento alla **Piattaforma Open Data** e all'**infrastruttura di notarizzazione blockchain**. Il report è destinato a fornire una visione tecnico-istituzionale delle soluzioni realizzate, evidenziando le scelte progettuali, i flussi operativi e le garanzie di integrità e tracciabilità offerti dal sistema. METROFOOD-IT costituisce il nodo italiano di un'infrastruttura di ricerca europea dedicata alla metrologia nel settore alimentare e nutrizionale. Il progetto, finanziato come iniziativa pluriennale con un investimento complessivo prossimo ai 20 milioni di euro, integra componenti fisiche (laboratori, strutture sperimentali, infrastrutture di misura) e componenti digitali in un ecosistema unitario finalizzato a supportare la tracciabilità, l'autenticità, la sicurezza e la sostenibilità dei prodotti alimentari (Kshetri, 2018; Kamilaris, et al., 2019, Tian, 2016). All'interno di questo ecosistema, il nucleo IT svolge un ruolo abilitante, articolandosi su tre livelli architetturali strettamente integrati: un livello dati (Open Data Platform), un livello di fiducia (notarizzazione blockchain) e un livello di intelligenza (AI/ML). Il presente report si concentra sui primi due livelli, delineando al contempo le modalità di integrazione con il terzo.

Piattaforma Open Data

La Piattaforma Open Data costituisce il livello fondante dell'architettura METROFOOD-IT. La sua funzione primaria è consentire l'acquisizione, la descrizione strutturata, la scoperta e la condivisione controllata di asset informativi eterogenei nel dominio agroalimentare, coinvolgendo una pluralità di stakeholder: laboratori scientifici, aziende produttrici, enti di certificazione, agenzie di monitoraggio e istituzioni governative, garantendo i principi FAIR (Wilkinson et al., 2016).

Principio architetturale: dati federati, metadati centralizzati

La scelta progettuale fondante della piattaforma è la separazione rigorosa tra la gestione dei dati e quella dei metadati. Gli asset informativi—siano essi report di analisi di laboratorio, misurazioni spettrali, log di sensori, documenti di certificazione—sono mantenuti localmente dai rispettivi originatori, nei formati nativi di ciascun stakeholder (file Excel/

CSV, archivi di immagini, output strumentali proprietari, documenti di certificazione). Nessuna conversione di formato, migrazione di schema o trasformazione strutturale viene imposta al momento dell’acquisizione. Ciò che viene centralizzato è il livello dei metadati. Al momento del caricamento, l’originatore dei dati compila un insieme strutturato di campi descrittivi tramite un’interfaccia dedicata. Questi campi sono basati su un vocabolario ontologico specifico del progetto, progettato per catturare gli attributi descrittivi, di provenienza e di dominio rilevanti per la metrologia alimentare. La scelta di sviluppare un vocabolario specifico, anziché adottare standard generali come Dublin Core (Kunze & Baker, 2007) o DCAT-AP (World Wide Web Consortium, 2024), riflette la natura specialistica del dominio metrologico: i concetti biochimici, analitici e di certificazione centrali per la metrologia alimentare non sono adeguatamente coperti dalle ontologie generali esistenti. I record di metadati risultanti sono indicizzati centralmente e costituiscono il meccanismo primario di scoperta della piattaforma. Gli utenti che cercano dati formulano query sui campi dei metadati e ricevono come risultato riferimenti ai contenitori dati originali, in qualunque formato l’originatore li abbia definiti. Questo design garantisce la scalabilità attraverso confini organizzativi e disciplinari, poiché l’unico impegno condiviso richiesto ai fornitori di dati è il vocabolario dei metadati, non il formato dei dati.

Stack tecnologico

La piattaforma è costruita su uno stack tecnologico document-oriented, i cui componenti principali sono listati in Tab. 1:

Table 1: Stack tecnologici

Componente	Tecnologia	Funzione
Database	MongoDB	Archiviazione dati e metadati in formato documentale (JSON/BSON)
Back end	Flask (Python)	API RESTful per ingestione, ricerca, download e gestione utenti
Front end	Angular	Portale web per l’interazione utente
Autenticazione	JWT (PyJWT / flask_jwt_extended)	Gestione sessioni e controllo degli accessi
Validazione	jsonschema	Validazione dei metadati contro lo schema JSON di riferimento
Containerizzazione	Docker / docker-compose	Deployment riproducibile e scalabilità

La scelta di MongoDB riflette l’eterogeneità intrinseca dell’ecosistema dati: gli asset agroalimentari variano ampiamente per formato e struttura interna. Un database document-oriented consente di gestire tale diversità senza richiedere normalizzazione dello schema. Il livello API REST espone i servizi della piattaforma sia per gli utenti umani attraverso il portale Angular, sia per pipeline automatizzate all’interno dell’infrastruttura METROFOOD-IT. Una caratteristica architettuale rilevante è la separazione netta tra la piattaforma Open Data e il livello di notarizzazione blockchain a livello implementativo: il back end gestisce archiviazione dati, metadati e calcolo degli hash, ma non incorpora un client blockchain. L’ancoraggio on-chain è delegato a un servizio distinto, garantendo che il livello di fiducia possa evolvere indipendentemente—ad esempio, passando da una tecnologia blockchain a un’altra—senza richiedere modifiche all’infrastruttura di gestione dati.

Modello dei metadati

Ogni asset informativo nella piattaforma è descritto da un record di metadati conforme a uno JSON Schema che organizza i campi in quattro gruppi funzionali, come mostrato in Tab. 2:

Table 2: Metadati gestiti e relative finalità.

Gruppo funzionale	Campi principali	Finalità
Identificazione e descrizione	file_id, file_name, file_format, category, description, tags	Scoperta e classificazione degli asset
Provenienza e versionamento	user_id, upload_date, version	Tracciabilità temporale e supporto all’evoluzione dei dataset
Governance	visibility (private public)	Controllo dell’accesso da parte dell’originatore
Integrità e collegamento analitico	hash (SHA-256), jupyter_tools, jupyter_folder	Impronta univoca per notarizzazione; collegamento con ambienti di analisi (Jupyter, MATLAB, Python)

L’inclusione dei metadati relativi agli ambienti analitici (jupyter_tools, jupyter_folder) all’interno dello schema dati rappresenta una scelta progettuale significativa: la piattaforma Open Data non è un semplice repository passivo, ma è consapevole del contesto computazionale

in cui gli asset sono prodotti e consumati, abilitando un'integrazione più stretta con il livello AI/ML dell'architettura.

Modello di accesso e governance dei dati

La piattaforma implementa un modello di accesso duale che distingue tra interazioni pubbliche e autenticate.

Accesso pubblico

Gli utenti non autenticati possono cercare asset informativi, visualizzarne i metadati associati e scaricare i file la cui visibilità sia stata impostata come pubblica dall'originatore. Questa modalità supporta il mandato di scienza aperta della piattaforma, consentendo la scoperta e il riutilizzo di dataset condivisi pubblicamente senza richiedere registrazione o affiliazione istituzionale.

Accesso autenticato

Gli utenti registrati, autenticandosi tramite il sistema di login della piattaforma (basato su JWT), accedono a funzionalità aggiuntive: caricamento di asset con metadati associati, gestione della visibilità dei propri file (pubblica o privata) e accesso alla propria area riservata. Il controllo della visibilità è esercitato esclusivamente dall'originatore dei dati: la decisione se un asset sia pubblicamente scopribile o limitato allo spazio privato è presa al momento del caricamento e può essere modificata successivamente solo dall'originatore. Questo modello di governance preserva la sovranità sui dati degli stakeholder contribuenti, consentendo al contempo un'apertura selettiva.

Flussi operativi

Archiviazione

Un utente registrato carica un file e, nella stessa operazione, compila i metadati associati tramite un modulo strutturato, i cui campi sono tratti dal vocabolario ontologico della piattaforma. Il file e il suo record di metadati sono archiviati come unità accoppiata, ma gestiti in modo distinto: il file è preservato nel formato originale, mentre il record di metadati è indicizzato per la scoperta. Al momento dell'archiviazione, un hash crittografico (SHA-256) viene calcolato sul contenuto del file, generando un'impronta digitale univoca per ciascun

asset. Questa impronta svolge una duplice funzione: internamente alla piattaforma, fornisce un identificatore a prova di manomissione; attraverso i livelli architetturali, costituisce il punto di ancoraggio per il processo di notarizzazione sulla blockchain descritto nella sezione successiva.

Ricerca e recupero

Gli utenti—autenticati o meno, nel rispetto dei vincoli di visibilità—cercano dati selezionando campi di metadati, specificando valori di filtro e, opzionalmente, delimitando la ricerca ad asset pubblici o privati. I risultati sono presentati come un elenco di asset corrispondenti, ciascuno accompagnato dai propri metadati e dalla propria impronta crittografica univoca. L'utente può quindi scaricare il file originale nel formato definito dall'originatore. Il meccanismo di ricerca si basa interamente sui metadati: gli utenti non devono conoscere preventivamente il formato interno degli asset, e la piattaforma gestisce una varietà aperta di formati di file senza richiedere indicizzazione o parsing specifici per formato.

Infrastruttura di Notarizzazione Blockchain

Il secondo livello architetturale del nucleo IT di METROFOOD-IT è costituito dall'infrastruttura di notarizzazione basata su tecnologie blockchain e Distributed Ledger (DLT) (Christidis & Devetsikiotis, 2016; Casino et al., 2019). La sua funzione è garantire l'integrità, la provenienza e la verificabilità degli asset informativi gestiti dalla piattaforma Open Data, trasformando il sistema da un semplice repository in un'infrastruttura di fiducia verificabile (Galvez et al., 2018).

Principio: ancoraggio on-chain selettivo

L'integrazione di tecnologie blockchain in sistemi data-intensive è spesso vincolata dalla tensione tra l'esigenza di tracciabilità completa e i limiti pratici dell'archiviazione on-chain, in termini di throughput, costo e latenza. L'architettura METROFOOD-IT risolve questa tensione attraverso il principio dell'ancoraggio on-chain selettivo: solo gli hash crittografici di asset selezionati vengono registrati sul registro distribuito, mentre i dataset completi restano off-chain all'interno dei

repository della piattaforma Open Data. Questo design ibrido preserva le garanzie fondamentali della tecnologia blockchain—immutabilità, verificabilità e attestazione decentralizzata—senza imporre le penalità di scalabilità legate all’archiviazione di dati voluminosi o ad alta frequenza on-chain. La selezione degli asset da ancorare costituisce, essa stessa, una decisione di policy configurabile, consentendo al sistema di adattarsi a diversi requisiti regolamentari e operativi.

Flusso di notarizzazione

Il processo di notarizzazione si articola nelle seguenti fasi:

1. Generazione dell’hash. Al momento dell’archiviazione di un asset sulla piattaforma Open Data, viene calcolato un hash SHA-256 del contenuto del file. Questo hash è memorizzato come campo del record di metadati e costituisce l’impronta univoca dell’asset.
2. Ancoraggio on-chain. L’hash, insieme ai metadati identificativi essenziali, viene trasmesso al servizio di notarizzazione blockchain, che lo registra su un registro distribuito pubblico. La registrazione crea un’attestazione immutabile dell’esistenza e dell’integrità del dato in un determinato istante temporale.
3. Verifica. Qualsiasi stakeholder può successivamente verificare l’integrità di un asset ricalcolando il suo hash e confrontandolo con quello registrato on-chain. Una corrispondenza positiva certifica che il dato non è stato alterato dal momento della notarizzazione.

Agnosticismo tecnologico e flessibilità

Come evidenziato nella descrizione dello stack tecnologico della piattaforma Open Data (Sezione 2.2), il back end della piattaforma non incorpora un client blockchain: il calcolo dell’hash avviene internamente, ma l’ancoraggio on-chain è delegato a un servizio esterno. Questa separazione architetturale rende il sistema agnostico rispetto alla tecnologia DLT impiegata, consentendo la scelta della soluzione più adatta al contesto operativo. Nell’ambito di METROFOOD-IT, due tecnologie DLT sono state sperimentate per scenari complementari, i cui aspetti sono descritti in Tab. 3:

Table 3: Scenari di impiego delle tecnologie per la gestione degli hash.

Tecnologia	Architettura	Scenario di impiego	Vantaggi
Ethereum [10]	Blockchain tradizionale (catena di blocchi, consenso PoS)	Notarizzazione di risultati di laboratorio e documenti di certificazione	Maturità dell’ecosistema, ampia adozione, robustezza delle garanzie di sicurezza
IOTA Tangle [11]	DAG (Directed Acyclic Graph), feeless	Ancoraggio di dati IoT ad alta frequenza (monitoraggio ambientale e agronomico)	Assenza di commissioni per transazione, alta scalabilità per flussi IoT, bassa latenza

La coesistenza di queste due tecnologie all’interno della stessa architettura non è una contraddizione, ma una conseguenza diretta del principio di agnosticismo tecnologico: la scelta del registro distribuito è determinata dai requisiti dello specifico caso d’uso (frequenza dei dati, costo per transazione, latenza accettabile), non da vincoli architetturali rigidi.

Principio di non-intrusività per l’utente

Un rischio critico per i sistemi abilitati da blockchain è l’imposizione di complessità aggiuntiva sul flusso di lavoro degli utenti finali. Se la notarizzazione richiede competenze specialistiche o passaggi procedurali aggiuntivi, l’adozione resterà limitata agli utenti tecnicamente sofisticati. L’architettura METROFOOD-IT affronta questo rischio attraverso un principio di non-intrusività: il livello di notarizzazione blockchain è presentato all’utente come un’opzione semplice e trasparente all’interno dell’interfaccia standard della piattaforma. Un utente che desidera notarizzare un asset lo fa attraverso un singolo elemento di interazione (ad esempio, un pulsante nel flusso di caricamento o gestione), senza dover comprendere i meccanismi crittografici o di registro distribuito sottostanti. La decisione se notarizzare, e quali asset notarizzare, resta interamente a discrezione dell’utente. Questo design trasforma la blockchain da un’imposizione infrastrutturale in un servizio che gli utenti possono invocare in modo trasparente e selettivo.

Integrazione con il Livello di Intelligenza Artificiale

Sebbene il presente report si concentri sui livelli dati e fiducia dell’architettura METROFOOD-IT, è essenziale delineare come questi

si integrino con il terzo livello architetturale: il livello di intelligenza (AI/ML), che trasforma i dati validati e notarizzati in conoscenza predittiva, interpretabile e azionabile.

Flusso integrato dati-fiducia-intelligenza

L'integrazione dei tre livelli realizza una pipeline end-to-end in cui:

- La Piattaforma Open Data garantisce che i dati siano accessibili, interoperabili e riutilizzabili, e che il loro contesto analitico sia tracciabile (attraverso i campi `jupyter_tools` e `jupyter_folder` dello schema metadati).
- Il livello blockchain certifica l'integrità e la provenienza dei dati utilizzati come input dei modelli, rendendo la pipeline AI non solo predittiva, ma anche verificabile.
- Il livello AI/ML applica modelli di apprendimento automatico (Random Forest, SVM, reti neurali) sui dati validati, generando output predittivi e classificatori accompagnati da artefatti di spiegabilità (ad esempio, analisi SHAP) che rendono trasparente il ragionamento del modello (Lundberg & Lee, 2017).

Scenari applicativi

Due scenari complementari illustrano la flessibilità dell'architettura integrata:

- Valutazione dello stato azotato delle colture. Dati iperspettrali acquisiti da sensori di campo, gestiti dalla piattaforma Open Data e notarizzati via blockchain, alimentano modelli di machine learning per la classificazione dello stato azotato. Tecniche SHAP identificano le regioni spettrali determinanti per le predizioni, garantendo trasparenza verso agronomi, certificatori e regolatori.
- Monitoraggio IoT per l'agricoltura sostenibile. Sensori IoT monitorano in tempo reale parametri ambientali e agronomici (umidità del suolo, temperatura, nutrienti). I dati sono ancorati al Tangle di IOTA per la tracciabilità e archiviati per l'analisi. Il sistema supporta strategie di irrigazione intelligente, con prospettive di integrazione di modelli predittivi per l'ottimizzazione adattiva delle risorse.

Principi Progettuali Riassuntivi

L’architettura descritta nelle sezioni precedenti incarna un insieme di principi progettuali che, pur essendo istanziati nel contesto di METROFOOD-IT, sono generalizzabili a qualsiasi ecosistema informativo data-intensive e trust-sensitive che coinvolga molteplici stakeholder eterogenei. Tali principi sono riportati in Tab. 4.

Table 4: Principi progettuali riassuntivi.

Principio	Descrizione	Beneficio
Dati federati, meta-dati centralizzati	I dati restano locali nel formato dell’originatore; i metadati sono armonizzati e centralizzati	Scalabilità organizzativa, minime barriere di adozione
Ancoraggio on-chain selettivo	Solo hash crittografici vanno on-chain; i dati completi restano off-chain	Garanzie di fiducia senza penalità di scalabilità
Non-intrusività del livello di fiducia	La notarizzazione è un’opzione semplice nell’interfaccia, a discrezione dell’utente	Adozione diffusa, complessità assorbita dalla piattaforma
Spiegabilità come requisito architetturale	Tecniche come SHAP sono integrate strutturalmente nel livello AI, non aggiunte a posteriori	Trasparenza e fiducia per stakeholder regolamentari
ML come motore decisionale	Il livello AI non è solo analitico ma mira a chiudere il ciclo dati-decisione	Supporto operativo diretto per interventi agronomici e industriali

Conclusioni

Il presente manoscritto ha descritto l’architettura e i flussi operativi della Piattaforma Open Data e dell’infrastruttura di notarizzazione basata sulla blockchain di METROFOOD-IT. Le soluzioni realizzate dimostrano come un’infrastruttura di ricerca possa evolvere in una piattaforma digitale integrata che abilita la trasparenza, la verificabilità e la scalabilità nei sistemi agroalimentari. Le scelte progettuali chiave—la federazione dei dati con centralizzazione dei metadati, l’anco-

raggio on-chain selettivo, la non-intrusività per l'utente—definiscono un modello architetturale coerente la cui applicabilità si estende oltre il dominio agroalimentare, verso qualsiasi ecosistema informativo che richieda la coesistenza di eterogeneità dei dati, requisiti di fiducia e supporto decisionale intelligente. Le traiettorie di sviluppo futuro includono l'estensione del livello di AI/ML con analisi prescrittive e paradigmi di learning federato, l'integrazione di smart contract per l'esecuzione automatizzata di interventi agricoli e l'allineamento progressivo con i principi FAIR e con le infrastrutture europee di condivisione dei dati scientifici.

Bibliografia

- Buterin, V. (2014). Ethereum: A next-generation smart contract and decentralized application platform. White paper.
- Casino, F., Dasaklis, T. K., & Patsakis, C. (2019). A systematic literature review of blockchain-based applications: Current status, classification and open issues. *Telematics and informatics*, 36, 55-81.
- Christidis, K., & Devetsikiotis, M. (2016). Blockchains and Smart Contracts for The Internet of Things. *IEEE access*, 4, 2292-2303.
- Galvez, J. F., Mejuto, J. C., & Simal-Gandara, J. (2018). Future challenges on the use of blockchain for food traceability analysis. *TrAC Trends in Analytical Chemistry*, 107, 222-232.
- Kamilaris, A., Fonts, A., & Prenafeta-Boldú, F. X. (2019). The rise of blockchain technology in agriculture and food supply chains. *Trends in food science & technology*, 91, 640-652.
- Kshetri, N. (2018). 1 Blockchain's roles in meeting key supply chain management objectives. *International Journal of information management*, 39, 80-89.
- Kunze, J., & Baker, T. (2007). The Dublin Core metadata element set (RFC 5013). RFC Editor.
- Lundberg, S. M., & Lee, S. I. (2017). A unified approach to interpreting model predictions. *Advances in neural information processing systems*, 30.
- Popov, S. (2018). The Tangle: Version 1.4.3. IOTA Foundation.
- Tian, F. (2016, June). An agri-food supply chain traceability system for China based on RFID & blockchain technology. In *2016 13th International Conference on Service Systems and Service Management (ICSSSM)* (pp. 1-6). IEEE.
- Wilkinson, M. D., Dumontier, M., Aalbersberg, I. J., Appleton, G., Axton, M., Baak, A., ... & Mons, B. (2016). The FAIR Guiding Principles for scientific data management and stewardship. *Scientific data*, 3, 160018.
- World Wide Web Consortium (2024). Data Catalog Vocabulary (DCAT) - Version 3. W3C Recommendation.

Percorrendo la strada del cibo: nuovi modelli di coltivazione, trasformazione e confezionamento per una filiera sostenibile

Cristiana Tozzi¹, Sara Parri^{2,}, Jessica Costa^{3,4}, Marco Romi², Giampiero Cai², Patrizia Marti^{1,5}, Rebecca Pogni^{3,4}, Angelo Riccaboni^{1,6}*

¹ Santa Chiara Lab, University of Siena, Italia

² Dipartimento di Scienze della Vita, Università di Siena, Italia

³ Dipartimento di Biotecnologie, Chimica e Farmacia, Università di Siena, Italia

⁴ Consorzio Interuniversitario per lo sviluppo dei Sistemi a Grande Interfase, Università di Firenze, Sesto Fiorentino (FI), Italia

⁵ Dipartimento di Scienze Sociali, Politiche e Cognitive, Università di Siena, Italia

⁶ Dipartimento di Studi Aziendali e Giuridici, Università di Siena, Italia

*Corresponding Author: sara.parri2@unisi.it

ABSTRACT – Può la tecnologia riscrivere il futuro della nostra alimentazione, conciliando produttività e salute in un'unica filiera circolare? Il Santa Chiara Living Lab dell'Università di Siena risponde a questa sfida attraverso l'integrazione di competenze interdisciplinari che coprono l'intero ciclo vitale del cibo. Il percorso parte dal Farming Lab, dove vengono studiati nuovi protocolli di crescita delle piante per ottimizzare lo sviluppo delle colture e potenziarne le proprietà nutritive. Prosegue nel Kitchen Lab, hub di fabbricazione digitale che impiega la stampa 3D alimentare per trasformare sottoprodotti industriali in alimenti funzionali e personalizzati. Infine, il Packaging Lab chiude il ciclo sviluppando materiali *biobased* e compostabili, derivati da scarti come chitosano e lignina, per estendere la *shelf life* dei prodotti. Questo ecosistema, culminante nella visione olistica del percorso FUSTO, propone un modello di innovazione aperta capace di trasformare il dato ambientale in risorsa e lo scarto in valore, garantendo la resilienza del sistema agroalimentare contemporaneo.

Keywords: Vertical Farming, Nutraceutica, Food design, Stampa 3D, Packaging Bio-based.

Introduzione

Il Santa Chiara Living Lab, luogo di incontro di competenze complementari

All'interno dell'ecosistema METROFOOD-IT, il Santa Chiara Lab dell'Università di Siena ha agito come un vero e proprio hub di integrazione, affermandosi punto di incontro tra ricercatori, produttori e consumatori del mondo agroalimentare. Con l'obiettivo di offrire soluzioni tecnologiche derivanti dalla ricerca alle necessità emerse dal confronto tra i portatori di interesse, è nato il Living Lab, definito dall'ENoLL (European Network of Living Labs) un sistema di innovazione aperta e sostenibile incentrato sull'utente, radicato in un preciso territorio, che segue un approccio basato sulle attività fondamentali di co-creazione, esplorazione, sperimentazione e valutazione. Implementati grazie al progetto METROFOOD-IT, Farming Lab, Kitchen Lab e Packaging Lab costituiscono il core dei laboratori specializzati del Santa Chiara Living Lab. Lo studio della produzione di materie prime vegetali, la loro trasformazione e validazione culinaria e la prototipazione di nuovi materiali per il confezionamento di alimenti sono le tematiche centrali sulle quali si articola l'infrastruttura che non rimangono fasi isolate: grazie a un approccio interdisciplinare, l'infrastruttura genera strumenti per la progettazione, la valutazione e la sostenibilità a lungo termine del complesso sistema agroalimentare.

Resistenza e qualità: il Farming Lab e gli obiettivi dell'agricoltura del domani

Il Farming Lab è un "ambiente intelligente" in cui coltivare e studiare le piante. Grazie a diversi sistemi di crescita e molteplici sensori, è possibile controllare le condizioni di crescita e riprodurre sia situazioni ottimali sia condizioni anomale che mimano la coltivazione di piante in contesti estremi o non convenzionali. Il Farming Lab è uno spazio in cui immaginare l'agricoltura del futuro: più controllata, più efficiente e in grado di affrontare sfide quali la scarsità di risorse, il cambiamento climatico e la necessità di produrre in ambienti diversi da quelli tradizionali. Accanto allo studio della tolleranza delle colture agli stress, all'interno del Farming Lab vengono studiati e applicati protocolli di crescita volti a incentivare l'accumulo nelle piante di composti bioattivi utili per

migliorarne il valore nutraceutico. L'infrastruttura è dotata di due sistemi *soiless*, il sistema aeroponico (Fig. 1A), dove le radici vengono vaporizzate a intervalli regolari con la soluzione nutritiva e idroponico (Fig. 1B), dove le radici crescono immerse nella soluzione nutritiva e due stazioni Microcosmo (Fig. 1C), simulatori di campo che prevedono la crescita in suolo. Questi sistemi sono a circuito chiuso, prevedono infatti il ricircolo di acqua e nutrienti non assorbiti dalle radici, permettendo di minimizzare l'impiego di risorse esterne e di contenere i costi di coltivazione. La tecnologia presente si integra con altra strumentazione che consente non solo la coltivazione, ma anche l'analisi, il controllo, la tracciabilità e lo studio delle componenti biologiche delle piante. Il Farming Lab è quindi un laboratorio che integra agronomia, biologia, sostenibilità e innovazione tecnologica, e rappresenta la fase iniziale della filiera, in cui si sperimentano nuovi metodi di produzione.




Figura 1. (A) Portainnesti di vite in aeroponica; (B) varietà antiche di ortaggi a foglia in idroponica; (C) Piante di basilico in Microcosmo.

La ricerca al Farming Lab: incremento del potenziale di crescita e del contenuto nutraceutico delle lattughe

É possibile incrementare la qualità nutraceutica delle colture mediante la modulazione di specifici parametri ambientali? Quali condizioni di crescita permettono l'accumulo di biomassa, centrale in ambito produttivo, e incentivano nella pianta la sintesi di molecole bioattive utili per l'alimentazione umana? Per rispondere a queste domande, al Farming Lab è stato testato l'effetto di diverse intensità di luce blu e la presenza di far-red sulla crescita e l'accumulo di molecole antiossidanti di quattro varietà di ortaggi a foglia conservate nella Banca Regionale toscana del Germoplasma: Cicoria del Marzocco (*Chicorium intybus*), Radicchia di Lucca (*Chicorium endivia*), Foglia di Cerro (*Lactuca sativa*) e Rossina di Pescia (*Lactuca sativa*) (Anichini et al., 2025). Le piante,

cresciute in sistema aeroponico, sono state sottoposte a diversi spettri luminosi LED variando il rapporto tra luce rossa e blu (87:13, 75:25, 60:40) in presenza e in assenza di far-red. Sono stati misurati parametri morfologici, fisiologici e biochimici. Alla base dello studio vi è l'idea che la luce non serva soltanto alla fotosintesi, ma possa essere utilizzata come strumento per modulare la fisiologia e la produzione di composti antiossidanti (Carotti et al., 2021; Zou et al., 2023; Paglialunga et al., 2024). I risultati hanno chiaramente mostrato che la risposta alla luce è fortemente dipendente dal genotipo. Dal punto di vista morfologico, Cicoria del Marzocco e Radicchia di Lucca si sono mostrate meno sensibili delle lattughe (Rossina di Pescia e Foglia di Cerro), sulle quali la presenza di far-red favorisce l'accumulo di biomassa e l'espansione fogliare, mentre un'elevata percentuale di luce blu tende a ridurre il peso fresco, il peso secco e l'area fogliare. Sul piano fisiologico, l'aumento della percentuale di luce blu è associato a una maggiore conduttanza stomatica e a un miglioramento dei parametri fotosintetici. Tuttavia, questi vantaggi fisiologici non si traducono necessariamente in una crescita maggiore; al contrario, il lavoro evidenzia un vero e proprio *trade-off* tra produttività e accumulo di metaboliti secondari. Le condizioni ottimali per aumentare la biomassa, infatti, non sono necessariamente le stesse che massimizzano il valore nutrizionale o antiossidante delle foglie: elevate percentuali di luce blu tendono ad aumentare il contenuto di polifenoli e flavonoidi, confermando il suo ruolo di fattore che stimola il metabolismo secondario. Tuttavia, l'effetto del far-red non è uniforme: se nelle due specie di *Cichorium* e in Foglia di Cerro, l'aggiunta di far-red potenzia la capacità antiossidante, questo non avviene in Rossina di Pescia. Questo aspetto è fondamentale, in quanto suggerisce che nei sistemi di coltivazione controllata la luce possa essere modulata per orientare la produzione verso obiettivi diversi, come una maggiore resa o una maggiore concentrazione di concentrazione di composti salutari, e che non sia conveniente adottare una strategia luminosa unica per tutte le colture, ma sia invece più efficace sviluppare protocolli di illuminazione personalizzati per ciascun gruppo varietale. L'elevata ricchezza nutraceutica delle varietà locali dimostra infine come la biodiversità coltivata non sia un residuo del passato, ma una risorsa per costruire sistemi agricoli più resilienti, sostenibili e in grado di garantire alimenti di alta qualità.

Il Kitchen Lab: un'infrastruttura transdisciplinare per l'innovazione alimentare sostenibile e personalizzata

Il Kitchen Lab rappresenta un modello emergente di infrastruttura transdisciplinare per l'innovazione alimentare, in cui pratiche culinarie, metodologie di design e tecnologie digitali convergono per ridefinire il modo in cui il cibo viene concepito, prodotto ed esperito. Il Kitchen Lab è concepito come una “cucina-laboratorio” che combina le potenzialità di una cucina professionale con strumenti di fabbricazione digitale. Questa integrazione consente il passaggio da pratiche culinarie tradizionali a processi di prototipazione sperimentale, in cui il cibo può essere modellato digitalmente, ingegnerizzato a livello materiale e iterativamente perfezionato. Tecnologie come la stampa 3D alimentare (ad esempio Foodini), i sistemi di scansione tridimensionale e i software di modellazione 2D e 3D permettono di intervenire su diversi livelli – dalla composizione degli ingredienti alla geometria e alla texture – ampliando così lo spazio progettuale della produzione alimentare. All'interno di questo quadro, il Kitchen Lab supporta lo sviluppo di soluzioni alimentari personalizzate, adattate a specifiche esigenze nutrizionali, sensoriali e culturali. Ciò include alimenti progettati per individui con bisogni dietetici particolari, così come prodotti finalizzati a promuovere comportamenti alimentari più sani attraverso il design estetico ed esperienziale. La possibilità di controllare sia la composizione nutrizionale sia le caratteristiche formali del cibo – come forma, consistenza e attrattività visiva – colloca il laboratorio all'avanguardia nel campo della nutrizione personalizzata e del design alimentare inclusivo. Un elemento altrettanto rilevante è l'attenzione alla sostenibilità, in particolare attraverso la valorizzazione dei sottoprodotti alimentari e l'esplorazione delle filiere locali. Integrando sperimentazione tecnica, trasferimento tecnologico e *public engagement*, il laboratorio trasforma l'atto della prototipazione in uno strumento conoscitivo per affrontare le sfide della sostenibilità e dell'inclusività nei sistemi alimentari contemporanei.

La ricerca al Kitchen Lab

Il potenziale innovativo del Kitchen Lab si concretizza in alcune linee di ricerca principali, che affrontano temi quali la sostenibilità, il design data-driven e la trasformazione biotecnologica del cibo.

Pasta stampata in 3D per la valorizzazione dei sottoprodotti alimentari

La prima linea di ricerca riguarda lo sviluppo di pasta arricchita attraverso la valorizzazione dei sottoprodotti alimentari, in particolare le bucce di pomodoro. Questo lavoro affronta le problematiche ambientali ed economiche legate allo spreco alimentare, trasformando materiali di scarto in ingredienti nutrizionalmente preziosi. Infatti, la lavorazione del pomodoro genera ingenti quantità di scarti – oltre 200.000 tonnellate annue in Europa – che tuttavia risultano ricchi di composti bioattivi come i polifenoli (Marti et al., 2025). La ricerca integra sistemi di coltivazione controllata (idroponica e aeroponica) con tecnologie di trasformazione e stampa 3D per produrre pasta arricchita (Fig. 2A). Il processo prevede l'essiccazione e la polverizzazione delle bucce, la loro integrazione nell'impasto e la fabbricazione mediante stampa additiva. I risultati mostrano che le proprietà antiossidanti vengono in larga parte mantenute lungo l'intero processo, anche dopo la cottura (Marti et al., 2025). Questa linea di ricerca dimostra come l'innovazione tecnologica possa sostenere modelli di economia circolare, trasformando gli scarti in alimenti funzionali ad alto valore.

Dati edibili: rappresentazione multisensoriale dei dati ambientali

La seconda linea di ricerca esplora il concetto di *edible data*, in cui il cibo diventa un mezzo per rappresentare informazioni ambientali attraverso esperienze multisensoriali. In questo approccio, il design parametrico e la stampa 3D alimentare sono utilizzati per codificare dati – come emissioni di gas serra, consumo idrico e uso del suolo – nelle proprietà fisiche e sensoriali del cibo. Ad esempio, dessert al cioccolato al latte vengono progettati con forme, texture e colori che riflettono l'impatto ambientale di diversi tipi di latte utilizzati nella lavorazione del dessert (Fig. 2B). Queste rappresentazioni visive sono ulteriormente arricchite da elementi gustativi, olfattivi e sonori, creando un'esperienza immersiva che favorisce il coinvolgimento cognitivo ed emotivo. I risultati sperimentali indicano che tali approcci possono aumentare la consapevolezza e stimolare una riflessione critica sui temi della sostenibilità. Questa ricerca posiziona il cibo come interfaccia interattiva per la comunicazione dei dati, ampliando il campo della data *physicalization* verso dimensioni sensoriali ed esperienziali.



Figura 2. (A) Pasta prodotta con stampante 3D arricchita con bucce di pomodoro; (B) dessert al cioccolato al latte con forme e texture che riprendono l'impatto ambientale del latte contenuto; (C) tempeh di ceci e fagioli neri.

Tempeh: la fermentazione come processo biotecnologico progettuale

La terza linea di ricerca indaga la fermentazione come piattaforma per la produzione di alimenti sostenibili e nutrizionalmente avanzati, con particolare attenzione al tempeh di ceci e di fagioli neri (Fig. 2C). In questo contesto, la fermentazione viene reinterpretata come un processo biotecnologico progettuale, controllabile e ottimizzabile. Attraverso protocolli di fermentazione controllata, la ricerca dimostra come i processi microbici possano migliorare la qualità proteica, aumentarne la biodisponibilità e generare composti funzionali benefici per la salute. Al contempo, il tempeh si configura come una fonte proteica a basso impatto ambientale, coerente con la transizione verso diete più sostenibili. La ricerca esplora inoltre l'integrazione del tempeh nella cucina mediterranea attraverso pratiche di co-creazione, evidenziando come l'innovazione alimentare possa connettere sviluppo tecnologico e tradizione culturale.

Il Packaging Lab: sviluppo, caratterizzazione e scale-up di materiali sostenibili

Il Packaging Lab nasce con l'obiettivo di sviluppare soluzioni innovative per la valorizzazione degli scarti, trasformandoli in nuove risorse ad alto valore aggiunto, in linea con i principi dell'economia circolare. In questo contesto, l'attenzione è rivolta in particolare alla progettazione e realizzazione di materiali *biobased* e *home compostable*, in grado di ridurre l'impatto ambientale rispetto ai materiali plastici convenzionali e di contribuire a sistemi produttivi più sostenibili. Uno degli aspetti più critici in questo ambito è rappresentato dallo *scale-up* dei processi, ovvero il passaggio dalla scala di laboratorio alla scala in-

dustriale. Questo processo non è banale, poiché le proprietà dei materiali possono variare significativamente in funzione delle tecnologie di trasformazione impiegate. Ad esempio, tecniche come l'estrusione comportano modifiche strutturali e reologiche del materiale, influenzandone le prestazioni finali. Inoltre, i processi industriali richiedono generalmente grandi quantità di materia prima per la produzione di prototipi, rendendo difficile una fase preliminare di ottimizzazione su piccola scala. In questo scenario si inserisce il Packaging Lab, concepito come un ambiente intermedio tra laboratorio e industria, che consente di simulare e testare processi produttivi su scala ridotta, riducendo costi, tempi e sprechi di materiale. Il laboratorio è dotato di strumentazioni che riproducono, in versione ridotta, le principali tecnologie industriali per la trasformazione dei polimeri e dei materiali innovativi. Tra queste: un mini-estrusore, un sistema di stampaggio a iniezione (MiniJet) per la realizzazione di provini, una termopressa manuale per la produzione di film e sistemi di stampa 3D a granulo (Fig. 3), utili per la prototipazione rapida e la realizzazione di geometrie complesse. Parallelamente, il Packaging Lab è attrezzato per la caratterizzazione dei materiali, aspetto fondamentale per valutare le prestazioni dei prodotti sviluppati. In particolare, è possibile determinare le proprietà meccaniche dei materiali, come resistenza a trazione, modulo elastico e allungamento a rottura, parametri essenziali per verificare il comportamento dei materiali per specifiche applicazioni. Le principali linee di ricerca sviluppate all'interno del laboratorio comprendono:

- Prototipazione di packaging attivi, progettati per aumentare il tempo di conservazione del prodotto confezionato;
- Packaging intelligenti, basati sull'integrazione di indicatori di pH o altri sensori, in grado di monitorare lo stato di conservazione degli alimenti;
- Sviluppo di adesivi sostenibili;
- Realizzazione di supporti per idroponica e aeroponica, sistemi innovativi per l'agricoltura sostenibile che richiedono materiali performanti e biodegradabili;
- Sviluppo di soluzioni per l'agricoltura, come teli di pacciamatura biodegradabili e materiali per la produzione di microgreen, da materie prime seconde progettati per ridurre l'impatto ambientale e facilitare la gestione dei rifiuti.




Figura 3. Stampante 3D a granulo nel Packaging Lab.

Nel complesso, il Packaging Lab rappresenta un'infrastruttura strategica per colmare il divario tra ricerca e applicazione industriale, favorendo lo sviluppo di materiali sostenibili e accelerando il trasferimento tecnologico verso il mercato.

Caso studio: sviluppo di packaging attivi da scarti alimentari

Come caso studio, è stato approfondito lo sviluppo di sistemi di packaging attivo a partire da scarti alimentari, con l'obiettivo di valorizzare sottoprodotti dell'industria agroalimentare e trasformarli in materiali funzionali ad alto valore aggiunto. Ogni anno vengono generate enormi quantità di rifiuti alimentari, che rappresentano una risorsa ancora largamente sottoutilizzata. All'interno di questi scarti sono infatti presenti numerosi biopolimeri di grande interesse, come tannini da residui agricoli, lignina da scarti lignocellulosici, la pectina estratta dalle bucce di agrumi e il chitosano ottenuto dai gusci dei crostacei. Queste molecole, oltre a essere rinnovabili, presentano proprietà intrinseche che le rendono particolarmente adatte allo sviluppo di materiali sostenibili con proprietà aggiuntive. Tra questi, il chitosano riveste un ruolo di particolare rilievo. Si tratta di un biopolimero ottenuto principalmente da scarti di crostacei, caratterizzato da eccellenti proprietà filmogene, adesive e attività antibatterica che è stato utilizzato per la produzione

di un packaging attivo contenente anche nanoparticelle di lignina come biofiller attivo (Capecchi et al., 2022; Costa et al., 2024; Russo et al., 2025). Inoltre, grazie al contenuto di azoto, può essere impiegato come fertilizzante, contribuendo ulteriormente alla chiusura del ciclo nell'ottica dell'economia circolare. Ulteriori studi hanno considerato anche l'impiego della cheratina, derivata da piume di struzzo, derivante come scarto dall'industria della moda di lusso, come componente funzionale. L'approccio adottato si basa quindi sulla combinazione sinergica di diverse biomolecole, ciascuna caratterizzata da proprietà specifiche, al fine di ottenere materiali con prestazioni migliorate rispetto ai singoli componenti. Questa strategia consente di sviluppare sistemi avanzati di packaging biodegradabili e compostabili in grado non solo di svolgere una funzione di contenimento, ma anche di contribuire attivamente alla conservazione degli alimenti, prolungandone la *shelf life*.

Dal FUori Suolo alla Tavolo e Oltre (FUSTO), il percorso tracciato da Metrofood e Agritech

I laboratori Farming Lab, Kitchen Lab e Packaging Lab non sono entità isolate, ma rappresentano i pilastri di un unico percorso chiamato "FUSTO" ideato dal Santa Chiara Lab. Si tratta di una linea ideale che va dalla produzione del cibo fino al suo consumo e oltre (Fig. 4). Il Farming Lab si trova all'inizio di questo percorso e si occupa della produzione. È il luogo in cui gettare le basi per un'agricoltura sostenibile e resiliente. Il Kitchen Lab rappresenta il luogo della trasformazione. È qui che il prodotto grezzo viene trasformato in un'esperienza culinaria. Il Packaging Lab si colloca nella fase finale del processo, quella della conservazione e della distribuzione con la creazione di imballaggi sostenibili a partire dagli scarti dell'agricoltura e dell'industria alimentare, chiudendo così il cerchio della sostenibilità. L'obiettivo di FUSTO è, però, più ambizioso della somma delle attività dei singoli laboratori, in quanto mira a costruire un percorso interdisciplinare innovativo che coinvolga la ricerca, le imprese e il territorio con un approccio ampio alla sostenibilità. Per questo motivo, il progetto comprende anche un Track & Quality Lab che si occupa di identificare l'origine e la qualità dei prodotti attraverso analisi genetiche e chimiche, nonché un hub per la sostenibilità, come il laboratorio ESG4AGRI, dedicato alla mi-

surazione delle performance di sostenibilità delle aziende, e AgriHub, per l'analisi degli scenari del settore. Tutti questi elementi, insieme a Santa Chiara Next (uno *spin-off* universitario nato per supportare le imprese nel percorso di allineamento agli Obiettivi di Sviluppo Sostenibile dell'ONU), fanno di FUSTO un ecosistema per l'innovazione nel settore agroalimentare.



Figura 4. Schematizzazione del percorso FUSTO (Dal FUori Suolo alla Tavola e Oltre).

Bibliografia

- Anichini, S., Bellini, A., Cai, G., Romi, M., & Parri, S. (2025). Light spectrum differentially modulates physiology and secondary metabolism in underutilized leafy greens grown in aeroponics. *Plant Physiology and Biochemistry*, 110546.
- Capecci, E., Tomaino, E., Piccinino, D., Kidibule, P. E., Fernández-Lobato, M., Spinelli, D., ... & Saladino, R. (2022). Nanoparticles of lignins and saccharides from fishery wastes as sustainable uv-shielding, antioxidant, and antimicrobial biofillers. *Biomacromolecules*, 23(8), 3154-3164.
- Carotti, L., Potente, G., Pennisi, G., Ruiz, K. B., Biondi, S., Crepaldi, A., ... & Antognoni, F. (2021). Pulsed LED light: exploring the balance between energy use and nutraceutical properties in indoor-grown lettuce. *Agro-nomy*, 11(6), 1106.
- Costa, J., Baratto, M. C., Spinelli, D., Leone, G., Magnani, A., & Pogni, R. (2024). A novel bio-adhesive based on chitosan-polydopamine-xanthan gum for glass, cardboard and textile commodities. *Polymers*, 16(13), 1806.
- Marti, P., Cai, G., Parri, S., Di Noi, A., Mastrodonato, S., & Gullì, A. (2025). Plant to fork: from sustainably sourced bio-based feedstock to 3D printed delicacies. *Ahfe international*, 160, 550-558.
- Paglalunga, G., Moscatello, S., Battistelli, A., Mattioni, M., Del Bianco, M., & Proietti, S. (2024). Continuous Blue Light Treatment Enhances the Nutritional

Value of Hydroponically Grown *Eruca vesicaria* L. by Improving Ascorbic Acid Biosynthesis. *Foods*, 13(13), 2141.

Russo, A., D'Alessandro, A., Di Paola, M., Cerasuolo, B., Renzi, S., Meriggi, N., ... & Cavalieri, D. (2025). On the role of bacterial gut microbiota from supralittoral amphipod *Talitrus saltator* (Montagu, 1808) in bioplastic degradation. *Science of the Total Environment*, 972, 179109.

Zou, J., Fanourakis, D., Tsaniklidis, G., Woltering, E. J., Cheng, R., & Li, T. (2023). Far-red radiation during indoor cultivation reduces lettuce nutritional quality and shortens the shelf-life when stored at supra optimal temperatures. *Postharvest Biology and Technology*, 198, 112269.

Microplastics analyzer: una piattaforma digitale per la quantificazione e l'analisi morfologica e composizionale di microplastiche

Marta Vicentini^{1}, Maria Assunta Acquavia², Marta Fadda¹⁺, Angelo Mariano³, Alessio Sacco¹, Andrea Mario Giovannozzi¹, Andrea Mario Rossi¹, Alessandra Manzin¹*

¹ Istituto Nazionale di Ricerca Metrologica (INRiM), Torino, Italy

² Istituto Nazionale di Ricerca Metrologica (INRiM), Matera, Italy

³ Agenzia Nazionale per le nuove Tecnologie, l'Energia e lo Sviluppo economico sostenibile (ENEA), Bari, Italy

⁺ Present address: Department of Applied Science and Technology, Politecnico di Torino, Italy

^{*} Corresponding Author: m.vicentini@inrim.it

ABSTRACT – Le microplastiche, particelle polimeriche di dimensioni comprese tra 1 μm e 1 mm, sono ormai ubiquitarie negli ecosistemi e sono state rilevate in numerose matrici alimentari, tra cui prodotti ittici, acqua potabile, zucchero e alimenti di origine vegetale. La loro persistenza e capacità di veicolare contaminanti rendono necessaria una valutazione approfondita dei potenziali rischi per la salute umana. Diventa quindi essenziale l'analisi accurata di morfologia, dimensione, distribuzione e composizione per test tossicologici e valutazione del rischio affidabili. L'analisi delle microplastiche comprende le fasi di campionamento, isolamento, identificazione, quantificazione e caratterizzazione. Nello specifico, tecniche di microscopia, spettroscopia e cromatografia vengono adoperate per fornire informazioni complementari su morfologia e composizione chimica. Tuttavia, le analisi morfologiche, basate sull'analisi delle immagini acquisite tramite microscopia ottica, sono spesso limitate da approcci manuali o semplificati, con riduzione di accuratezza e riproducibilità. Nel progetto PNRR METROFOOD-IT è stata sviluppata una piattaforma digitale (*Microplastics Analyzer*) con funzionalità di servizio per supportare la quantificazione e l'analisi morfologica di microplastiche, integrando tecniche di *computer vision* con un modello di rete neurale addestrato su dati

sperimentali. Tale strumento consente la segmentazione automatizzata di particelle anche di forma irregolare e inglobate in agglomerati. È inoltre disponibile una libreria di spettri dei principali polimeri, acquisiti mediante spettroscopia Raman, infrarossa e a risonanza magnetica nucleare (NMR).

Keywords: Microplastiche; Analisi dimensionale; Microscopia ottica; Segmentazione di immagini; Rete neurale convoluzionale; Spettroscopia; Libreria di spettri; Polimeri.

Introduzione

Il rilevamento di microplastiche in un numero crescente di alimenti ha suscitato preoccupazione per la sicurezza alimentare, attirando l'attenzione della comunità scientifica, degli enti regolatori e dei consumatori (Bhattacharjee et al., 2025; Mir et al., 2025; Muhib et al. 2023; Usman et al., 2020). Le microplastiche, classificate come frammenti di plastica tra 1 μm e 1 mm secondo la normativa ISO/TR 21960:2020, si definiscono primarie se prodotte nella scala micrometrica o secondarie se derivano dalla degradazione di oggetti in materiali polimerici di dimensione maggiore (Cole et al., 2011). La loro diffusione nei sistemi naturali è ubiquitaria e la presenza nella catena alimentare è stata rilevata in prodotti ittici, acqua potabile, miele, zucchero e alimenti vegetali (Giri et al., 2024; Fadda et al., 2026). La contaminazione alimentare può derivare da molteplici fattori, tra cui l'uso di acqua contaminata, la contaminazione tramite particelle presenti nell'ambiente durante i processi di trasformazione e manipolazione degli alimenti, e la migrazione di microplastiche dagli imballaggi (Melikoglu, 2025). La persistenza di queste particelle, unita alla loro potenziale capacità di trasportare contaminanti (Rafa et al., 2024), solleva interrogativi sui possibili rischi per la salute umana, evidenziando la necessità di studi volti a fornire evidenze robuste sui loro effetti e sulle implicazioni a lungo termine. Diventa quindi essenziale l'analisi accurata della loro morfologia, dimensione, stato di agglomerazione e composizione, ai fini dei test tossicologici e di una valutazione del rischio affidabile.

Un tipico flusso di lavoro per lo studio di microplastiche prevede una sequenza strutturata che comprende la raccolta e selezione dei campioni, seguite da procedure di preparazione e filtrazione finalizzate

all'isolamento delle particelle dalla matrice in cui sono contenute, cui fanno seguito le fasi di identificazione, quantificazione e caratterizzazione (Schnepf et al., 2023). Le principali tecniche analitiche per la loro analisi si possono classificare in tre categorie, basate rispettivamente su microscopia, cromatografia e spettroscopia (Ciornii et al., 2025; Randhawa, 2023; Kwon et al., 2020; Schymanski et al., 2021). Le prime permettono di valutare le proprietà morfologiche delle particelle, mentre le altre consentono l'identificazione dei polimeri che le costituiscono. È possibile combinare diverse tecniche per arrivare ad una valutazione completa delle caratteristiche delle microplastiche. In particolare, tecniche come la spettroscopia infrarossa a trasformata di Fourier (FTIR) e la spettroscopia Raman, se accoppiate alla microscopia, permettono un'analisi qualitativo-quantitativa non distruttiva, fornendo informazioni complete sia sul numero sia sulla composizione chimica delle microplastiche, motivo per cui sono tra le più utilizzate (Ciornii et al., 2025). Tuttavia, le analisi morfologiche tradizionali spesso si basano su esecuzioni manuali o procedure semplificate, che possono essere soggette a variabilità e limitazioni nella quantificazione accurata; per questo motivo, lo sviluppo di strumenti automatizzati di segmentazione di immagini e analisi dimensionale rappresentano un supporto fondamentale per ottenere dati più affidabili (Ko et al., 2024; Valente et al., 2023; Vicentini et al., 2026).

Nell'ambito del progetto PNRR METROFOOD-IT, l'Istituto Nazionale di Ricerca Metrologica (INRiM) ha sviluppato una piattaforma digitale (*Microplastics Analyzer*) con funzionalità di servizio per l'analisi dimensionale e morfologica di microplastiche in campioni alimentari, ambientali e biologici. Tale strumento permette di elaborare immagini acquisite con microscopia ottica in modo completamente automatizzato, consentendo la segmentazione di particelle di forma irregolare e all'interno di agglomerati. *Microplastics Analyzer* integra metodi tradizionali di *computer vision* con un modello di rete neurale addestrato e validato su immagini di diverse tipologie di microplastiche. Parallelamente, il servizio rende disponibile una libreria di spettri dei principali polimeri, acquisiti con tecniche di spettroscopia Raman, IR e risonanza magnetica nucleare (NMR). L'obiettivo è fornire uno strumento pratico e di facile utilizzo per supportare l'analisi delle microplastiche, promuovendo la comparabilità dei dati tra laboratori e contribuendo a migliorare il monitoraggio della contaminazione lungo la catena alimentare.

Materiali e Metodi

In questa sezione vengono descritte le metodologie alla base del servizio *Microplastics Analyzer*, includendo sia le tecniche di segmentazione delle immagini disponibili per l'analisi delle microplastiche (finalizzate all'estrazione dei contorni delle microplastiche e al calcolo dei parametri morfologici), sia le tecniche analitiche utilizzate per l'acquisizione degli spettri che costituiscono la libreria.

Tecniche di segmentazione implementate per l'analisi morfologica di microplastiche

Per analizzare morfologia e distribuzione delle microplastiche in immagini da microscopia ottica, è necessario separare la proiezione delle particelle dallo sfondo tramite tecniche di segmentazione. Attualmente non esistono procedure univoche per l'elaborazione delle immagini, in quanto tipicamente le immagini di microplastiche presentano elevata eterogeneità dovuta sia alle condizioni di acquisizione (l'illuminazione può essere in modalità *bright field* o *dark field*), sia alla variabilità intrinseca delle particelle, in termini di forma, dimensione, colore, trasparenza e stato di agglomerazione. Questa complessità rende necessario testare diverse strategie di segmentazione. A tal fine, sono stati considerati i tre approcci di seguito riportati e schematizzati in Fig. 1.

- Applicazione di sogliatura automatica mediante algoritmo di Otsu (ISO 13322-1:2014; Schnepf et al., 2023), seguita da *post-processing* tramite operatori morfologici di apertura e chiusura, per ridurre il contenuto di rumore.
- Applicazione di un metodo ai contorni attivi (Márquez-Neila et al., 2014), basato sull'evoluzione, tramite iterazione sul gradiente dell'immagine, di un contorno iniziale fino all'adattamento progressivo ai bordi delle particelle individuate.
- Applicazione di una rete neurale convoluzionale di tipo avanzato addestrata appositamente su immagini di microplastiche, nello specifico Mask R-CNN (Abdulla, 2017; Han et al., 2023). Questo modello, definito di segmentazione delle istanze, combina il rilevamento di oggetti, per individuare la posizione delle microplastiche nell'immagine, con la segmentazione semantica, che classifica ogni pixel in oggetto di interesse o *background*.




Figura 1. Schema del flusso di elaborazione che, a partire dall'immagine acquisita, conduce al rilevamento dei contorni delle microplastiche, definiti dalle curve in giallo, in funzione dell'approccio di segmentazione adottato. Il percorso #1 corrisponde alla segmentazione mediante sogliatura automatica, il percorso #2 all'applicazione del metodo dei contorni attivi, mentre il percorso #3 all'impiego della rete neurale convoluzionale Mask R-CNN.

Per ogni percorso sono riportati anche i passaggi intermedi di elaborazione necessari all'ottenimento del risultato finale. I primi due approcci sono stati ottimizzati per immagini *dark field* e prevedono un *pre-processing* specifico, comprendente conversione in scala di grigi dell'immagine, normalizzazione dell'intensità e amplificazione del contrasto. Il modello Mask R-CNN, invece, garantisce maggiore flessibilità e accuratezza su entrambe le modalità di illuminazione, senza necessità di pre-elaborazione. Nella sogliatura e nella rete neurale l'output consiste in maschere binarie, ovvero immagini in bianco e nero in cui le regioni bianche corrispondono agli oggetti rilevati e la parte in nero allo sfondo, dalle quali è possibile estrarre i contorni delle microplastiche; invece, il secondo metodo fornisce direttamente i contorni. Dopo l'estrazione dei contorni, per ciascuna microplastica vengono calcolate le coordinate dei rispettivi centroidi e i principali parametri morfologici utili a descriverne forma e dimensione, tra cui area, perimetro, diametro equivalente, lunghezza degli assi maggiore e minore dell'ellisse di Legendre e diametri massimo e minimo di Feret. I valori sono ottenuti mediante funzioni di analisi di regione implementate nella libreria open source di Python *scikit-image*. La selezione dei parametri morfologici è stata effettuata in coerenza con quelli comunemente calcolati dai principali software di analisi integrati negli strumenti per la microscopia, garantendo così la confrontabilità e l'interoperabilità dei dati tra diverse piattaforme.

Tecniche analitiche per l'acquisizione degli spettri di materiali polimerici

Per la predisposizione della libreria di spettri sono state considerate tre tra le principali tecniche analitiche di spettroscopia, i.e. IR, Raman e NMR. La scelta di integrare queste tre tecniche deriva dalla loro complementarità nella caratterizzazione dei materiali polimerici, in quanto ciascuna fornisce informazioni specifiche sulla struttura chimica del campione e consente di migliorare l'affidabilità del riconoscimento dei diversi polimeri. La spettroscopia IR è una delle tecniche più diffuse per l'identificazione delle microplastiche, poiché consente di rilevare le vibrazioni caratteristiche dei gruppi funzionali presenti nelle catene polimeriche (Chen et al., 2020). Gli spettri IR risultano particolarmente utili per distinguere materiali con differente composizione chimica e per evidenziare eventuali fenomeni di ossidazione, invecchiamento o presenza di additivi. Quale tecnica complementare all'IR, la spettroscopia Raman è stata inclusa poiché particolarmente adatta alla caratterizzazione di particelle di piccole dimensioni. Essa si basa sull'interazione tra radiazione laser e modi vibrazionali della materia, permettendo di ottenere un'impronta spettrale caratteristica del polimero (Jin et al., 2022). La spettroscopia NMR è stata considerata come tecnica di supporto per la caratterizzazione molecolare dei polimeri, in quanto consente di ottenere informazioni dettagliate sull'ambiente chimico dei nuclei atomici e quindi sulla struttura delle unità monomeriche, sulla composizione del materiale e, in alcuni casi, sulla presenza di copolimeri o additivi (Zhou et al., 2025). Pur essendo meno comunemente impiegata per l'identificazione diretta di singole microplastiche rispetto a IR e Raman, la spettroscopia NMR costituisce un valido strumento per la conferma dell'identità chimica dei materiali di riferimento utilizzati nella costruzione della libreria spettrale. L'integrazione di queste tre tecniche ha quindi permesso di costruire una libreria robusta e versatile, basata su segnali spettroscopici tra loro complementari. Tale approccio consente di migliorare la qualità dell'identificazione dei principali polimeri di interesse nelle analisi di microplastiche e di fornire un supporto più completo agli utenti del servizio *Microplastics Analyzer*, anche in presenza di matrici complesse o materiali parzialmente degradati.

Descrizione della piattaforma digitale Microplastics Analyzer

Applicazione all'analisi dimensionale e morfologica di microplastiche

La Fig. 2 mostra degli esempi di applicazione delle tre tecniche di segmentazione integrate in *Microplastics Analyzer* su porzioni di immagini di particelle polimeriche di diversa origine; le curve gialle sovrapposte corrispondono ai contorni ottenuti dal processo di segmentazione.

Data la modalità di acquisizione (*dark-field*), sullo sfondo è possibile osservare, con visibilità variabile in funzione del grado di messa a fuoco, la struttura porosa della membrana (in silicio) sulla quale sono depositate le microplastiche a seguito dei processi di filtrazione. Tutte le tecniche di segmentazione si sono dimostrate efficaci nel discriminare le microplastiche rispetto allo sfondo. In particolare, è stata evitata la segmentazione erronea dei pori della membrana che, pur essendo visibili nelle immagini, non sono stati identificati come oggetti di interesse. Inoltre, la variabilità morfologica, così come i diversi livelli di contrasto e visibilità delle particelle, non rappresentano un limite per l'estrazione accurata dei contorni. Tuttavia, sia la sogliatura automatica sia i contorni attivi risultano più adatti in condizioni in cui le microplastiche sono ben separate tra loro, come i casi riportati in Fig. 2a e Fig. 2b. In condizioni in cui le particelle risultano agglomerate, hanno forme irregolari o presentano convessità accentuata che può dare origine ad artefatti, l'approccio basato su Mask R-CNN si dimostra più efficace. Ad esempio, la rete neurale evidenzia una buona capacità nel distinguere correttamente microplastiche di forma sferica nonostante la comparsa di bordi interni "falsi" dovuti a effetti di rifrazione. I risultati ottenuti nel caso di particelle di riferimento




Figura 2 a, b, c. Esempi di applicazione del modulo di analisi di immagini integrato nel servizio *Microplastics Analyzer* su porzioni di immagini, acquisite in modalità *dark field*, di microplastiche di diversa origine. Le curve gialle sovrapposte corrispondono ai contorni ottenuti dal processo di segmentazione: (a) sogliatura automatica, (b) contorni attivi, (c) rete neurale convoluzionale Mask R-CNN.




Figura 3. Esempio di applicazione del processo di segmentazione su un'immagine contenente particelle di forma sferica in polistirene (a). Confronto dei risultati ottenuti con (b) il software di analisi di immagini integrato nel microscopio ottico usato per l'acquisizione dell'immagine e (c) il metodo di segmentazione presente nel servizio *Microplastics Analyzer*, basato sulla rete neurale Mask R-CNN.

di forma sferica in polistirene (diametro nominale di $51.2 \mu\text{m}$) sono illustrati in Fig. 2c, ove è inoltre possibile apprezzare l'efficacia del metodo nel separare agglomerati. I cerchi rossi evidenziano come il software commerciale tende a identificare particelle adiacenti come un unico oggetto, mentre la rete neurale consente una migliore separazione delle singole microplastiche. I pallini rossi indicano il centroide di ogni oggetto rilevato. Per evidenziare il vantaggio di disporre di una segmentazione in grado di distinguere oggetti spazialmente molto vicini, la Fig. 3 riporta un confronto con il software di segmentazione integrato nel microscopio ottico utilizzato per l'acquisizione delle immagini.

I cerchi rossi evidenziano come il software commerciale tende a identificare particelle adiacenti come un unico oggetto, mentre la rete neurale consente una migliore separazione delle singole microplastiche. I pallini rossi indicano il centroide di ogni oggetto rilevato. Come evidenziato dai cerchi in rosso in Fig. 3b, tale software tende a identificare come un unico oggetto più sfere di polistirene adiacenti, portando a una non corretta caratterizzazione morfologica e quantificazione delle microplastiche nel campione in analisi. Al contrario, il modello proposto in *Microplastics Analyzer* dimostra una buona capacità di distinguere efficacemente le particelle adiacenti (Fig. 3c). Infatti, i software di analisi immagini integrati negli strumenti non sempre integrano tecniche di segmentazione avanzate come quella presente nel servizio, né propongono l'utilizzo di algoritmi aggiuntivi ideati appositamente per la separazione degli agglomerati, come ad esempio il *watershed* (Gamarra et al., 2019). Inoltre, tali software possono mostrare una ridotta sensibilità nel distinguere particelle di dimensioni molto piccole, con conseguente sottostima numerica e alterazione della distribuzione dimensionale (Schnepf et al.,

2023). *Microplastics Analyzer* consente di esportare i risultati delle segmentazioni in formato immagine (.PNG), come illustrato nelle Fig. 2 e 3, cioè con i contorni in giallo delle microplastiche individuate. Le maschere e i contorni identificati permettono l'estrazione delle principali caratteristiche morfologiche, nonché delle coordinate spaziali delle microplastiche nell'immagine fornita. Tutti i dati estratti vengono salvati in formato tabellare (.CSV). Per impostazione predefinita, le misure sono espresse in pixel; tuttavia, è possibile specificare un fattore di conversione da pixel a micrometro. Per ciascuna caratteristica geometrica è possibile inoltre esportare i corrispondenti istogrammi (in formato .PNG), facilitando una valutazione statistica immediata della distribuzione. Infine, è disponibile anche un file contenente la maschera dell'immagine segmentata, compatibile con il software *Particle Finder* (HORIBA Scientific, Kyoto, Japan).

Esplorazione della libreria di spettri di polimeri

I polimeri presenti nella libreria e le corrispondenti tipologie di spettri sono riassunti nella Tab. 1.

Tabella 1. Riepilogo delle tecniche spettroscopiche utilizzate per l'acquisizione degli spettri dei polimeri. IR: spettroscopia infrarossa; NMR: spettroscopia di risonanza magnetica nucleare; Raman: spettroscopia Raman. Il simbolo ✓ indica la disponibilità nella libreria di spettri per la tecnica indicata.

Materiale	IR	Raman	NMR
HDPE	✓		
LDPE			✓
PA	✓	✓	✓
PC	✓		✓
PE	✓	✓	✓
PET	✓	✓	✓
PMMA	✓		✓
PP	✓		✓
PS	✓	✓	✓
PTFE	✓		
PVC	✓		✓

Nota: HDPE = polietilene ad alta densità; LDPE = polietilene a bassa densità; PA = poliammide; PC = policarbonato; PE = polietilene; PET = polietilene tereftalato; PMMA = polimetilmetacrilato; PP = polipropilene; PS = polistirene; PTFE = politetrafluoroetilene; PVC = cloruro di polivinile.

Per ciascuno spettro incluso nella libreria, sono resi disponibili i rispettivi dati numerici in duplice formato, per garantire la massima interoperabilità e tracciabilità: file di testo (.TXT) e file nativo (.OPJ), compatibile con il software *Origin* (OriginLab Corporation, Northampton, MA, USA), ampiamente utilizzato per l'elaborazione e la rappresentazione di dati scientifici. A corredo dei dati numerici, è inoltre fornita la corrispondente rappresentazione grafica dello spettro in formato ad alta risoluzione (.TIF). Una sua anteprima è direttamente accessibile tramite l'interfaccia web prima del download. La libreria è stata strutturata in modo da consentire una consultazione agevole e un confronto diretto tra materiali polimerici diversi e tra spettri acquisiti con differenti tecniche analitiche. Questa organizzazione permette all'utente di selezionare i dati più pertinenti rispetto alle proprie condizioni sperimentali e di utilizzare la libreria sia come supporto all'identificazione qualitativa dei polimeri, sia come riferimento per attività di confronto, validazione e interpretazione dei segnali acquisiti sperimentalmente. Per la spettroscopia IR, gli spettri sono stati acquisiti con obiettivo 15 $\times$, risoluzione pari a 8 cm⁻¹, nell'intervallo spettrale 748-4000 cm⁻¹, con tempo di acquisizione di 3 s e 16 scansioni, e sono stati infine elaborati e resi disponibili in formato *Absorbance vs Wave-number* (cm⁻¹). Nel caso della spettroscopia Raman, gli spettri sono stati acquisiti mediante strumentazione Raman, utilizzando un obiettivo 10 $\times$, potenza laser pari a 12 mW, 10 scansioni e un tempo di esposizione di 1 s. Per il trattamento dei dati è stata applicata la correzione della linea di base mediante polinomio di grado 6. Inoltre, sono state considerate diverse lunghezze d'onda laser (455 nm, 532 nm, 633 nm e 780 nm), così da ampliare la rappresentatività della libreria rispetto a differenti condizioni sperimentali e strumentali. Gli spettri acquisiti sono resi disponibili in formato *Intensity vs Raman Shift* (cm⁻¹). Per la spettroscopia NMR, le acquisizioni sono state effettuate a 600 MHz, in condizioni riconducibili allo stato semi-solido mediante tecnica *High-Resolution Magic Angle Spinning* (HRMAS) NMR e/o in soluzione, in funzione del tipo di polimero analizzato. In particolare, per il polietilene tereftalato (PET) sono stati acquisiti spettri in soluzione usando CDCl₃/TFA (4:1, v/v) a concentrazione di 0.5 mg/mL come solvente. Invece, per il polistirene (PS) gli spettri sono stati acquisiti in CDCl₃ a concentrazione di 0.1 mg/mL. L'impiego combinato di acquisizioni allo stato semi-solido e in soluzione consente di estendere l'applicabilità della libreria a materiali con differente comportamento chimico-



Figura 4. Schema illustrativo dell'interazione dell'utente con i due moduli principali del servizio *Microplastics Analyzer*. Nella parte superiore è rappresentato il flusso operativo relativo all'analisi di dimensione e forma di microplastiche da immagini acquisite tramite microscopia ottica, mentre nella parte inferiore è riportato il modulo dedicato alla consultazione e al download della libreria di spettri dei polimeri.

fisico e differente solubilità, migliorando la qualità della caratterizzazione molecolare. Per gli spettri NMR l'intensità del segnale è riportata in funzione del *chemical shift*, espresso come δ (ppm).

Accesso alla piattaforma digitale *Microplastics Analyzer*

Il servizio *Microplastics Analyzer* è accessibile tramite un'interfaccia web sviluppata dall'INRiM e resa disponibile online dall'ENEA al link <https://microplasticismfit.enea.it/>. Dalla schermata principale, l'utente può accedere ai due principali moduli: (i) lo strumento digitale per la segmentazione di immagini e l'analisi morfologica delle microplastiche e (ii) la libreria di spettri di polimeri plastici. I corrispondenti *workflow* di ogni modulo sono schematizzati in Fig. 4.

Conclusioni

In questo lavoro è stata presentata la piattaforma digitale *Microplastics Analyzer* sviluppata nell'ambito del progetto PNRR METRO-FOOD-IT a supporto dell'analisi di microplastiche, che combina strumenti avanzati di analisi di immagini e una libreria di spettri dei principali polimeri plastici. I risultati riportati mostrano come le tec-

niche di segmentazione proposte possono essere adoperate per analizzare in modo automatizzato la morfologia e la dimensione delle microplastiche. Il confronto tra i diversi approcci di segmentazione evidenzia come metodi più semplici, quali la sogliatura automatica e i contorni attivi, risultano efficaci in contesti a bassa complessità, mentre modelli basati su *deep learning*, come Mask R-CNN, offrono buone prestazioni in scenari più articolati, caratterizzati da particelle agglomerate, morfologicamente molto eterogenee o in presenza di artefatti. Inoltre, la possibilità di fornire le coordinate spaziali delle particelle rilevate rappresenta un elemento di particolare rilevanza operativa, consentendo di guidare in modo mirato analisi spettroscopiche, come quelle Raman, di limitare l'acquisizione degli spettri alle sole regioni contenenti microplastiche di interesse. Parallelamente, la disponibilità di una libreria di spettri acquisiti mediante diverse tecniche spettroscopiche e in differenti condizioni operative costituisce un importante supporto per l'identificazione chimica dei polimeri, aumentando l'affidabilità delle analisi, in quanto consente di selezionare i dati più pertinenti rispetto alle specifiche condizioni sperimentali. Infine la libreria può essere utilizzata anche per attività di confronto, validazione e interpretazione dei segnali acquisiti sperimentalmente.

Acknowledgments

L'attività descritta è stata supportata dal Progetto METROFOOD-IT, finanziato dall'Unione Europea – NextGenerationEU, nell'ambito del PNRR – Missione 4 “Istruzione e Ricerca”, Componente 2: “Dalla ricerca all'impresa”, Linea di investimento 3.1: Fondo per la realizzazione di un sistema integrato di infrastrutture di ricerca e innovazione [IR0000033] (D.M. Prot. n. 120 del 21/06/2022).

Bibliografia

- Abdulla, W. (2017). Mask R-CNN for object detection and instance segmentation on Keras and TensorFlow.
- Bhattacharjee, U., Baruah, K. N., & Shah, M. P. (2025). Exploring sustainable strategies for mitigating microplastic contamination in soil, water, and the food chain: A comprehensive analysis. *Environmental Chemistry and Ecotoxicology*, 7, 453–461.

- Chen, Y., Wen, D., Pei, J., Fei, Y., Ouyang, D., Zhang, H., & Luo, Y. (2020). Identification and quantification of microplastics using Fourier-transform infrared spectroscopy: Current status and future prospects. *Current Opinion in Environmental Science & Health*, 18, 14–19.
- Ciornii, D., Hodoroaba, V. D., Benismail, N., Maltseva, A., Ferrer, J. F., Wang, J., ... & Altmann, K. (2025). Interlaboratory comparison reveals state of the art in microplastic detection and quantification methods. *Analytical Chemistry*, 97(16), 8719–8728.
- Cole, M., Lindeque, P., Halsband, C., & Galloway, T. S. (2011). Microplastics as contaminants in the marine environment: a review. *Marine Pollution Bulletin*, 62(12), 2588–2597.
- Fadda, M., Sacco, A., Rossi, A. M., & Giovannozzi, A. M. (2026). Hidden pollutants in food: Evidence of small microplastic particles (100–5 µm) in refined sugar from the Italian market. *Journal of Hazardous Materials*, 503(141113), 141113.
- Gamarra, M., Zurek, E., Escalante, H. J., Hurtado, L., & San-Juan-Vergara, H. (2019). Split and Merge Watershed: a two-step method for cell segmentation in fluorescence microscopy images. *Biomedical Signal Processing and Control*, 53, 101575.
- Giri, S., Lamichhane, G., Khadka, D., & Devkota, H. P. (2024). Microplastics contamination in food products: Occurrence, analytical techniques and potential impacts on human health. *Current Research in Biotechnology*, 7, 100190.
- Han, X.-L., Jiang, N.-J., Hata, T., Choi, J., Du, Y.-J., & Wang, Y.-J. (2023). Deep learning based approach for automated characterization of large marine microplastic particles. *Marine Environmental Research*, 183, 105829.
- Jin, N., Song, Y., Ma, R., Li, J., Li, G., & Zhang, D. (2022). Characterization and identification of microplastics using Raman spectroscopy coupled with multivariate analysis. *Analytica Chimica Acta*, 1197, 339519.
- Ko, K., Lee, J., Baumann, P., Kim, J., & Chung, H. (2024). Analysis of micro(nano) plastics based on automated data interpretation and modeling: A review. *NanoImpact*, 34, 100509.
- Kwon, J.-H., Kim, J.-W., Pham, T. D., Tarafdar, A., Hong, S., Chun, S.-H., Lee, S.-H., Kang, D.-Y., Kim, J.-Y., Kim, S.-B., & Jung, J. (2020). Microplastics in food: A review on analytical methods and challenges. *International Journal of Environmental Research and Public Health*, 17(18), 6710.
- Márquez-Neila, P., Baumela, L., & Alvarez, L. (2014). A morphological approach to curvature-based evolution of curves and surfaces. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 36(1), 2–17.
- Melikoglu, M. (2025). Microplastics and nanoplastics in food systems: Contamination, impacts, and mitigation strategies – a global review. *Next Research*, 2(4), 100998.
- Mir, M. A., Ali Khan, M. A., Banik, B. K., Hasnain, S. M., Alzayer, L., Andrews, K., & Abba, S. I. (2025). Microplastics in food products: Prevalence, artifi-

- cial intelligence based detection, and potential health impacts on humans. *Emerging Contaminants*, 11(2), 100477.
- Muhib, M. I., Uddin, M. K., Rahman, M. M., & Malafaia, G. (2023). Occurrence of microplastics in tap and bottled water, and food packaging: A narrative review on current knowledge. *The Science of the Total Environment*, 865, 161274.
- Rafa, N., Ahmed, B., Zohora, F., Bakya, J., Ahmed, S., Ahmed, S. F., Mofijur, M., Chowdhury, A. A., & Almomani, F. (2024). Microplastics as carriers of toxic pollutants: Source, transport, and toxicological effects. *Environmental Pollution (Barking, Essex: 1987)*, 343, 123190.
- Randhawa, J. S. (2023). Advanced analytical techniques for microplastics in the environment: a review. *Bulletin of the National Research Centre*, 47(1), 174.
- Schnepf, U., von Moers-Meißner, M. A. L., & Brümmer, F. (2023). A practical primer for image-based particle measurements in microplastic research. *Microplastics and Nanoplastics*, 3(1), 16.
- Schymanski, D., Oßmann, B. E., Benismail, N., Boukerma, K., Dallmann, G., Von der Esch, E., ... & Ivleva, N. P. (2021). Analysis of microplastics in drinking water and other clean water samples with micro-Raman and micro-infrared spectroscopy: minimum requirements and best practice guidelines. *Analytical and bioanalytical chemistry*, 413(24), 5969-5994.
- Usman, S., Abdull Razis, A. F., Shaari, K., Amal, M. N. A., Saad, M. Z., Mat Isa, N., ... & Ibrahim, M. A. (2020). Microplastics pollution as an invisible potential threat to food safety and security, policy challenges and the way forward. *International Journal of Environmental Research and Public Health*, 17(24), 9591.
- Valente, T., Ventura, D., Matiddi, M., Sbrana, A., Silvestri, C., Piermarini, R., Jacomini, C., & Costantini, M. L. (2023). Image processing tools in the study of environmental contamination by microplastics: reliability and perspectives. *Environmental Science and Pollution Research International*, 30(1), 298-309.
- Vicentini, M., Fadda, M., Fracchia, C., Lamberti, P., Remogna, S., Sacco, A., Giovannozzi, A. M., Rossi, A. M. & Manzin, A. (2026). Microplastics quantification in microscopy images via gradient vector flow snake method combined with watershed transform. Under review.
- Zhou, Z., Duan, X., Yu, Y., Ma, L., Moreno, A., Xia, Y., Chen, L., Ye, S., & Cong, R. (2025). Recent advances and applications of NMR techniques in plastic characterizations. *Analytical Chemistry*, 97(11), 5847-5865.

CONSIGLIO SCIENTIFICO-EDITORIALE
SAPIENZA UNIVERSITÀ EDITRICE

Presidente

AUGUSTO ROCA DE AMICIS

Membri

MARCELLO ARCA

ORAZIO CARPENZANO

MARIANNA FERRARA

CRISTINA LIMATOLA

ENRICO ROGORA

FRANCESCO SAITTO

COLLANA SAPIENZA PER TUTTI

Per informazioni sui volumi precedenti della collana, consultare il sito:
www.editricesapienza.it | *For information on the previous volumes included
in the series, please visit the following website: www.editricesapienza.it*

22. Il clima che cambia
Passato e presente
Franco Bruno
23. L'albero del drago
Soqotra, paradiso di diversità
Franco Bruno e Fabio Attorre
24. Biodiversità
Animale e vegetale
Franco Bruno
25. Sapienza a Scuola: Laboratorio di anamorfosi tra arte e scienza
Un progetto di Terza Missione
a cura di Sofia Menconero, Vittoria Castiglione, Michela Ceracchi
26. Lezioni di storia (AA 2024-2025)
Incontri con Chris Wickham, Francisco Bethencourt, Tamar Herzog
e Umberto Gentiloni Silveri
a cura di Serena Di Nepi e Umberto Longo
27. La Terza Missione in Sapienza: 45 modi per valorizzare la conoscenza
Casi studio per la VQR 2020-2024
a cura di Fabio Lucidi, Fabiola Fratini, Giulia Antinucci
28. Le piante medicinali attraverso la storia
Franco Bruno e Andrea Bonito
29. La Rosa dall'antichità romana ad oggi
Stelvio Coggiatti †, Stefano Marzullo, Franco Bruno
30. *Spillover*: come ti racconto la *One Health*
Comunicazione, scienza, salute
Michaela Liuccio
31. Il libro che cambia forma
Esperienze di lettura tra immateriale e visivo
a cura di Marianna Ferrara
32. METROFOOD-IT: il quaderno
Conoscere l'infrastruttura di ricerca dedicata alla qualità, alla sicurezza
e alla valorizzazione delle filiere agroalimentari attraverso casi studio
a cura di Cesare Manetti



METROFOOD-IT: il quaderno presenta l'Infrastruttura di Ricerca italiana per la metrologia e i dati aperti a supporto del sistema agroalimentare. L'obiettivo del progetto è quello di rafforzare l'eccellenza scientifica italiana nella sicurezza alimentare attraverso lo sviluppo di piattaforme e servizi per la qualità, autenticità e rintracciabilità di materie prime e prodotti e per la digitalizzazione del settore è l'obiettivo del progetto METROFOOD-IT finanziato dal Piano Nazionale di Ripresa e Resilienza (PNRR). Attraverso una selezione di casi studio, il volume mostra come ricerca, tecnologie avanzate e condivisione dei dati possano tradursi in strumenti concreti per garantire qualità, sicurezza, autenticità e sostenibilità lungo le filiere alimentari. Spettroscopia, metabolomica, intelligenza artificiale, blockchain, sensoristica, analisi delle microplastiche e packaging innovativo sono alcuni degli ambiti presentati, evidenziando il valore dell'approccio multidisciplinare e del trasferimento dell'innovazione.

Cesare Manetti è Professore Associato di Chimica Fisica presso la Sapienza Università di Roma. La sua attività scientifica comprende la caratterizzazione chimica degli alimenti, la spettroscopia NMR, la metabolomica e lo studio dell'autenticità e qualità dei prodotti agroalimentari. È referente scientifico di Sapienza per METROFOOD-IT.

ISBN 978-88-9377-470-3



9 788893 774703

