



UNIVERSITÀ DEGLI STUDI DI PALERMO

Corso di dottorato in Biodiversity in Agriculture and Forestry

Dipartimento di Scienze Agrarie, Alimentari e Forestali

Settore Scientifico disciplinare AGR/03

Gestione sostenibile del vigneto mediante Data Science e Big Data Management

Il dottorando:

STEFANO PUCCIO

Il tutor:

PROF. ANTONINO PISCIOTTA

Il coordinatore:

PROF. RICCARDO LO BIANCO

I co-tutor:

PROF. STEFANO BARONE

DOTT. ALBERT COMELLI

CICLO XXXVI
ANNO CONSEGUIMENTO TITOLO: 2024

Gestione sostenibile del vigneto mediante Data Science e Big Data Management

*Se qualche scoperta seconderà le nostre previsioni,
la considereremo con speciale diffidenza.*

(Bertolt Brecht, Vita di Galileo)

Indice

Indice delle abbreviazioni	1
1 Introduzione	4
1.1 Obiettivi del progetto di ricerca e struttura della tesi	5
1.2 Riferimenti bibliografici.....	6
2 L'analisi d'immagini RGB in viticoltura	8
2.1 Riferimenti bibliografici.....	9
3 Stima del numero di fiori e previsione di componenti della resa in <i>Vitis vinifera</i> L. tramite analisi di immagini RGB	13
3.1 Materiale e metodi.....	15
3.1.1 Disegno sperimentale e acquisizione delle immagini RGB	15
3.1.2 Rilievo delle componenti della resa	18
3.1.3 Analisi delle immagini	19
3.1.4 Analisi statistica	20
3.2 Risultati	20
3.2.1 Stima del numero di fiori	20
3.2.2 Stima delle componenti della resa	26
3.3 Discussione	30
3.4 Conclusioni.....	33
3.5 Riferimenti bibliografici.....	34
4 Stima del numero di acini in grappoli di uva da tavola attraverso l'analisi di immagini	37
4.1 Materiale e Metodi	38
4.2 Risultati e discussione.....	42
4.3 Conclusioni.....	44
4.4 Riferimenti bibliografici.....	45
5 Stima del peso del legno di potatura in <i>Vitis vinifera</i> L. attraverso l'analisi d'immagini RGB	47
5.1 Materiale e Metodi	49
5.1.1 Disegno sperimentale e acquisizione di immagini	49
5.1.2 Analisi delle immagini	53
5.1.3 Analisi statistica	55
5.2 Risultati	57
5.2.1 Valutazione delle modalità di acquisizione delle immagini.....	57
5.2.2 Effetto dello sfondo ed effetto della cultivar	61
5.3 Discussione	64
5.4 Conclusioni.....	66
5.5 Riferimenti bibliografici.....	67

6 Modelli suolo-pianta-atmosfera per la stima del potenziale idrico del germoglio (Ψ_{stem}) in <i>Vitis vinifera</i> L. (cv Touriga Nacional)	71
6.1 Materiale e metodi	73
6.1.1 Disegno sperimentale.....	73
6.1.2 Dati climatici.....	75
6.1.3 Stato idrico del suolo.....	75
6.1.4 Stato idrico delle piante.....	77
6.1.5 Analisi statistica ed elaborazione dei modelli.....	77
6.2 Risultati	78
6.2.1 Clima, stato idrico del suolo e stato idrico delle piante.....	78
6.2.2 Modelli di stima del Ψ_{stem}	82
6.3 Discussione	89
6.4 Conclusioni	91
6.5 Riferimenti bibliografici	92
7 Complementary Use of Ground-Based Proximal Sensing and Airborne/Spaceborne Remote Sensing Techniques in Precision Agriculture: A Systematic Review	98
8 Conclusioni generali	139
9 Ringraziamenti	140

Indice delle abbreviazioni

a: actual, reale

AIC: Akaike's Information Criterion, criterio di informazione di Akaike

ANOVA: Analysis of Variance, analisi della varianza

AWS: Available Soil Water, acqua disponibile nel suolo

BBCH: Biologische Bundesanstalt, Bundessortenamt and CHEmical industry

BF: bagnatura fogliare

BIC: Bayesian Information Criterion, criterio di informazione bayesiano

CIELAB: Color space CIE L*a*b, Spazio colore CIE L*a*b

DL: Deep Learning, apprendimento profondo

DOY: Day of Year, giorno dell'anno

DSS: Decision Support System, Sistema di Supporto Decisionale

ET₀: evapotraspirazione di riferimento

FAO: Food and Agriculture Organization, organizzazione per l'alimentazione e l'agricoltura

FREAK: Fast Retina Keypoint

FTSW: Fraction of Transpirable Soil Water, frazione di acqua traspirabile del suolo

GDD: Growing Degree Days, somma termica

GPS: Global Positioning System, sistema di posizionamento globale

HOG: Histogram of Oriented Gradients

HS: Hyperspectral, iperspettrale

HUE: Hue Saturation Brightness, tonalità saturazione luminosità

HV: High Vigor, alto vigore

IoT: Internet of Things, internet delle cose

LAI: Leaf Area Index, indice di area fogliare

L: lunghezza

LIDAR: Light Detection and Ranging, rilevamento e misurazione della luce

LORAwan: Long-Range Wide Area Network, rete a larga area a lungo raggio

LOOCV: leave one out cross-validation, convalida incrociata escludendo un'osservazione alla volta

LV: Low Vigor, basso vigore

LVDT: Linear Variable Differential Transformer, trasformatore differenziale variabile lineare

MAPE: Mean Absolute Percentage Error, errore percentuale medio assoluto

ML: Machine Learning, apprendimento automatico

MS: Multispectral, multispettrale

NB: No Background, senza sfondo

NDVI: Normalized Difference Vegetation Index, indice di vegetazione normalizzato

NIR: Near-Infrared Spectroscopy, spettroscopia del vicino infrarosso

P: valore P

PI: primo intervento irriguo

PV: Precision Viticulture, viticoltura di precisione

p₁: SWC a 20 cm di profondità del suolo

p₂: SWC a 40 cm di profondità del suolo

p₃: SWC a 60 cm di profondità del suolo

p₄: SWC a 80 cm di profondità del suolo

p_{sum}: SWC nel profilo 0-80 cm del suolo

R²: coefficiente di determinazione

RDI: Regulated Deficit Irrigation, deficit idrico controllato

RGB: Red-Green-Blue, rosso-verde-blu

RMSE: Root Mean Squared Error, errore quadratico medio

ROI: Regions of Interest, Regioni di Interesse

RQs: Main Research Questions, principali domande di ricerca

Rs: radiazione solare

SURF: Speeded Up Robust Feature, caratteristica robusta accelerata

SWC: Soil Water Content, contenuto idrico del suolo

SWC_{fc}: Soil Water Content at Field Capacity, contenuto idrico del suolo alla capacità idrica di campo

SWC_{min}: Soil Water Content minimum, contenuto idrico del suolo minimo

SWIR: Short Wavelength InfraRed, infrarosso a lunghezza d'onda corta

T: temperatura

t: target, obiettivo

T_{max}: temperatura massima del giorno

T_{media}: temperatura media del giorno

TTSW: Total Transpirable Soil Water, acqua traspirabile totale del suolo

TWS: Trainable Weka Segmentation, segmentazione addestrabile di Weka

UAV: Unmanned Aerial Vehicle, veicolo aereo senza equipaggio

UI: ultimo intervento irriguo

UN: United Nations, Nazioni Unite

UR: umidità relativa

UR_{min}: umidità relativa minima del giorno

VHR: Very-high-resolution, altissima risoluzione

VI: volume irriguo

VIF: Variance Inflation Factor, fattore di inflazione della varianza

VPD: deficit di pressione di vapore

VPD_{max}: deficit di pressione di vapore massimo del giorno

VPD_{medio}: deficit di pressione di vapore medio del giorno

VV: velocità del vento

VV_{max}: velocità del vento massima del giorno

WB: With Background, con sfondo

WP: Wilting Point, Punto di Appassimento

Ψ_L: potenziale idrico fogliare *leaf*

Ψ_{PD}: potenziale idrico fogliare *pre-dawn*

Ψ_{stem}: potenziale idrico del germoglio *stem*

1 Introduzione

Negli ultimi anni, la ricerca in ambito viticolo (*Vitis vinifera* L.) è stata notevolmente influenzata dalla necessità duplice di rispondere alla crescente domanda di prodotto ad elevati standard qualitativi e a mediare criticità come l'emissione di gas serra e il conseguente aumento delle temperature medie, il degrado del suolo, la contaminazione delle acque, nonché una rinnovata consapevolezza dei consumatori per la sicurezza alimentare e la sostenibilità, tutti fattori che concorrono al delinearsi di nuovi scenari, talvolta imprevedibili, che richiedono una riprogrammazione dei diversi modelli gestionali. Alla base della mediazione di tali fattori risulta fondamentale una ricalibrazione della gestione del vigneto, spostandosi da un approccio convenzionale che prevede una gestione dello stesso come unità omogenea, verso uno che tenga in considerazione le sue discontinuità spaziali legate alle peculiarità pedoclimatiche e alle variabili biotiche, le quali, avendo riflessi eterogenei sul ciclo biologico della vite, determinano un uso non sempre razionale delle risorse (Crookston, 2006; Jones and Webb, 2010; Fraga et al., 2012; Urretavizcaya et al., 2015; Fraga, 2019; van Leeuwen et al., 2019; Santos et al., 2020). Emerge così l'esigenza di un rinnovamento dei sistemi di monitoraggio, che unisca il trasferimento tecnologico (anche di tecnologie già esistenti) alle conoscenze scientifiche pregresse, verso usi mirati e calibrati sull'ambito viticolo, attraverso i quali poter attuare strategie previsionali che permettano la salvaguardia degli equilibri ecologici pur mantenendo inalterato il livello di produttività e qualità (Crookston, 2006; Proffitt et al., 2006; Sayer e Cassman, 2013; Poppe et al., 2015; Oberti et al., 2016; Terribile et al., 2017; Ammoniaci et al., 2021; Sassu et al., 2021; Bramley, 2022; Alexopoulos et al., 2023; Ferro e Catania, 2023). Nello scenario della moderna viticoltura, il flusso di dati estratti dal campo proviene da fonti diverse tra loro. Non ci si riferisce soltanto a dati acquisiti attraverso sensori prossimali o da remoto; ad essere altrettanto eterogenea è la loro natura. Si tratta infatti di informazioni relative a diversi aspetti, che vanno dalla caratterizzazione della fisiologia delle piante, alla natura del contesto pedoclimatico fino a dati relativi alla gestione colturale: concimazione, irrigazione, potatura. Informazioni di georeferenziazione (GPS), immagini RGB o termiche, mappe di vigore acquisite da satellite o da drone (NDVI), firme multispettrali e iperspettrali (NIR, SWIR), misure di assorbanza e/o riflettanza, si aggiungono ad un panorama già assai ricco di altre informazioni legate al comportamento vegeto-produttivo e alle fasi fenologiche della vite o alla qualità delle uve e dei vini. Appare chiaro che, oltre a fornire grandi opportunità di indagine del sistema vigneto, questa abbondanza e diversificazione dei dati pone di fronte l'onere di dover gestire moli di dati spesso non strutturati che, pur avendo un grande valore intrinseco, richiedono di essere analizzate e sintetizzate affinché possano essere utilizzate in maniera proficua per la gestione

agronomica del vigneto. Questi, infatti, se slegati dal contesto o se letti individualmente, danno spesso informazioni assai scarse, difficilmente leggibili, poco legate alla realtà applicativa e che in alcuni casi portano ad errori interpretativi (Sonka, 2016; Balafoutis et al., 2017; Cravero et al., 2018; Santesteban, 2019; Tsai and Lin, 2020; Patel et al., 2021; Mohimont et al., 2022; Morata et al., 2022; Alexopoulos et al., 2023; Poblete-Echeverría and Tardaguila, 2023). Lo scopo dell'analisi di tali dati (chiamati non a caso *Big Data*) è quindi quello di individuare correlazioni, tendenze, pattern che si ripetono secondo schemi più o meno intuitivi, dinamiche di interdipendenza nascoste o comunque non facilmente identificabili, al fine di elaborare modelli simulativi costantemente aggiornati sulla base della biodiversità del panorama viticolo e dei contesti pedoclimatici, che consentano decisioni basate su dati più strettamente connessi alla realtà di campo anziché sulla semplice speculazione empirica o su serie storiche, con relativi vantaggi gestionali.

1.1 Obiettivi del progetto di ricerca e struttura della tesi

Gli obiettivi del progetto di dottorato sono stati quelli di: (i) sviluppare metodologie per l'acquisizione e l'analisi di immagini RGB dal contesto vigneto ed estrarre e analizzare i dati ad esse relativi per meglio comprendere le criticità, i vantaggi e le prospettive applicative di tale tecnologia; (ii) sviluppare modelli per la stima dello stato idrico della vite basati sull'analisi spazio-temporale di dati relativi al sistema pianta-suolo-atmosfera, per acquisire utili informazioni sulla gestione dell'irrigazione; (iii) applicare le metodologie e i modelli di simulazione sviluppati su casi studio reali per valutarne le prestazioni, confrontandoli con metodi esistenti, e analizzando la loro accuratezza nel fornire informazioni per la gestione sostenibile del vigneto.

La prima parte della tesi è dedicata a tre esperimenti condotti in merito all'analisi delle immagini in viticoltura, che affrontano delle topiche cardine di questo tema, ossia la stima del numero di fiori in infiorescenze di vite da vino, la stima del numero di acini in grappoli di uva da tavola e il peso del legno di potatura in vite da vino. Dei tre, solo il secondo è attualmente in fase di pubblicazione, per questo motivo sono stati indicati gli autori, e i grafici presentati sono quelli della versione originale, per cui mantenuti in lingua inglese. La seconda parte è dedicata alla tematica dello stato idrico in vite da vino, ed in particolare all'elaborazione di modelli per la simulazione del potenziale idrico basati su variabili meteorologiche e/o relative al contenuto idrico del suolo; l'esperimento è stato condotto in collaborazione con l'Istituto Superior de Agronomia, Università di Lisbona, Portogallo, nell'ambito del progetto *BioDAgro* - Sistema operativo intelligente di informazione e supporto decisionale in AgroBiodiversità, progetto PD20-00011, promosso dalla *Fundação La Caixa* e dalla *Fundação para a Ciência e a Tecnologia*, in corso presso il C-MAST - Centro per le

Scienze e la Tecnologia Meccanica e Aerospaziale, Dipartimento di Ingegneria Elettromeccanica dell'Università della Beira Interior, Covilhã, Portogallo. In questo caso si tratta di materiale ancora non pubblicato. La terza parte è costituita da una review condotta in collaborazione con l'*Industrial System Institute, Athena Research Center* di Patras (Grecia) e sviluppata come parte del progetto *SUSTAINABLE*, finanziato dall'*European Union's Horizon 2020 research and innovation program (Grant Agreement No. 101007702)* sulla tematica dell'uso complementare della sensoristica da remoto e prossimale nell'ambito dell'agricoltura di precisione e pubblicata su *Agronomy* (2023), 13 (7), 1942, doi: 10.3390/agronomy13071942. Il dottorato di ricerca è stato finanziato dall'Istituto Nazionale della Previdenza Sociale (INPS).

1.2 Riferimenti bibliografici

- Alexopoulos, A., Koutras, K., Ali, S. B., Puccio, S., Carella, A., Ottaviano, R., et al. (2023). Complementary Use of Ground-Based Proximal Sensing and Airborne/Spaceborne Remote Sensing Techniques in Precision Agriculture: A Systematic Review. *Agronomy* 13, 1942. doi: 10.3390/agronomy13071942.
- Ammoniaci, M., Kartsiotis, S.-P., Perria, R., e Storchi, P. (2021). State of the Art of Monitoring Technologies and Data Processing for Precision Viticulture. *Agriculture* 11, 201. doi: 10.3390/agriculture11030201.
- Balafoutis, A. T., Beck, B., Fountas, S., Tsiropoulos, Z., Vangeyte, J., van der Wal, T., et al. (2017). "Smart Farming Technologies – Description, Taxonomy and Economic Impact," in *Precision Agriculture: Technology and Economic Perspectives*, eds. S. M. Pedersen and K. M. Lind (Cham: Springer International Publishing), 21–77. doi: 10.1007/978-3-319-68715-5_2.
- Bramley, R. G. V. (2022). "12 - Precision Viticulture: Managing vineyard variability for improved quality outcomes," in *Managing Wine Quality (Second Edition)*, ed. A. G. Reynolds (Woodhead Publishing), 541–586. doi: 10.1016/B978-0-08-102067-8.00002-6.
- Cravero, A., Lagos, D., and Espinosa, R. (2018). Big Data / IoT Use in Wine Production: A Systematic Mapping Study. *IEEE Lat. Am. Trans.* 16, 1476–1484. doi: 10.1109/TLA.2018.8408444.
- Crookston, R. K. (2006). A Top 10 List of Developments and Issues Impacting Crop Management and Ecology During the Past 50 Years. *Crop Sci.* 46, 2253–2262. doi: 10.2135/cropsci2005.11.0416gas.
- Ferro, M. V., and Catania, P. (2023). Technologies and Innovative Methods for Precision Viticulture: A Comprehensive Review. *Horticulturae* 9, 399. doi: 10.3390/horticulturae9030399.
- Fraga, H. (2019). Viticulture and Winemaking under Climate Change. *Agronomy* 9, 783. doi: 10.3390/agronomy9120783.
- Fraga, H., Malheiro, A. C., Moutinho-Pereira, J., and Santos, J. A. (2012). An overview of climate change impacts on European viticulture. *Food Energy Secur.* 1, 94–110. doi: 10.1002/fes3.14.
- Jones, G. V., and Webb, L. B. (2010). Climate Change, Viticulture, and Wine: Challenges and Opportunities. *J. Wine Res.* 21, 103–106. doi: 10.1080/09571264.2010.530091.
- Mohimont, L., Alin, F., Rondeau, M., Gaveau, N., and Steffemel, L. A. (2022). Computer Vision and Deep Learning for Precision Viticulture. *Agronomy* 12, 2463. doi: 10.3390/agronomy12102463.
- Morata, A., Loira, I., and González, C. (2022). *Grapes and Wine*. BoD – Books on Demand. IntechOpen. doi: 10.5772/intechopen.95210.

- Oberti, R., Marchi, M., Tirelli, P., Calcante, A., Iriti, M., Tona, E., et al. (2016). Selective spraying of grapevines for disease control using a modular agricultural robot. *Biosyst. Eng.* 146, 203–215. doi: 10.1016/j.biosystemseng.2015.12.004.
- Patel, J., Patel, R., Shah, S., and Patel, J. A. (2021). Big Data Analytics for Advanced Viticulture. *Scalable Comput. Pract. Exp.* 22, 302–312. doi: 10.12694/scpe.v22i3.1856.
- Poblete-Echeverría, C., and Tardaguila, J. (2023). “Digital Technologies: Smart Applications in Viticulture,” in *Encyclopedia of Digital Agricultural Technologies*, ed. Q. Zhang (Cham: Springer International Publishing), 336–348. doi: 10.1007/978-3-031-24861-0_206.
- Poppe, K., Wolfert, S., Verdouw, C., and Renwick, A. (2015). “A European Perspective on the Economics of Big Data,” 11–19. *Farm Policy J.*, 12 (1), 11-19
- Proffitt, T., Bramley, R., Lamb, D., and Winter, E. (2006). *Precision Viticulture: A new era in vineyard management and wine production*. Winetitles Pty Ltd. Available at: <https://rune.une.edu.au/web/handle/1959.11/786> (Accessed March 10, 2024).
- Santesteban, L. G. (2019). Precision viticulture and advanced analytics. A short review. *Food Chem.* 279, 58–62. doi: 10.1016/j.foodchem.2018.11.140.
- Santos, J. A., Fraga, H., Malheiro, A. C., Moutinho-Pereira, J., Dinis, L.-T., Correia, C., et al. (2020). A Review of the Potential Climate Change Impacts and Adaptation Options for European Viticulture. *Appl. Sci.* 10, 3092. doi: 10.3390/app10093092.
- Sassu, A., Gambella, F., Ghiani, L., Mercenaro, L., Caria, M., and Pazzona, A. L. (2021). Advances in Unmanned Aerial System Remote Sensing for Precision Viticulture. *Sensors* 21, 956. doi: 10.3390/s21030956.
- Sayer, J., and Cassman, K. G. (2013). Agricultural innovation to protect the environment. *Proc. Natl. Acad. Sci.* 110, 8345–8348. doi: 10.1073/pnas.1208054110.
- Sonka, S. (2016). Big Data: Fueling the Next Evolution of Agricultural Innovation. *J. Innov. Manag.* 4, 114–136. doi: 10.24840/2183-0606_004.001_0008.
- Terribile, F., Bonfante, A., D’Antonio, A., De Mascellis, R., De Michele, C., Langella, G., et al. (2017). A geospatial decision support system for supporting quality viticulture at the landscape scale. *Comput. Electron. Agric.* 140, 88–102. doi: 10.1016/j.compag.2017.05.028.
- Tsai, Y.-L. S., and Lin, S.-Y. (2020). Big climate data assessment of viticultural conditions for wine quality determination in France. *OENO One* 54, 699–717. doi: 10.20870/oeno-one.2020.54.4.3563.
- Urretavizcaya, I., Miranda, C., Royo, J. b., and Santesteban, L. g. (2015). “Within-vineyard zone delineation in an area with diversity of training systems and plant spacing using parameters of vegetative growth and crop load,” in *Precision agriculture '15*, (Wageningen Academic Publishers), 479–486. doi: 10.3920/978-90-8686-814-8_59.
- van Leeuwen, C., Destrac-Irvine, A., Dubernet, M., Duchêne, E., Gowdy, M., Marguerit, E., et al. (2019). An Update on the Impact of Climate Change in Viticulture and Potential Adaptations. *Agronomy* 9, 514. doi: 10.3390/agronomy9090514.

2 L'analisi d'immagini RGB in viticoltura

La complessità precedentemente descritta, che dal punto di vista pratico prende il nome di viticoltura di precisione (PV), è una metodologia di gestione del vigneto che mira ad ottimizzare la resa della coltura, la qualità delle uve e i costi di produzione, considerando alla base la salvaguardia degli equilibri ambientali (Matese e Di Gennaro, 2015; Pérez-Expósito et al., 2017; Santesteban, 2019). Recentemente si è assistito a una parziale automazione di alcuni processi inerenti alla gestione del sistema vigneto grazie a progressi scientifici e tecnologici. Sono state esplorate diverse tecnologie, come droni o veicoli da terra attrezzati di telecamere RGB, termiche e spettrali, che consentono la rilevazione dello stato idrico e fitosanitario o il vigore delle piante (Matese e Di Gennaro, 2015, 2018). Inoltre, sono stati sperimentati robot dedicati alla viticoltura che permettono di svolgere varie azioni sul campo, come la potatura, la fertilizzazione, il controllo della flora spontanea (Keresztes et al., 2014; Kicherer et al., 2015; Pilli et al., 2015; Botterill et al., 2017; Kicherer et al., 2017a; Kurtser et al., 2020; Lopez-Castro et al., 2020). Con l'avvento di fotocamere digitali accessibili a basso costo e dell'intelligenza artificiale abbinata all'evoluzione delle tecniche di elaborazione delle immagini, si è resa possibile l'ipotesi di un'automazione di compiti necessari ma, fino ad oggi, legati a metodi distruttivi e dispendiosi in termini di manodopera e tempo, come la stima delle rese e del vigore (Aquino et al., 2015, 2018; Kicherer et al., 2017b; Millan et al., 2017; Victorino et al., 2020; Fernandes et al., 2021; Lopes and Cadima, 2021). Questo può essere fatto attraverso approcci di *Computer Vision* che abbinano tecniche classiche di analisi delle immagini RGB a tecniche di *Machine Learning* (ML), che consentono di analizzare le immagini con l'ausilio di modelli matematici (Seng et al., 2018; Mohimont et al., 2022a). La *Computer Vision* nel campo della viticoltura si riferisce quindi ad algoritmi di intelligenza artificiale progettati per estrarre informazioni utili da immagini o video (Mohimont et al., 2022a). Gli algoritmi di elaborazione delle immagini operano direttamente sui *pixel*, ossia l'unità minima di superficie di un'immagine digitale, attraverso regole sviluppate e scelte dalla componente umana e attraverso una scelta preventiva delle modalità d'acquisizione in relazione alla scena. Ciò è reso necessario dal fatto che le immagini naturali estratte dal contesto vigneto contengono scene troppo complesse per essere efficacemente processate in maniera completamente automatica. Una prima complessità è data dalle dimensioni delle moderne immagini ad alta risoluzione, le quali contengono tante informazioni, ma il più delle quali risultano superflue per gli obiettivi preposti. Una soluzione è l'applicazione di vincoli all'ambiente di acquisizione dell'immagine utilizzando sfondi artificiali, illuminazione artificiale o operando preventivamente sulle piante per mettere in evidenza le regioni d'interesse (ROI), ossia l'oggetto dell'analisi (e.g. grappoli, infiorescenze) (Barriguinha et al., 2021; Laurent et al., 2021). A

valle di ciò uno strumento utile è il ML, che attraverso l'uso di algoritmi che possono risolvere compiti inerenti all'analisi della complessità dell'immagine senza l'ausilio della componente manuale. Generalmente, tali algoritmi seguono una struttura costituita da tre fasi principali: pre-elaborazione dell'immagine per rendere più semplici le fasi successive, estrazione della ROI, infine post-elaborazione per l'ottenimento dell'output, ossia il dato utile. Il secondo passaggio può essere portato a termine attraverso una delle seguenti tecniche: classificazione delle immagini, rilevamento degli oggetti all'interno dell'immagine o segmentazione, ossia discriminazione dei pixel secondo specifiche caratteristiche (Mohimont et al., 2022a). Molti algoritmi di ML sono disponibili in quanto implementati per applicazioni non inerenti all'agricoltura e alla viticoltura, ma non possono essere applicati direttamente alle immagini senza uno studio della complessità e delle criticità che ciò comporta. Le tecniche di elaborazione delle immagini classiche e di ML sono state sperimentate per diverse applicazioni viticole, ma presentano limitazioni legate alla necessità di selezionare attentamente gli algoritmi appropriati per l'estrazione delle informazioni, il rilevamento delle forme e la loro classificazione, nonché la già menzionata necessità di un controllo parziale dell'ambiente con uno sfondo artificiale o illuminazione artificiale (Aquino et al., 2015; Liu et al., 2020). Un nuovo approccio sperimentato in tempi recenti è quello che utilizza il *Deep Learning* (DL), ovvero reti neurali a più livelli, e che sembra essere più robusto nel discriminare la suddetta complessità dell'ambiente naturale (Kamilaris and Prenafeta-Boldú, 2018; Gikunda and Jouandeu, 2019). Tuttavia, il DL richiede una grande quantità di dati per essere addestrato ed elevate potenze di calcolo. La ricerca in questo campo, com'è stato evidenziato, potrebbe beneficiare di miglioramenti come la standardizzazione delle modalità e delle metriche d'acquisizione o l'aggiunta di nuovi predittori legati a forma e dimensione delle componenti oggetto d'indagine (Kicherer et al., 2017b; Aquino et al., 2018; Liu et al., 2018; Mohimont et al., 2022b).

2.1 Riferimenti bibliografici

- Aquino, A., Millan, B., Diago, M.-P., and Tardaguila, J. (2018). Automated early yield prediction in vineyards from on-the-go image acquisition. *Comput. Electron. Agric.* 144, 26–36. doi: 10.1016/j.compag.2017.11.026.
- Aquino, A., Millan, B., Gaston, D., Diago, M.-P., and Tardaguila, J. (2015). vitisFlower®: Development and Testing of a Novel Android-Smartphone Application for Assessing the Number of Grapevine Flowers per Inflorescence Using Artificial Vision Techniques. *Sensors* 15, 21204–21218. doi: 10.3390/s150921204.
- Barriguiha, A., de Castro Neto, M., and Gil, A. (2021). Vineyard yield estimation, prediction, and forecasting: A systematic literature review. *Agronomy* 11, 1789.
- Botterill, T., Paulin, S., Green, R., Williams, S., Lin, J., Saxton, V., et al. (2017). A Robot System for Pruning Grape Vines. *J. Field Robot.* 34, 1100–1122. doi: 10.1002/rob.21680.

- Fernandes, M., Scaldaferrì, A., Fiameni, G., Teng, T., Gatti, M., Poni, S., et al. (2021). Grapevine Winter Pruning Automation: On Potential Pruning Points Detection through 2D Plant Modeling using Grapevine Segmentation., in *2021 IEEE 11th Annual International Conference on CYBER Technology in Automation, Control, and Intelligent Systems (CYBER)*, 13–18. doi: 10.1109/CYBER53097.2021.9588303.
- Gikunda, P. K., and Jouandeau, N. (2019). State-of-the-art convolutional neural networks for smart farms: A review., *Intelligent Computing: Proceedings of the 2019 Computing Conference*. Springer International Publishing., 1, 763–775.
- Kamilaris, A., and Prenafeta-Boldú, F. X. (2018). Deep learning in agriculture: A survey. *Comput. Electron. Agric.* 147, 70–90.
- Keresztes, B., Grenier, G., Germain, C., Da Costa, J., and Beaulieu, X. (2014). VVINNER: An autonomous robot for automated scoring of vineyards. *Proceedings of the International Conference of Agricultural Engineering, Zurich, Switzerland*. 6-10.
- Kicherer, A., Herzog, K., Pflanz, M., Wieland, M., Rüger, P., Kecke, S., et al. (2015). An automated field phenotyping pipeline for application in grapevine research. *Sensors* 15, 4823–4836.
- Kicherer, A., Herzog, K., Bendel, N., Klück, H.-C., Backhaus, A., Wieland, M., et al. (2017a). Phenoliner: a new field phenotyping platform for grapevine research. *Sensors* 17, 1625.
- Kicherer, A., Klodt, M., Sharifzadeh, S., Cremers, D., Töpfer, R., and Herzog, K. (2017b). Automatic image-based determination of pruning mass as a determinant for yield potential in grapevine management and breeding. *Aust. J. Grape Wine Res.* 23, 120–124. doi: 10.1111/ajgw.12243.
- Kurtser, P., Ringdahl, O., Rotstein, N., Berenstein, R., and Edan, Y. (2020). In-field grape cluster size assessment for vine yield estimation using a mobile robot and a consumer level RGB-D camera. *IEEE Robot. Autom. Lett.* 5, 2031–2038.
- Laurent, C., Oger, B., Taylor, J. A., Scholasch, T., Metay, A., and Tisseyre, B. (2021). A review of the issues, methods and perspectives for yield estimation, prediction and forecasting in viticulture. *Eur. J. Agron.* 130, 126339.
- Liu, S., Li, X., Wu, H., Xin, B., Tang, J., Petrie, P. R., et al. (2018). A robust automated flower estimation system for grape vines. *Biosyst. Eng.* 172, 110–123.
- Liu, S., Zeng, X., and Whitty, M. (2020). A vision-based robust grape berry counting algorithm for fast calibration-free bunch weight estimation in the field. *Comput. Electron. Agric.* 173, 105360. doi: 10.1016/j.compag.2020.105360.
- Lopes, C. M., and Cadima, J. (2021). Grapevine bunch weight estimation using image-based features: comparing the predictive performance of number of visible berries and bunch area. *Oeno One.* 4, 209-226. doi: 10.20870/oenone.2021.55.4.4741.
- Lopez-Castro, A., Marroquin-Jacobo, A., Soto-Amador, A., Padilla-Davila, E., Lopez-Leyva, J. A., and Castañeda-Ramos, M. O. (2020). Design of a vineyard terrestrial robot for multiple applications as part of the innovation of process and product: preliminary results., *International Conference on Engineering Veracruz (ICEV)*, 1–4.
- Matese, A., and Di Gennaro, S. F. (2015). Technology in precision viticulture: A state of the art review. *Int. J. Wine Res.* 7, 69–81.
- Matese, A., and Di Gennaro, S. F. (2018). Practical Applications of a Multisensor UAV Platform Based on Multispectral, Thermal and RGB High Resolution Images in Precision Viticulture. *Agriculture* 8, 116. doi: 10.3390/agriculture8070116.
- Millan, B., Aquino, A., Diago, M. P., and Tardaguila, J. (2017). Image analysis-based modelling for flower number estimation in grapevine. *J. Sci. Food Agric.* 97, 784–792. doi: 10.1002/jsfa.7797.
- Mohimont, L., Alin, F., Rondeau, M., Gaveau, N., and Steffanel, L. A. (2022a). Computer vision and deep learning for precision viticulture. *Agronomy* 12, 2463.

Mohimont, L., Alin, F., Rondeau, M., Gaveau, N., and Steffanel, L. A. (2022b). Computer Vision and Deep Learning for Precision Viticulture. *Agronomy* 12, 2463. doi: 10.3390/agronomy12102463

Pérez-Expósito, J. P., Fernández-Caramés, T. M., Fraga-Lamas, P., and Castedo, L. (2017). VineSens: An eco-smart decision-support viticulture system. *Sensors* 17, 465.

Pilli, S. K., Nallathambi, B., George, S. J., and Diwanji, V. (2015). eAGROBOT—A robot for early crop disease detection using image processing., 2nd International Conference on Electronics and Communication Systems (ICECS) (pp. 1684-1689), 1684–1689.

Santesteban, L. G. (2019). Precision viticulture and advanced analytics. A short review. *Food Chem.* 279, 58–62. doi: 10.1016/j.foodchem.2018.11.140.

Seng, K. P., Ang, L.-M., Schmidtke, L. M., and Rogiers, S. Y. (2018). Computer vision and machine learning for viticulture technology. *Access* 6, 67494–67510.

Victorino, G., Braga, R., Santos-Victor, J., and Lopes, C. M. (2020). Yield components detection and image-based indicators for non-invasive grapevine yield prediction at different phenological phases. *OENO One*. 54 (4), 833-848 doi: 10.20870/oeno-one.2020.54.4.3616

3 Stima del numero di fiori e previsione di componenti della resa in *Vitis vinifera* L. tramite analisi di immagini RGB

La possibilità di stimare la resa di un vigneto in maniera accurata è un vantaggio da tenere in grande considerazione. Specie laddove questo è fatto precocemente, può consentire di regolare quantità e qualità dell'uva prodotta in relazione agli obiettivi enologici e, qualora presenti, ai limiti imposti dai disciplinari di produzione, nonché garantire una corretta organizzazione della logistica di cantina (Kliewer e Casteel, 2003; Dunn e Martin, 2004; Kliewer e Dokoozlian, 2005). Accanto a questi fattori, inoltre, conoscere la quantità di uva prodotta in maniera anticipata può essere un'utilissima informazione nella gestione delle operazioni colturali quali potatura in verde, diradamento, concimazione e irrigazione (Howell, 2001). I metodi utilizzati tradizionalmente per la stima di produzione in vigneto sono basati su metodi distruttivi e manuali, che chiaramente limitano l'applicazione ad un numero ristretto di campioni (siano essi infiorescenze per il conteggio del numero di fiori o di grappoli per peso e numero di acini) (Lopes et al., 2021). Per questo motivo, ad oggi, uno degli obiettivi che si pone la viticoltura di precisione è proprio la messa a punto di strumenti economici, non distruttivi e il più possibile precisi per il raggiungimento di tale obiettivo. In letteratura sono riportati diversi studi sulla stima delle rese attraverso l'analisi di immagini basati sul conteggio del numero di grappoli per pianta (Liu and Whitty, 2015), sul conteggio dei germogli due settimane dopo il germogliamento (Liu, 2017), sul conteggio degli acini da grappoli (Aquino et al., 2018; Millan et al., 2018) o approcci basati sul conteggio combinato di germogli, infiorescenze e grappoli in differenti stadi fenologici (Victorino et al., 2020). Tuttavia, l'ottenimento di informazioni precoci riferito al numero di fiori per infiorescenza risulterebbe un vantaggio maggiore, sia perché al numero di fiori sono connesse più componenti che caratterizzano il grappolo (oltre a numero di acini e peso del grappolo, infatti, può essere monitorata la percentuale di allegagione), sia perché si può disporre di un tempo maggiore per programmare le operazioni colturali a ciò connesse (Howell, 2001; May, 2004). È noto inoltre che, se il 65% circa della variabilità annuale del peso di uva prodotta sia dovuto al numero di grappoli (componente della resa che comunque viene scelta in fase di potatura invernale), approssimativamente un buon 35% di questa dipende invece dal numero di acini per grappolo, numero ovviamente strettamente connesso al numero di fiori (Clingeffer e Krstic, 2003; Clingeffer, 2010). Per ovviare al problema della conta manuale dei singoli bottoni fiorali dell'intera infiorescenza, alcuni metodi alternativi sono stati proposti nel corso degli anni, come la conta manuale dei fiori nella prima ala dell'infiorescenza (Bennett et al., 2005) o la conta manuale del numero di ali nelle infiorescenze (Dunn and Martin, 2007), o ancora la conta manuale dei fiori visibili a partire da immagini delle infiorescenze stampate su carta (Poni et al., 2006), ma rimangono comunque metodi distruttivi e/o laboriosi che limitano

l'applicazione ad un numero comunque ristretto di infiorescenze. Alcuni autori hanno messo in luce come la stima del numero di fiori visibili attraverso l'analisi computerizzata di immagini sia possibile: Diago et al., (2014), hanno proposto una metodologia, poi applicata da Aquino et al., (2015a) nello sviluppo di un'applicazione per dispositivo mobile, che consiste nella segmentazione di immagini di infiorescenze acquisite manualmente *ex-vivo* e basata sull'applicazione della funzione *H-maxima transform*. Questa, sfruttando la maggiore riflessione della luce da parte dei bottoni floreali visibili rispetto agli altri elementi dell'immagine, ha permesso di misurare i punti di massima luminosità e contarli automaticamente per metterli in correlazione col numero effettivo di fiori. Sulla base dello stesso principio Aquino et al., (2015b), hanno sviluppato un algoritmo basato su analisi morfologiche dell'immagine e scomposizione piramidale in grado di operare senza l'ausilio sfondi artificiali su foto acquisite in vigneto. Altri autori hanno poi sviluppato differenti modelli che includono approcci multi-cultivar e modelli a più fattori: Millan et al., (2017) ne hanno presentati alcuni lineari a un fattore e non- multifattore per la stima del peso del grappolo a partire dal numero di fiori visibili (includendo nel modello il peso medio noto dell'acino). Lo stesso algoritmo è stato sfruttato da Palacios et al., (2020), i quali lo hanno applicato per l'analisi di immagini acquisite *on-the-go* con lo scopo di stimare anche la resa per pianta. Liu et al., (2018), hanno attuato un approccio diverso, applicando a diversi stadi fenologici un metodo che si basa sulla segmentazione dell'immagine dell'infiorescenza a partire da filtri morfologici, con l'obiettivo di isolare i bottoni floreali visibili erodendoli dal resto degli elementi dell'immagine attraverso l'algoritmo *Watershed*. Similmente hanno operato Benmehaia et al., (2016) su infiorescenze di uva da tavola. Tello et al., (2020a), hanno studiato la relazione tra numero di fiori e densità dell'infiorescenza, riportando come la modellizzazione per la stima dei fiori beneficerebbe di modelli di regressione multipla che includono tale parametro. In ogni caso tutti gli studi citati in merito all'analisi di immagini si sono concentrati esclusivamente sulla correlazione tra numero di fiori visibili e numero di fiori effettivi. Come evidenziato da Bessis (1960), esiste una relazione lineare tra la lunghezza, la densità dell'infiorescenza e la quantità di fiori. Tale relazione è stata esplorata da Liu et al., (2018); i risultati danno evidenza di come la densità dell'infiorescenza sia un fattore critico nel determinare risultati soddisfacenti in termini di analisi d'immagini, principio suggerito anche dai risultati ottenuti per la stima del numero di acini per grappolo da altri autori (Cubero et al., 2015; Tello et al., 2018; Lopes & Cadima, 2021; Victorino et al., 2022). Giacché il numero di fiori è connesso a tratti morfologici dell'infiorescenza, come la lunghezza della stessa, appare intuibile come ciò determini una certa variabilità in termini di superficie proiettata qualora si consideri l'immagine di un'infiorescenza acquisita attraverso una camera RGB. Ciò considerato,

l'obiettivo del seguente studio è stato quello di: (i) valutare la correlazione tra il numero effettivo di fiori e il numero di pixel (area) afferenti alla superficie proiettata dall'infiorescenza attraverso l'analisi di immagini di infiorescenze acquisite in campo in condizioni di luce naturale e validare il modello su un dataset esterno; (ii) indagare se e come la lunghezza dell'infiorescenza può influenzare la precisione della metodologia di stima elaborata; (iii) valutare l'applicabilità del modello alla stima di componenti della resa come numero di acini e peso dei grappoli nell'ottica della trasferibilità della metodologia su app mobile.

3.1 Materiale e metodi

3.1.1 Disegno sperimentale e acquisizione delle immagini RGB

La prova è stata condotta durante la stagione 2023 presso un vigneto della cultivar Catarratto/1103P (*Vitis vinifera* L.) ubicato a Camporeale (37°55'12,82"N, 13°04'28,33"E; 320 m s.l.m.; Palermo, Italia), nell'areale della D.O.C. Alcamo. Le viti erano allevate a controspalliera con sistema di potatura a cordone speronato bilaterale, irrigate attraverso un sistema d'irrigazione a goccia (portata gocciolatore di 2 L/h; distanza tra i gocciolatori 80 cm) su un terreno franco-argilloso. Le distanze d'impianto erano di 0,9 m sulla fila e 2,2 m tra le file e l'orientamento dei filari nord/est-sud/ovest. La gestione fitosanitaria, della chioma e della concimazione sono state applicate secondo le pratiche viticole standard di un vigneto biologico. Durante la potatura invernale (2022), sulla base del peso del legno asportato, sono state selezionate e contrassegnate 36 piante che presentavano variabilità in termini di vigore e classificate in piante ad alto vigore (HV) e piante a basso vigore (LV) (Fig. 1).




Figura 1. Sito presso il quale è stato condotto lo studio. Contrassegnate in rosso (LV, basso vigore) e in blu (HV, alto vigore) le parcelle costituite da sei piante dalle quali le infiorescenze sono state campionate.

Allo stadio di pre-fioritura (BBCH 55) secondo la scala di Lorenz et al., (1994), su ogni pianta sono state misurate ed etichettate tutte le infiorescenze per un totale di 300 e ad ognuna è stato assegnato un codice univoco per poterla ricondurre successivamente alla pianta d'origine una volta asportato il grappolo. Di ogni infiorescenza è stata misurata la lunghezza dal punto d'inserzione della prima ala all'ultimo bottone florale della porzione distale. Nel caso di prima ala particolarmente pronunciata, la lunghezza dell'infiorescenza è stata acquisita come somma della lunghezza dell'ala e del rachide. Sulla base della lunghezza le infiorescenze sono state suddivise in sei classi: **A**, $L < 6$ cm; **B**, $6 \leq L < 8$ cm; **C**, $8 \leq L < 10$ cm; **D**, $10 \leq L < 12$ cm; **E**, $12 \leq L < 14$ cm; **F**, $L \geq 14$ cm.

L'acquisizione delle immagini è avvenuta allo stadio BBCH 55 in accordo Liu et al., (2018), i quali identificano il suddetto stadio fenologico come il più stabile e adeguato all'acquisizione di immagini di infiorescenze di vite da vino per l'analisi digitale, in quanto la loro forma varia all'avanzare della stagione e all'aumentare della lunghezza, fattore che può modificare la relazione tra quest'ultima e il numero di fiori (Bessis, 1960; May, 2000) (Fig. 2).




Figura 2. Esempio di immagini delle infiorescenze di Catarratto fotografate e analizzate allo stadio fenologico BBCH 55 secondo la scala di Lorenz et al., (1995). Il segmento nero (3 cm) rappresenta la scala di conversione cm/pixel. Si notino la variabilità in termini di forma e dimensione delle infiorescenze nonché di condizioni incontrollate di illuminazione della scena, le quali possono influire sul risultato della segmentazione delle immagini.

Le immagini sono state acquisite in campo, tra le 08:00 e le 14:00 del mattino, in condizioni di illuminazione variabile e non controllata, utilizzando un foglio di cartoncino bianco dietro le infiorescenze per l'omogeneizzazione dello sfondo. Il dispositivo usato per l'acquisizione era la fotocamera di un comune smartphone (Sony Xperia 1 VI, SONY, Giappone). Le impostazioni della fotocamera erano quelle automatiche di default (apertura f/1,8 e lunghezza focale 26 mm), non è stato utilizzato il flash. Le infiorescenze sono state fotografate secondo un asse ortogonale da una distanza di 20 cm misurati servendosi di una riga graduata come riferimento. Successivamente, ogni infiorescenza è stata coperta da una rete di tessuto tulle (Fig. 3). Questa è stata rimossa dopo la completa fioritura ed è stato effettuato il conteggio manuale delle caliptrite distaccate, necessario per la validazione dell'analisi. Con le medesime modalità e nelle medesime condizioni descritte, per effettuare una validazione esterna del modello, ossia valutare la precisione di stima se applicato su dati estratti da immagini provenienti da un dataset sul quale il modello non è stato addestrato, sono state acquisite in maniera casuale le immagini di ulteriori 70 infiorescenze di Catarratto da piante contigue a quelle contrassegnate. In più, ci si è serviti anche di un dataset di immagini acquisite precedentemente con le medesime modalità in vigneto (*in-vivo*) o in laboratorio (*ex-vivo*), delle cultivar Chardonnay (48 immagini di infiorescenze *in-vivo* e 62 *ex-vivo*) e della cultivar Vermentino (34 immagini di infiorescenze *ex-vivo*). Di queste è stato determinato esclusivamente il numero di bottoni fiorali attraverso conta manuale.



Figura 3 Esempio del tessuto con il quale sono state coperte le infiorescenze dopo l’acquisizione delle immagini fino alla completa fioritura per permettere la raccolta e il conteggio delle calipre distaccate.

3.1.2 Rilievo delle componenti della resa

In prossimità della vendemmia, le 36 piante di Catarratto contrassegnate sulle quali erano state etichettate le infiorescenze (poi grappoli) sono state vendemmiate manualmente. Il peso complessivo dei grappoli è stato misurato tramite un dinamometro digitale (GC-60, LCD s.r.l., Italia). Questi sono stati trasportati in laboratorio, dove è stato misurato singolarmente il loro peso (bilancia tecnica Gibertini, EU-C7500PT) e contato il relativo numero di acini. La percentuale di allegazione per ogni pianta è stata calcolata in accordo con Palacios et al., (2020) come:

$$\% All. = \frac{\sum A_g}{\sum F_i} * 100 \quad (1)$$

dove A_g rappresenta il numero di acini per grappolo e F_i il numero fiori per infiorescenza.

È stato infine calcolato l’indice di compattezza di ogni infiorescenza come rapporto tra il numero di fiori e la lunghezza della stessa.

3.1.3 Analisi delle immagini

Tutte le immagini sono state pre-processate e analizzate utilizzando il software open-source FIJI/ImageJ® (Schindelin et al., 2012). Ogni immagine, della risoluzione di 1536 x 2048 pixel, è stata preliminarmente convertita in scala di grigi (8-bit) per ridurre la quantità di informazioni relative al colore in esse presenti (256 valori possibili) e permetterne la segmentazione (*Image > Type > 8-Bit*). Successivamente, è stata estratta la *Region of Interest* (ROI) dall'immagine, ossia l'infiorescenza, mediante la sogliatura automatica dell'immagine utilizzando il metodo di Otsu (Otsu, 1975; Otsu, 1979), attraverso la seguente equazione:

$$ROI = \begin{cases} 0 & \text{if } I_b(x, y) \leq T_{otsu} \\ 255 & \text{otherwise} \end{cases} \quad (2)$$

Dove T_{otsu} è la soglia ottimale per la quale, se si assume l'esistenza di sole due classi di pixel all'interno dell'immagine (una relativa allo sfondo e una al primo piano), si cerca di trovare la soglia ottimale che massimizza la varianza tra le due classi. I_b rappresenta l'immagine 8-bit come funzione bidimensionale nello spazio discreto i cui valori rientrano nell'intervallo $[0, \dots, 255]$. In questo modo è stata ottenuta un'immagine binaria (0 = bianco e 255 = nero) contenente solo la ROI e i pixel dello sfondo (*Image > Adjust > Auto Threshold > Otsu*). Nessun parametro relativo al metodo di Otsu è stato impostato manualmente. Il numero di pixel della ROI è stato quindi conteggiato (*Analyze > Measure*). Il diagramma di flusso relativo all'analisi delle immagini può essere riassunto dalla sequenza rappresentata in figura 4.




Figura 4 Diagramma di flusso dei principali passaggi dell'analisi. **a**, immagine originale; **b**, immagine convertita in scala di grigi (8-bit); **c**, immagine segmentata e binarizzata attraverso il metodo di Otsu (1975). Infiorescenza della cv Catarratto.

3.1.4 Analisi statistica

I dati ottenuti sono stati analizzati utilizzando il software statistico Minitab[®] versione 19 (Minitab, USA). La distribuzione delle infiorescenze in termini di lunghezza è stata valutata attraverso il test della normalità di Shapiro-Wilk considerato significativo per $P \leq 0,05$. Le correlazioni tra il numero di fiori contato manualmente, il numero di pixel relativo alle infiorescenze ottenuto attraverso la segmentazione delle immagini e la lunghezza delle infiorescenze sono state valutate attraverso modelli di regressione lineare e polinomiale e i relativi coefficienti di determinazione (R^2) considerati significativi per $P \leq 0,01$. Per la valutazione dell'errore del modello di stima del numero fiori sono stati calcolati il *Root Mean Square Error* (RMSE) e il *Mean Absolute Percentage Error* (MAPE) in accordo con Paulus et al., (2014) attraverso le seguenti formule:

$$RMSE = \sqrt{\text{mean}(t - a)^2} \quad (3)$$

$$MAPE = \text{mean} \left(\left| \frac{t-a}{t} * 100 \right| \right) \quad (4)$$

Dove t (*target*) è il valore di riferimento, a (*actual*) il valore stimato.

Il numero di fiori stimato attraverso l'equazione della retta di regressione, cumulato per la relativa pianta, è stato correlato al numero di acini e al peso dei grappoli cumulato della stessa pianta utilizzando un modello di regressione lineare, e il relativo coefficiente di determinazione (R^2) considerato significativo per $P \leq 0,01$, similmente a quanto riportato da Palacios et al., (2020) per la stima del numero di fiori/pianta nell'ottica della stima delle componenti di resa. I parametri relativi alle classi di lunghezza e di vigore sono stati confrontati attraverso l'analisi della varianza (ANOVA) utilizzando il test post-hoc Tukey ($P < 0,05$).

3.2 Risultati

3.2.1 Stima del numero di fiori

Le misurazioni effettuate preliminarmente all'acquisizione delle immagini hanno permesso di valutare come la lunghezza delle infiorescenze seguisse una distribuzione di tipo normale secondo il

test di normalità di Shapiro-Wilk per via di un *P-value* al di sopra del livello considerato significativo (Fig. 5).




Figura 5. Distribuzione della lunghezza delle infiorescenze valutata attraverso il test della normalità di Shapiro–Wilk ($P \leq 0,05$).

Sulla base di ciò sono state determinate sei classi discrete di lunghezza (*L*) che coprissero tale distribuzione in modo che per ogni classe il numero di infiorescenze non fosse al di sotto del 10% del totale. La Tabella 1 mostra le classi di lunghezza, il numero di fiori per infiorescenza medio e l'indice di compattezza medio all'interno delle relative classi.

Tabella 1. Classificazione delle infiorescenze sulla base della lunghezza (*L*). La percentuale (%) è da riferirsi alla rappresentatività della relativa classe sul totale delle infiorescenze campionate ($n = 300$).

Classe di lunghezza	Lunghezza (cm)	%	Fiori (n)	Indice di compattezza
A	$L < 6$	14	$131 \pm 11,3^d$	$32,9 \pm 2,77^{n.s.}$
B	$6 \leq L < 8$	14	$272 \pm 17,9^c$	$38,7 \pm 2,70$
C	$8 \leq L < 10$	18	$287 \pm 11,3^c$	$32,3 \pm 1,30$
D	$10 \leq L < 12$	25	$399 \pm 14,7^b$	$36,4 \pm 1,28$
E	$12 \leq L < 14$	15	$446 \pm 25,0^b$	$34,4 \pm 1,95$
F	$L \geq 14$	13	$552 \pm 29,2^a$	$35,2 \pm 2,00$

Lettere differenti tra le classi indicano differenze statisticamente significative per $P < 0,05$ secondo il test di Tukey. n.s. indica assenza di significatività. Il numero di fiori e l'indice di compattezza dell'infiorescenza sono riportati come media \pm errore standard.

La Figura 6 mostra l'esistenza di una correlazione lineare positiva tra la lunghezza delle infiorescenze e il numero di fiori. Tuttavia, all'interno di ogni classe di lunghezza il relativo numero di fiori varia considerevolmente, con range via via più ampi all'aumentare della lunghezza stessa. Si

passa infatti da un delta di 274 fiori per infiorescenza all'interno della classe **A** fino ad uno di 900 all'interno della classe **F**.

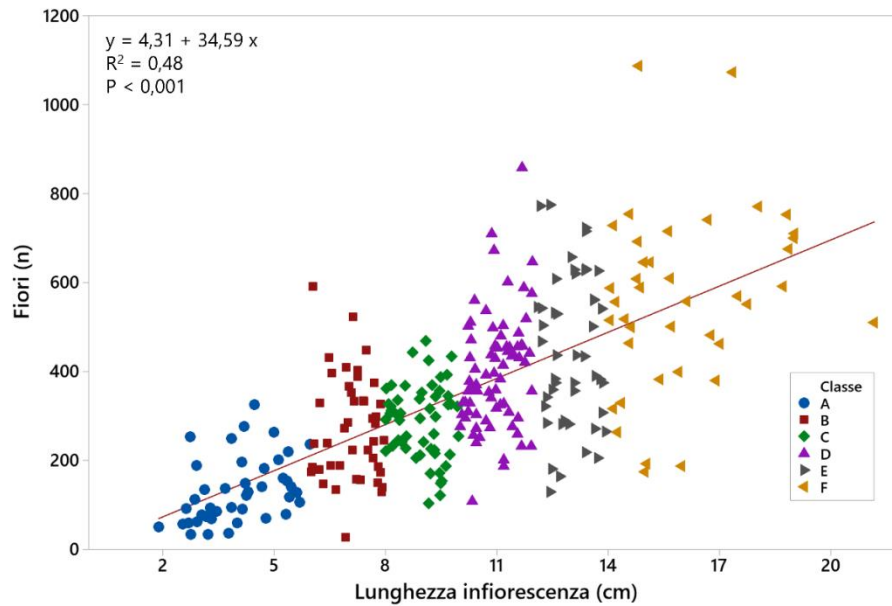


Figura 6 Correlazione tra il numero di fiori contati manualmente e la lunghezza (L) delle infiorescenze misurate manualmente (n=300). **A**, $L < 6$ cm; **B**, $6 \leq L < 8$ cm; **C**, $8 \leq L < 10$ cm; **D**, $10 \leq L < 12$ cm; **E**, $12 \leq L < 14$ cm; **F**, $L \geq 14$ cm.

Tale ipotesi sembrerebbe avallata dal fatto che la correlazione tra numero di pixel e lunghezza dell'infiorescenza, in questo caso di tipo quadratico, presenti un andamento simile (Fig. 7): anche in questo caso, infatti, per una data classe, l'area espressa in numero di pixel estratti varia su range assimilabili ai precedenti. Infiorescenze che all'interno della stessa classe differiscono in lunghezza per un massimo di 2 cm proiettano infatti superfici via via maggiori all'aumentare del numero di fiori.




Figura 7. Correlazione tra la lunghezza dell'infiorescenza (L) e il numero di pixel della *Region of interest* (ROI) nelle infiorescenze analizzate (n=300). **A**, $L < 6$ cm; **B**, $6 \leq L < 8$ cm; **C**, $8 \leq L < 10$ cm; **D**, $10 \leq L < 12$ cm; **E**, $12 \leq L < 14$ cm; **F**, $L \geq 14$ cm.

Se si osserva la regressione tra il numero di pixel della ROI e il numero di fiori contati manualmente per singola infiorescenza (Fig. 8) è evidente che all'aumentare del numero di fiori aumenta linearmente anche il numero di pixel relativi alla ROI. È possibile notare infatti come ad un numero stimato di circa mille fiori corrisponda linearmente un incremento notevole del numero di pixel della ROI estratta. Tuttavia, in quasi tutti i casi di infiorescenze con numero di fiori inferiore al centinaio i punti si trovano sempre al di sotto della linea di regressione. Ciò è probabilmente attribuibile all'influenza maggiore che il rachide ha al diminuire del numero di fiori rispetto l'area totale della ROI che, al contrario, in infiorescenze con numero di fiori più elevato risulta poco influente. Ciò è dovuto alla natura dell'analisi, attraverso la quale si estraggono informazioni da un'immagine bidimensionale di un oggetto che è invece tridimensionale. In più, questo non è di forma regolare, per cui a seconda del piano catturato durante l'acquisizione dell'immagine e dell'asimmetria dell'infiorescenza la percentuale della superficie che rimane nascosta può essere minore o maggiore.

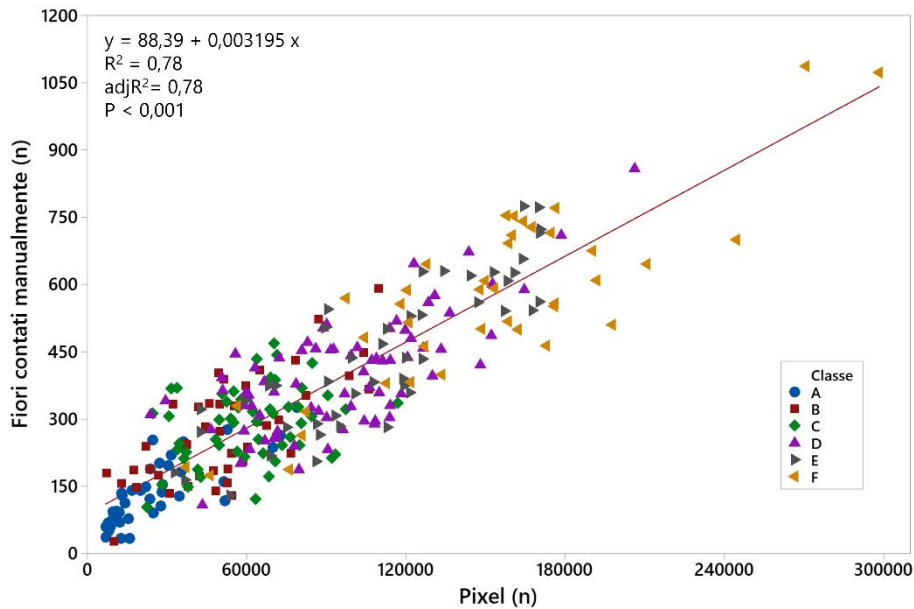


Figura 8. Correlazione tra il numero di fiori contati manualmente e il numero di pixel della Region of interest (ROI) nelle infiorescenze analizzate (n=300). La classe si riferisce alla lunghezza (L) delle infiorescenze. **A**, $L < 6$ cm; **B**, $6 \leq L < 8$ cm; **C**, $8 \leq L < 10$ cm; **D**, $10 \leq L < 12$ cm; **E**, $12 \leq L < 14$ cm; **F**, $L \geq 14$ cm. RMSE = 96,37; MAPE = 29,3%.

Quanto detto appare più chiaro osservando i modelli elaborati per ogni classe di lunghezza (Fig. 9). Si può notare come il valore del coefficiente di determinazione (R^2) sia più basso nella classe **C**. Questa mostra un *P-value* non significativo e un'assenza di correlazione tra le due variabili, dovuto al fatto che tra gli 8 e 9,9 cm la variabilità in termini di numero di fiori è la minore all'interno della popolazione studiata, considerazione confermata dall'errore standard minore di tale parametro e dall'indice di compattezza medio più basso tra tutte le classi (Tab. 1). È possibile osservare inoltre che la percentuale di errore nella stima diminuisca all'aumentare della lunghezza e del numero di fiori, si passa da un MAPE del 58,4% della classe **A**, dove il RMSE è di 55 fiori su una media di 131 ± 73 , a uno del 18,7% della classe **F**, dove il RMSE è di 105 fiori ma su una media ben maggiore di 562 ± 202 fiori (Tab. 2). In sintesi, se si analizzano solo infiorescenze con un numero di fiori poco variabile all'interno dello stesso range di lunghezza, il metodo di stima è influenzato prevalentemente dalla morfologia dell'infiorescenza (simmetria) e dal piano di acquisizione, al contrario, se la variabilità è ampia, la stima del numero di fiori, per quanto approssimativa, risulta buona, come osservabile nelle classi **E** ed **F** e nel modello globale tra le classi (Fig. 8)

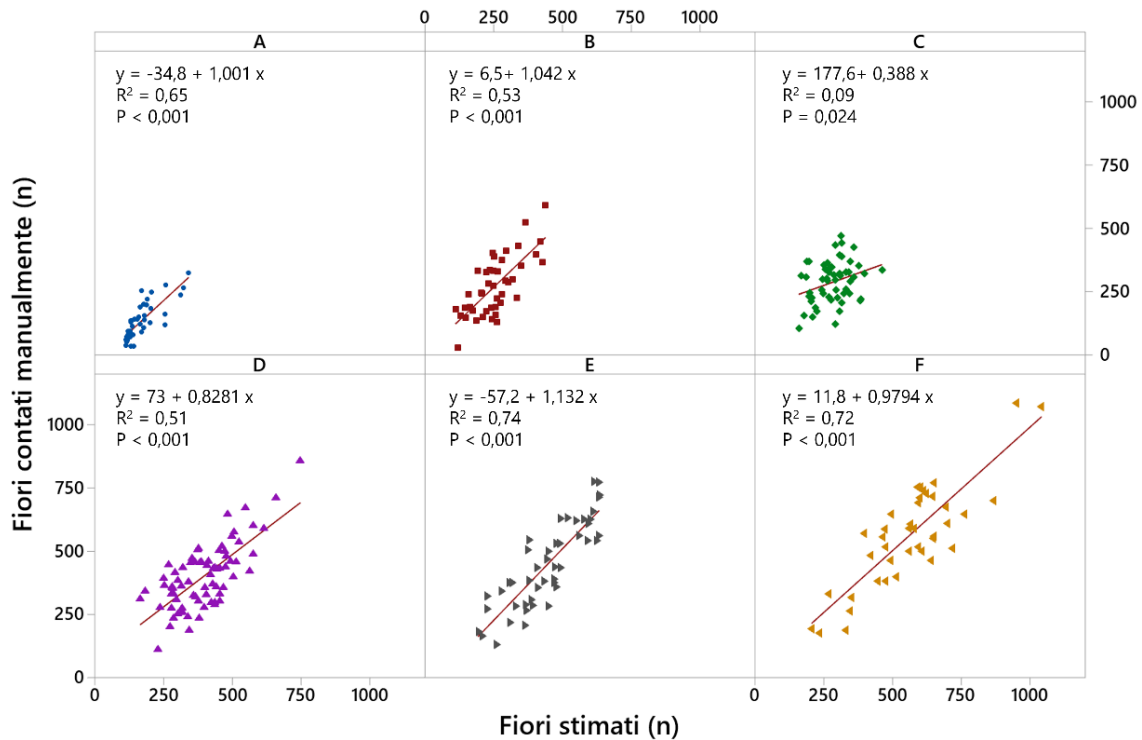


Figura 9. Correlazione tra il numero di fiori contati manualmente e il numero di fiori stimati nelle infiorescenze analizzate all'interno delle singole classi (n=300). **A**, $L < 6$ cm; **B**, $6 \leq L < 8$ cm; **C**, $8 \leq L < 10$ cm; **D**, $10 \leq L < 12$ cm; **E**, $12 \leq L < 14$ cm; **F**, $L \geq 14$ cm.

Tabella 2. Metriche di valutazione dei modelli elaborati sulla base della lunghezza (L) delle infiorescenze (n = 300).

Classe di lunghezza	Fiori (n)	RMSE (n)	MAPE (%)	R ²
A	131 ± 11	55,23	58,4	0,65
B	272 ± 18	81,21	33,8	0,53
C	287 ± 11	87,72	27,4	0,09
D	399 ± 11	90,36	22,5	0,54
E	446 ± 25	87,34	20,8	0,74
F	562 ± 32	104,98	18,7	0,72

RMSE, Root Mean Square Error; MAPE, Mean Absolute Percentage Error. Il numero di fiori è riportato come media ± errore standard.

La validazione del modello sui dataset esterni sembrerebbe confermarne le buone capacità di previsione del numero di fiori (Fig. 10). Sulla stessa cultivar (Catarratto) i risultati ottenuti mostrano una stima del numero di fiori con un MAPE del 20% ed un RMSE di 68 fiori (Tab. 3). Inferiori i risultati ottenuti su cultivar diverse. Nello Chardonnay, sebbene i due dataset abbiano generato R² simili, il dataset acquisito *ex-vivo* mostra un MAPE molto elevato in relazione alla media del campione, mentre più basso è nel dataset acquisito *in-vivo* in cui la media nel numero di fiori si presentava più elevata, risultato coerente con quello ottenuto tra le classi di lunghezza del Catarratto. Nel Vermentino, infine, la precisione della stima è risultata la minore tra tutti i dataset.

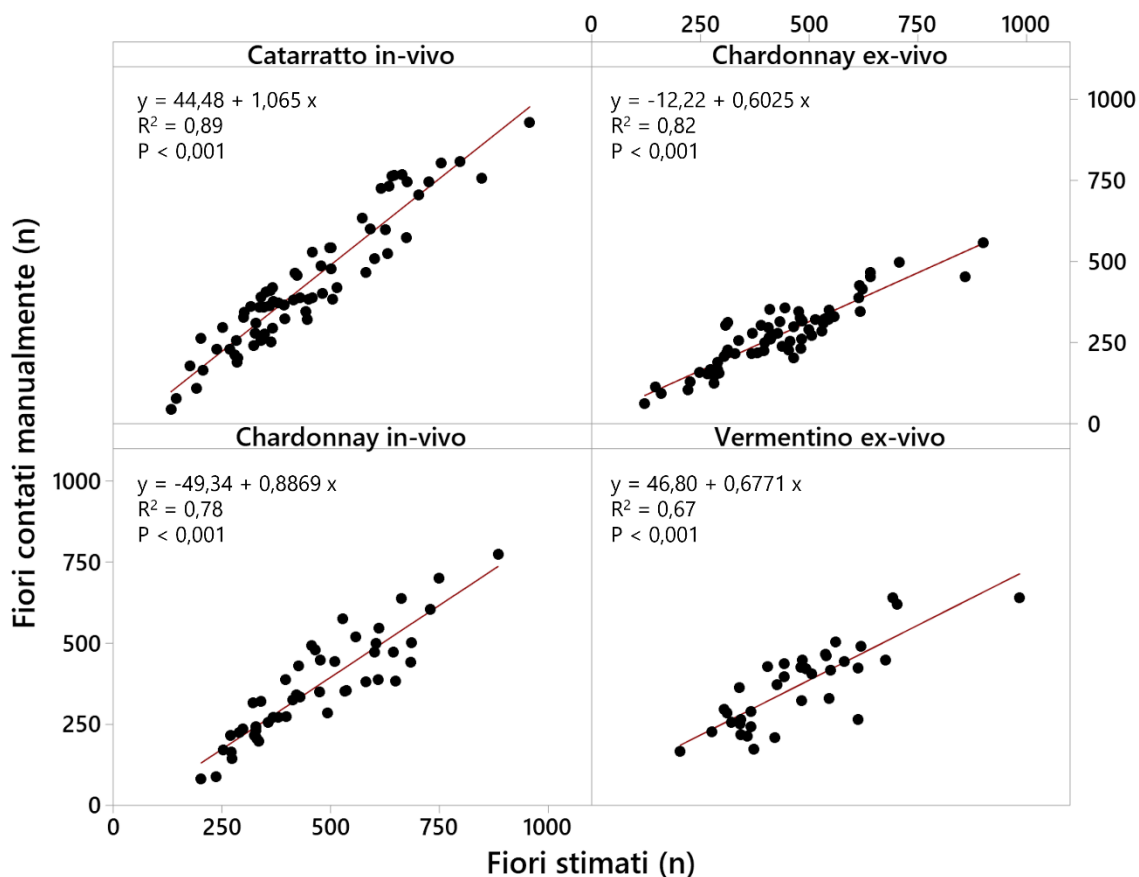


Figura 10. Correlazione tra il numero di fiori contati manualmente e il numero di fiori stimati nelle infiorescenze di Catarratto (n=70) campionate casualmente per la validazione esterna del modello e nelle infiorescenze di Chardonnay analizzate da immagini *in vivo* (n = 48) ed *ex-vivo* (n = 62) e di Vermentino analizzate da immagini *ex-vivo* (n = 34).

Tabella 3. Metriche di valutazione della validazione esterna del modello per la stima del numero di fiori.

Dataset	Fiori (n)	RMSE (n)	MAPE (%)	R ²
Catarratto <i>in-vivo</i>	436 ± 23,42	68,31	20,01	0,89
Chardonnay <i>ex-vivo</i>	269 ± 34,18	175,28	62,73	0,82
Chardonnay <i>in-vivo</i>	359 ± 51,80	123,53	40,42	0,78
Vermentino <i>ex-vivo</i>	367 ± 62,95	136,99	34,23	0,67

RMSE, Root Mean Square Error; MAPE, Mean Absolute Percentage Error. Il numero di fiori è riportato come media ± errore standard.

3.2.2 Stima delle componenti della resa

Il modello globale è stato utilizzato anche per la stima delle componenti della resa su scala pianta. La figura 11 mostra come non ci siano sostanziali differenze nella correlazione tra il numero di pixel e il numero di fiori tra le infiorescenze che sono state campionate da piante classificate come alto vigore (HV) e basso vigore (LV), se non per valori di RMSE e MAPE leggermente inferiori nel basso vigore che comunque vanno letti in funzione dei valori medi del campione, i quali risultano

anch'essi inferiori. Va sottolineato comunque, che la differenza di vigore identificata in fase di potatura invernale, non si è poi manifestata in maniera significativa in termini di componenti della resa (Tab. 4).




Figura 11. Correlazione tra il numero di fiori contati manualmente e il numero di pixel della *Region of interest* (ROI) nelle infiorescenze analizzate (nHV = 169; nLV = 131). La classe si riferisce al vigore delle piante definito sulla base del peso del legno di potatura della stagione 2022. **HV**, alto vigore. **LV**, basso vigore. **HV**: RMSE = 87,46; MAPE = 30,3%. **LV**: RMSE = 84,95; MAPE = 27,9%.

Tabella 4 Peso del legno di potatura misurato nel 2022 e relative componenti della resa della stagione 2023 nelle piante delle due classi di vigore. **HV**, alto vigore (n=18); **LV**, basso vigore (n=18).

Classe di vigore	Peso del legno 2022 (g)	Componenti della resa 2023			
		Fiori (n)	Acini (n)	Allegagione (%)	Massa grappoli (g)
HV	388 ± 39 ^a	2755 ± 387 ^{n.s.}	1109 ± 128 ^{n.s.}	42 ± 2	1115 ± 117 ^{n.s.}
LV	173 ± 11 ^b	2358 ± 319	831 ± 90	37 ± 2	827 ± 102
Totale	280 ± 26	2527 ± 250	957 ± 81	40 ± 2	961 ± 80

Lettere differenti tra le classi indicano differenze statisticamente significative per $P < 0,05$ secondo il test di Tukey. n.s. indica assenza di significatività. I valori sono riportati come media ± errore standard.

Il modello predittivo ha mostrato un buon livello di precisione nello stimare il numero di fiori se questo è relativo al numero di fiori complessivo per pianta (Fig. 12). Ne è risultato un R^2 di 0,95, un RMSE di 349 e un MAPE del 26,7%. Quest'ultimo valore è attribuibile alle due piante che presentavano il più esiguo numero di fiori totale, senza questi due valori, infatti, il MAPE generato scendeva al 12,6%, risultato in linea con quanto discusso in merito alle classi di lunghezza. Per la

stima del numero di acini è stata utilizzata la percentuale di allegagione di ciascuna pianta come fattore di correzione, in accordo con Millan et al., (2017) e Palacios et al., (2020), ottenendo anche in questo caso un buon risultato (Fig. 13). Come si può notare infatti, il MAPE generato era del 13,7%. Risultato soddisfacente ma non altrettanto buono, invece, è stato quello relativo alla stima della massa dei grappoli (Fig. 14). Se per la stima del numero di acini la percentuale di allegagione gioca un ruolo determinante nel determinare la precisione, nel caso della massa dei grappoli è il peso medio dell'acino a spostare gli equilibri, per questo motivo si può ipotizzare che l'utilizzo di questo ulteriore fattore di correzione avrebbe aumentato il livello di precisione, come messo in luce già da Palacios et al., (2020).




Figura 12. Correlazione tra il numero di fiori contati manualmente e il numero di fiori stimati nelle infiorescenze analizzate, cumulato per pianta (n=36). La classe si riferisce al vigore delle piante definito sulla base del peso del legno di potatura della stagione 2022. HV, alto vigore; LV, basso vigore. RMSE = 349,43; MAPE = 26,7%.




Figura 13. Correlazione tra il numero di acini contati manualmente e il numero di acini stimati nei grappoli analizzati cumulato per pianta (n=36). *Il valore stimato è stato corretto sulla base della % di allegazione della relativa pianta. La classe si riferisce al vigore delle piante definito sulla base del peso del legno di potatura della stagione 2022. **HV**, alto vigore; **LV**, basso vigore. RMSE = 117,8; MAPE = 13,7%.

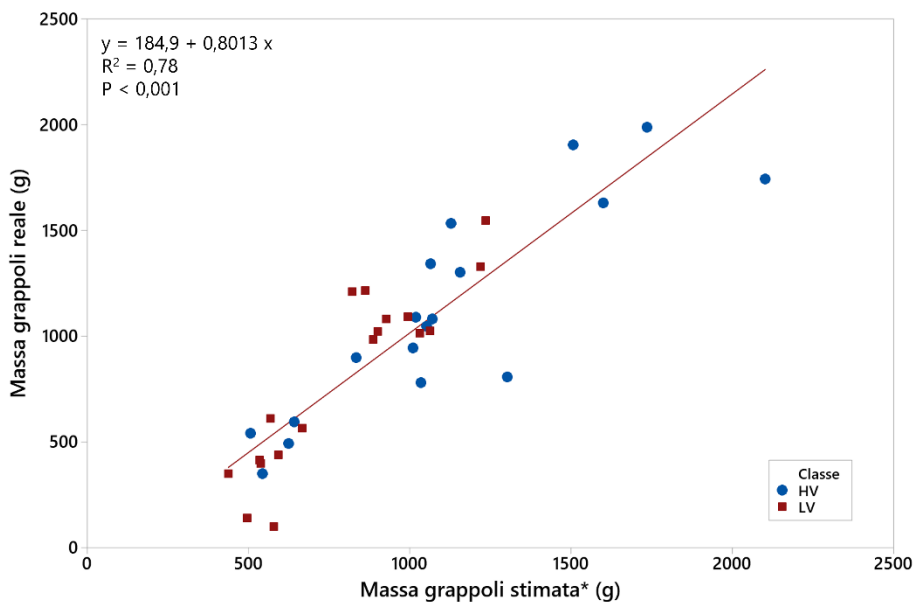


Figura 14. Correlazione tra la massa reale dei grappoli e quella stimata cumulato per pianta (n=36). *Il valore stimato è stato corretto sulla base della % di allegazione della relativa pianta. La classe si riferisce al vigore delle piante definito sulla base del peso del legno di potatura della stagione 2022. **HV**, alto vigore; **LV**, basso vigore. RMSE = 205,8 g; MAPE = 20,3%.

3.3 Discussione

La metodologia più largamente utilizzata ad oggi per la stima del numero di fiori attraverso l'analisi di immagini è riconducibile prevalentemente alla misura dei picchi di massima luminosità che i bottoni floreali presentano rispetto agli altri elementi delle immagini, a causa della loro forma sferoidale (Diago et al., 2014; Aquino et al., 2015a, 2015b; Millan et al., 2017). Tuttavia, questi picchi di luminosità non sono sempre chiaramente visibili o associabili ad un bottone floreale, sia perché un singolo bottone può presentare più di un picco, sia perché la forma di questi non è sempre la stessa (più o meno sferica) e ciò fa variare l'entità della riflessione. Questa problematica è stata già messa in evidenza da Liu et al., (2018), i quali hanno riscontrato nel loro studio come, ad esempio, i bottoni floreali della cultivar Chardonnay in fasi fenologiche precoci non presentano alcun picco di riflessione, mentre nella cultivar Syrah ne sono presenti anche più di due in fasi fenologiche più avanzate. Ciò fa intuire come questo possa variare tra una cultivar e l'altra e in relazione alle condizioni di illuminazione naturale. Liu et al., (2018) hanno superato tale problema utilizzando contestualmente differenti algoritmi, tra cui l'algoritmo *Speeded Up Robust Feature* (SURF), l'algoritmo *Fast Retina Keypoint* (FREAK) e l'algoritmo *Histogram of Oriented Gradients* (HOG), tutti rilevatori di forme utilizzati per il riconoscimento degli oggetti nelle immagini RGB (Dalal and Triggs, 2005; Bay et al., 2008; Alahi et al., 2012). In questo modo, hanno identificato i singoli bottoni floreali dal punto di vista morfologico, non più quindi sfruttando la riflessione della luce. Nel presente studio la metodologia adottata è stata la più semplice finora proposta: le immagini sono state segmentate semplicemente isolando l'intera l'infiorescenza dallo sfondo, e per stimare il numero di fiori totale è stata utilizzata l'area da queste proiettata (ossia il numero di pixel) per la correlazione. Come i risultati hanno mostrato, all'interno della medesima classe, e cioè in un range di circa 2 cm di lunghezza dell'infiorescenza, un aumento del numero di fiori ha determinato un conseguente aumento della superficie proiettata più che proporzionale. Le non significative differenze in termini di compattezza riscontrate tra le classi confrontate allontanano l'idea che la suddetta variabilità possa essere determinata da differenti gradi di densità o dalla dimensione dei singoli bottoni floreali (Tab 1). Ciò ha permesso di evitare la problematica del riconoscimento dei singoli fiori all'interno dell'immagine e la stima di falsi positivi o falsi negativi. Inoltre, i risultati ottenuti da altri autori che hanno utilizzato l'area proiettata dall'infiorescenza in combinazione con la conta dei bottoni floreali visibili per l'elaborazione di modelli a più fattori, fa supporre che una metodologia di stima basata esclusivamente sull'area, come quella presentata, sia applicabile con risultati soddisfacenti (Liu et al., 2018; Tello et al., 2019). Ciò scongiura la presenza di *bias* derivanti dal settaggio manuale di determinati parametri concernenti l'analisi che

caratterizza gran parte dei metodi di stima finora presenti in letteratura, con chiari riflessi positivi sulla replicabilità e sulla trasferibilità. Negli studi sopracitati il numero di fiori è stato stimato correlando questo alla conta dei fiori visibili nell'immagine, senza tenere conto della relazione che il numero di fiori ha con la dimensione dell'infiorescenza (Diago et al., 2014; Aquino et al., 2015a, 2015b; Millan et al., 2017; Palacios et al., 2020). Solo alcuni autori hanno introdotto anche il fattore densità che però è stato incluso in maniera diretta come fattore di modelli di regressione multipla che includevano comunque il numero dei fiori visibili tra gli altri fattori (Liu et al., 2018; Tello et al., 2020a). Il modello presentato è in linea con i modelli presenti in letteratura in termini di precisione (Tab. 5). Va sottolineato però che il confronto tra modelli generati a partire da metodologie differenti, dataset di diversa ampiezza in termini di numero di cultivar, infiorescenze e media della popolazione porta a misinterpretazioni rispetto la bontà dei modelli stessi, specie se questo si basa sul mero paragone degli R^2 . Molti dei modelli proposti, sia lineari mono-fattoriali ma soprattutto multi-fattoriali non lineari sono stati generati a partire da dataset la cui popolazione studiata andava da quindici unità al centinaio, per questo motivo alcuni autori suggeriscono il paragone attraverso ulteriori parametri, come l' R^2 adattato o il MAPE, fermo restando che ogni valutazione non può prescindere da una chiara conoscenza della distribuzione del dataset di riferimento (Miles, 2005; Liu et al., 2018). È chiaro quindi che risulta complicato determinare se un metodo sia superiore ad un altro. Tuttavia, è possibile prendere in considerazione altri aspetti, legati ad esempio alla potenza di calcolo necessaria all'algoritmo per effettuare le analisi e la sua trasferibilità, alla complessità dello stesso o del modello generato, fino alla preparazione della scena preliminare all'acquisizione delle immagini. Le immagini utilizzate nel presente studio sono state processate nell'ordine del secondo ogni venticinque, contro un'immagine al secondo degli studi di autori che riportano questo dato (Millan et al., 2017). Una metodologia rapida dal punto di vista analitico e semplice dal punto di vista del modello, come quella proposta, può avere maggior spazio applicativo qualora venisse implementata su un supporto mobile economico e validata su un numero maggiore di cultivar e condizioni. Inoltre, i risultati ottenuti da altri studi mettono in luce come non ci sia alcun vantaggio nell'utilizzo di più fattori nei modelli e che quelli lineari risultano i più performanti (Millan et al., 2017; Liu et al., 2018). In merito all'elaborazione di modelli cultivar-indipendenti i risultati ottenuti in altri studi suggeriscono che, se le immagini delle infiorescenze sono acquisite nel medesimo stadio di sviluppo ciò è possibile, a patto che si reputi l'80% nella precisione della stima come una soglia di successo (Liu et al., 2018; Tello et al., 2020b). La validazione del modello su dataset esterni effettuata nel presente studio è in linea con queste

considerazioni, motivo per il quale future indagini dovrebbero concentrarsi più sulla morfologia delle infiorescenze che sull'elaborazione di algoritmi più complessi.

In merito alla stima delle componenti della resa, nel presente studio si è partiti dal numero complessivo di fiori relativi ad una pianta, per stimarne prima il corrispettivo numero di acini e successivamente il peso dei grappoli. I risultati ottenuti, in accordo con quelli riscontrati da altri autori su Cabernet Sauvignon, Malvasia, Moscato d'Alessandria, Syrah, Tempranillo e Verdejo (Palacios et al., 2020), incoraggiano a pensare che, indagare più a fondo la tematica dell'analisi di immagini di infiorescenze, permetterebbe di elaborare modelli più precisi e in grado di prevedere con anticipo di tre o quattro mesi, la produzione. Chiaramente tale stima dipende anche da fattori slegati dai parametri che si possono dedurre da un'immagine. Il numero di acini e il peso dei grappoli dipendono infatti dalla percentuale di allegagione così come dall'andamento climatico della stagione, dallo stato nutrizionale e idrico delle piante, dalla gestione della chioma e da altri fattori esterni come luce e temperatura (Coombe, 1972; May, 2004; Krstic et al., 2005). Tuttavia, la moderna viticoltura può avvantaggiarsi dall'utilizzo di mappe di vigore e relative mappe di prescrizione, che permetterebbero una calibrazione dei modelli di stima della resa su percentuali di allegagione specifiche per la cultivar e l'ambiente pedoclimatico nel quale si opera. Una delle limitazioni all'applicazione di questo tipo di metodologia, ad oggi non esplorata, è legata a quali e quante infiorescenze e da quali piante andrebbero fotografate per ottenere una stima soddisfacente. I risultati ottenuti nel presente studio per la stima della resa, così come in altri (Palacios et al., 2020), sono stati ottenuti acquisendo le immagini del 100% delle infiorescenze di una pianta. Tuttavia, è stato messo in luce come infiorescenze di differenti classi di lunghezza possono determinare effetti nella precisione della stima e si è visto che, in linea generale è preferibile includere infiorescenze di lunghezza molto variabile ma che non vada al di sotto dei 6 cm, lunghezza al di sotto della quale la precisione della stima cala di molto, inficiando il risultato finale. Si è visto inoltre che la condizione di vigore della pianta non sembrerebbe influenzare la morfologia dell'infiorescenza e di riflesso la precisione dell'analisi. Per questo motivo, ulteriori studi dovranno riguardare la soglia ottimale di infiorescenze fotografate per pianta, fermo restando che applicando la metodologia a condizioni in cui si ha già cognizione della variabilità del vigneto è possibile pianificare schemi di campionamento oculati per ciascuna area.

Tabella 5 Confronto tra il presente ed altri studi sulla stima del numero di fiori in infiorescenze di uva da vino in termini di target d'analisi, ampiezza del dataset, numero di cultivar utilizzate, tipologia e precisione del modello elaborato e stima delle componenti della resa.

Studio	Target d'analisi	Infiorescenze (n)	Cultivar	Modello	R ²	RMSE (n. fiori)	MAPE (%)	Stima componenti resa
Presente	Area ROI	300 + 216	3	Lineare	0,78	86,37	23,84	sì
Diago et al., (2014)	N° fiori visibili	30*3	3	Lineare	0,76	-	-	no
Aquino et al., (2015)	N° fiori visibili	10*4	4	Lineare - non lineare	0,85-0,95	84 -58	-	no
Millan et al., (2017)	N° fiori visibili	12*11	11	Lineare - non lineare	0,91	59,90; 46,78; 37,1	-	sì
Liu et al., (2018)	N° fiori visibili + Area ROI	51*4	4	Lineare - non lineare	0,79 - 0,94	-	10,12-24,62	no
Tello et al., (2019)	N° fiori visibili + Area ROI	(100*4) + (4*15)	4+15	Lineare	0,83 - 0,91	46,8	14,4	no
Palacios et al., (2020)	N° fiori visibili	16*6	6	Lineare	-	-	-	sì

Le informazioni non riportate dagli autori sono segnalate col simbolo “-“.

3.4 Conclusioni

Nel presente studio i risultati ottenuti evidenziano che: (i) il modello di regressione lineare elaborato è promettente dal punto di vista della precisione nella stima del numero di fiori, soprattutto se si considera quello complessivo della pianta. Nella previsione di una eventuale implementazione della metodologia su applicazione per smartphone, la semplice correzione di parametri tecnici come la distanza tra infiorescenza e fotocamera o dell'angolo tra asse del rachide e superficie dell'obiettivo che riducano al minimo l'errore, potrebbe far aumentare considerevolmente tale precisione, portando ad un risultato concretamente applicabile nelle reali condizioni di campo per la previsione delle rese e l'elaborazione di mappe di produzione. Chiaramente, nonostante i presupposti lo suggeriscano, affinché la metodologia sia generalizzabile, sarà necessario applicarla su larga scala a diverse cultivar, analizzando immagini di infiorescenze con forme, dimensioni e gradi di densità dei fiori differenti. In ogni caso, differenti modelli calibrati su una specifica cultivar potrebbero essere una strada alternativa. (ii) I risultati ottenuti suggeriscono come il parametro lunghezza, fino ad oggi poco indagato, potrebbe rappresentare la chiave per ottenere modelli costruiti a partire da algoritmi d'analisi semplici e correlazioni singole e lineari. (iii) La stima delle componenti della resa tramite i modelli di regressione elaborati su questo tipo di analisi appare una strada praticabile, purché si

tengano in considerazione i parametri cultivar-dipendenti e ambientali che influiscono sulla percentuale di allegagione.

3.5 Riferimenti bibliografici

- Alahi, A., Ortiz, R., and Vandergheynst, P. (2012). Freak: Fast retina keypoint., Conference on computer vision and pattern recognition. 16-21 June 2012 pp. 510–517.
- Aquino, A., Millan, B., Diago, M.-P., and Tardaguila, J. (2018). Automated early yield prediction in vineyards from on-the-go image acquisition. *Comput. Electron. Agric.* 144, 26–36. doi: 10.1016/j.compag.2017.11.026.
- Aquino, A., Millan, B., Gaston, D., Diago, M.-P., and Tardaguila, J. (2015a). vitisFlower®: Development and Testing of a Novel Android-Smartphone Application for Assessing the Number of Grapevine Flowers per Inflorescence Using Artificial Vision Techniques. *Sensors* 15, 21204–21218. doi: 10.3390/s150921204.
- Aquino, A., Millan, B., Gutiérrez, S., and Tardaguila, J. (2015b). Grapevine flower estimation by applying artificial vision techniques on images with uncontrolled scene and multi-model analysis. *Comput. Electron. Agric.* 119, 92–104.
- Bay, H., Ess, A., Tuytelaars, T., and Van Gool, L. (2008). Speeded-up robust features (SURF). *Comput. Vis. Image Underst.* 110, 346–359.
- Benmehaia, R., Khedidja, D., and Bentchikou, M. E. M. (2016). Estimation of the flower buttons per inflorescences of grapevine (*Vitis vinifera* L.) by image auto-assessment processing. *Afr. J. Agric. Res.* 11, 3203–3209.
- Bennett, J., Jarvis, P., Creasy, G. L., and Trought, M. C. (2005). Influence of defoliation on overwintering carbohydrate reserves, return bloom, and yield of mature Chardonnay grapevines. *Am. J. Enol. Vitic.* 56, 386–393.
- Bessis, R. (1960). Two rapid methods of estimating the number of flowers in vine inflorescences. *C. r. Hebd. Seances Acad. Agric. Fr.* 46, 823–8.
- Clingeffer, P. R. (2010). Plant management research: status and what it can offer to address challenges and limitations. *Aust. J. Grape Wine Res.* 16, 25–32.
- Clingeffer, P. R., and Krstic, M. (2003). *Crop development, crop estimation and crop control to secure quality and production of major wine grape varieties: a national approach: final report to Grape and Wine Research & Development Corporation*. Grape and Wine Research and Development Corporation: Adelaide, Australia
- Coombe, B. (1972). The regulation of set and development of the grape berry. *Acta Hortic.* 34: Symposium on Growth Regulators in Fruit Production. 261–274.
- Cubero, S., Diago, M. p., Blasco, J., Tardaguila, J., Prats-Montalbán, J. m., Ibáñez, J. (2015). A new method for assessment of bunch compactness using automated image analysis. *Aust. J. Grape Wine Res.* 21, 101–109. doi: 10.1111/ajgw.12118.
- Dalal, N., and Triggs, B. (2005). Histograms of oriented gradients for human detection. Computer society conference on computer vision and pattern recognition (CVPR'05) 20-25 June, 2005.1, pp. 886-893 886–893.
- Diago, M. P., Sanz-Garcia, A., Millan, B., Blasco, J., and Tardaguila, J. (2014). Assessment of flower number per inflorescence in grapevine by image analysis under field conditions. *J. Sci. Food Agric.* 94, 1981–1987. doi: 10.1002/jsfa.6512.
- Dunn, G. M., and Martin, S. R. (2004). Yield prediction from digital image analysis: A technique with potential for vineyard assessments prior to harvest. *Aust. J. Grape Wine Res.* 10, 196–198. doi: 10.1111/j.1755-0238.2004.tb00022.x.

- Dunn, G. M., and Martin, S. R. (2007). A functional association in *Vitis vinifera* L. cv. Cabernet Sauvignon between the extent of primary branching and the number of flowers formed per inflorescence. *Aust. J. Grape Wine Res.* 13, 95–100. doi:10.1111/j.1755-0238.2007.tb00239.x
- Howell, G. S. (2001). Sustainable Grape Productivity and the Growth-Yield Relationship: A Review. *Am. J. Enol. Vitic.* 52, 165–174. doi: 10.5344/ajev.2001.52.3.165.
- Kliewer, W., and Casteel, T. (2003). Canopy management. *Or. Vitic. EW Hellman Ed*, 177–184.
- Kliewer, W. M., and Dokoozlian, N. K. (2005). Leaf Area/Crop Weight Ratios of Grapevines: Influence on Fruit Composition and Wine Quality. *Am. J. Enol. Vitic.* 56, 170–181. doi: 10.5344/ajev.2005.56.2.170.
- Krstic, M., Clingeleffer, P., Dunn, G., Martin, S., and Petrie, P. (2005). Grapevine growth and reproductive development: an overview. In *Transforming flowers to fruit. ASVO Proc.*, 7–10.
- Liu, S., Li, X., Wu, H., Xin, B., Tang, J., Petrie, P. R. (2018). A robust automated flower estimation system for grape vines. *Biosyst. Eng.* 172, 110–123.
- Liu, S. (Scarlett) (2017). Automated yield estimation in viticulture by computer vision. PhD Thesis. UNSW Sydney. doi: 10.26190/unsworks/3097.
- Liu, S., and Whitty, M. (2015). Automatic grape bunch detection in vineyards with an SVM classifier. *J. Appl. Log.* 13, 643–653.
- Lopes, C., Graça, J., and Monteiro, A. (2021). Accurate estimation of grapevine bunch weight using image analysis: a case study with two portuguese cultivars. *Acta Hortic.*, November 18, 2021, 1314, 117-124. doi: 10.17660/ActaHortic.2021.1314.16
- Lopes, C. M., and Cadima, J. (2021). Grapevine bunch weight estimation using image-based features: comparing the predictive performance of number of visible berries and bunch area. *Oeno One.* 4, 209-226. doi: 10.20870/oeno-one.2021.55.4.4741.
- Lorenz, D., Eichhorn, K., Bleiholder, H., Klose, R., Meier, U., and Weber, E. (1994). Phänologische Entwicklungsstadien der Weinrebe (*Vitis vinifera* L. ssp. *vinifera*). Codierung und Beschreibung nach der erweiterten BBCH-Skala. *Wein-Wiss.* 49, 66–70.
- May, P. (2000). From bud to berry, with special reference to inflorescence and bunch morphology in *Vitis vinifera* L. *Aust. J. Grape Wine Res.* 6, 82–98.
- May, P. (2004). *Flowering and fruitset in grapevines*. Lythrum Press, Adelaide (Australia).
- Miles, J. (2005). “R-Squared, Adjusted R-Squared,” in *Encyclopedia of Statistics in Behavioral Science*, (John Wiley & Sons, Ltd). doi: 10.1002/0470013192.bsa526
- Millan, B., Aquino, A., Diago, M. P., and Tardaguila, J. (2017). Image analysis-based modelling for flower number estimation in grapevine. *J. Sci. Food Agric.* 97, 784–792. doi: doi.org/10.1002/jsfa.7797
- Millan, B., Velasco-Forero, S., Aquino, A., and Tardaguila, J. (2018). On-the-Go Grapevine Yield Estimation Using Image Analysis and Boolean Model. *J. Sens.* 2018, e9634752. doi: 10.1155/2018/9634752.
- Nobuyuki, O. (1979). A Threshold Selection Method From Gray-Level Histograms In *Transactions On Systems, Man, And Cybernetics*, Vol. 9, 62.
- Otsu, N. (1975). A threshold selection method from gray-level histograms. *Automatica* 11, 23–27.
- Palacios, F., Bueno, G., Salido, J., Diago, M. P., Hernández, I., and Tardaguila, J. (2020). Automated grapevine flower detection and quantification method based on computer vision and deep learning from on-the-go imaging using a mobile sensing platform under field conditions. *Comput. Electron. Agric.* 178, 105796. doi: 10.1016/j.compag.2020.105796.

- Poni, S., Casalini, L., Bernizzoni, F., Civardi, S., and Intrieri, C. (2006). Effects of early defoliation on shoot photosynthesis, yield components, and grape composition. *Am. J. Enol. Vitic.* 57, 397–407. doi: 10.5344/ajev.2006.57.4.397
- Schindelin, J., Arganda-Carreras, I., Frise, E., Kaynig, V., Longair, M., Pietzsch, T. (2012). Fiji: an open-source platform for biological-image analysis. *Nat. Methods* 9, 676–682.
- Tello, J., Herzog, K., Rist, F., This, P., and Doligez, A. (2020). Automatic Flower Number Evaluation in Grapevine Inflorescences Using RGB Images. *Am. J. Enol. Vitic.* 71, 10–16. doi: 10.5344/ajev.2019.19036.
- Tello, J., Montemayor, M. I., Forneck, A., and Ibáñez, J. (2018). A new image-based tool for the high throughput phenotyping of pollen viability: evaluation of inter- and intra-cultivar diversity in grapevine. *Plant Methods* 14, 3. doi: 10.1186/s13007-017-0267-2
- Victorino, G., Braga, R., Santos-Victor, J., and Lopes, C. M. (2020). Yield components detection and image-based indicators for non-invasive grapevine yield prediction at different phenological phases. *OENO One.* 54 (4), 833-848 doi: 10.20870/oeno-one.2020.54.4.3616
- Victorino, G., Poblete-Echeverría, C., and Lopes, C. M. (2022). A multicultivar approach for grape bunch weight estimation using image analysis. *Horticulturae* 8 (3), 233.

4 Stima del numero di acini in grappoli di uva da tavola attraverso l'analisi di immagini*

Antonino Pisciotta ⁽¹⁾ Stefano Puccio ⁽¹⁾, Pietro Scafidi ⁽²⁾, Daniele Micciché ⁽¹⁾, Emanuele Santo Blando ⁽¹⁾, Massimo Ferro ⁽¹⁾, Stefano Barone ⁽¹⁾, Albert Comelli ⁽³⁾, Rosario Di Lorenzo ⁽¹⁾

⁽¹⁾ Dipartimento di Scienze Agrarie Alimentari e Forestali (SAAF), Università degli studi di Palermo

⁽²⁾ International Fruit Genetics (IFG)

⁽³⁾ Fondazione Ri.MED

*Lavoro presentato al IX Convegno Nazionale di Viticoltura (Conegliano, 13-15 giugno 2022). In corso di pubblicazione.

La conoscenza precoce del numero di acini per grappolo nella vite (*Vitis vinifera* L.) è un indicatore importante per la stima della produzione, l'ottimizzazione delle pratiche di potatura in verde e il raggiungimento di obiettivi di qualità (Dunn e Martin, 2004). Nel caso dell'uva da tavola, questa informazione consente di stimare sia la quantità di uva sulla pianta che regolarne la qualità in termini di forma e compattezza del grappolo mediante interventi agronomici mirati, come il diradamento dei grappoli e degli acini (Karoglan et al., 2014). I metodi utilizzati per questo scopo, fino ad oggi, sono in gran parte distruttivi, richiedono molto tempo, manodopera e si basano sulla valutazione di campioni numericamente ristretti (Lopes et al., 2021). Una stima tardiva della resa ed errori predittivi possono portare a una gestione inefficace della logistica dell'uva raccolta e a un eccessivo carico di lavoro in un periodo di tempo limitato (Liu et al., 2020). Per questo motivo, la stima in fasi precoci può fornire informazioni più utili per la pianificazione e per la gestione delle pratiche agricole. Per raggiungere tale obiettivo, risulta necessario sostituire il campionamento manuale e la stima visuale con metodi automatizzati a basso costo e affidabili. Attualmente, sono stati presentati diversi metodi per stimare il numero di fiori, acini o grappoli sulla vite attraverso l'analisi delle immagini. Reis et al., (2012) hanno proposto una metodologia per rilevare i grappoli utilizzando il colore degli stessi come elemento discriminante su immagini acquisite in condizioni notturne; Aquino et al., (2015; 2018) hanno sviluppato due sistemi per rilevare i fiori e gli acini della vite operando rispettivamente nello spazio colore *Hue Saturation Brightness* (HSV) e Color space CIE L*a*b (CIELAB) per enfatizzare i picchi di luminosità all'interno di infiorescenze e grappoli. Molto simile è la metodologia sviluppata da Diago et al., (2014), in cui le immagini acquisite utilizzando un pannello per l'omogeneizzazione dello sfondo sono state analizzate convertendo le immagini dallo spazio colore RGB allo spazio colore CIELAB e identificando i fiori come punti di luminosità massima. Liu et al., (2015) hanno optato per la ricostruzione tridimensionale di un grappolo d'uva da un'immagine singola utilizzando la tecnica *Circle Hough Transform* (CHT). Tuttavia, la maggior parte delle tecnologie esistenti, sviluppate per la stima

automatizzata del numero di acini, richiede spesso una specifica configurazione di laboratorio o velocità computazionali che richiedono un tempo eccessivo per l'applicazione in vigneto (Buayai et al., 2020). La sfida principale della stima del numero di acini dall'analisi delle immagini è legata anche alla percentuale di quelli non visibili da un'immagine bidimensionale perché nascosti da quelli in primo piano. Come sostenuto da altri autori, un'alta densità di acini (o di fiori nel caso in cui si voglia stimare il loro numero su infiorescenze) può influire negativamente sul conteggio automatico (Liu et al., 2018). Tuttavia, nell'uva da tavola, l'analisi eseguita durante fasi precoci dello sviluppo degli acini potrebbe consentire una stima più accurata grazie a una minore compattezza dei grappoli. Lo scopo di questo studio è stato quindi quello di sviluppare una metodologia accurata, veloce ed economica per la stima precoce del numero di acini su grappoli di uva da tavola attraverso l'analisi di immagini RGB, per valutarne la trasferibilità su supporto mobile ed app in tempo reale.

4.1 Materiale e Metodi

Il presente studio è stato condotto nel 2021 utilizzando immagini di grappoli della cv IFG 068-175 (Sweet Celebration™). Le immagini sono state acquisite quando i grappoli si trovavano allo stadio fenologico di allegagione (BBCH 71) secondo la scala di Lorenz et al., (1995). Un totale di 150 grappoli è stato campionato casualmente per garantire variabilità morfologica e dimensionale, fotografato in condizioni di luce naturale e trasferito in laboratorio per l'analisi biometrica (Fig. 1).



Figura 1 Esempio di grappoli di uva da tavola analizzati nel presente studio. Si noti la consistente variabilità in termini di forma e numero di acini.

Per l'acquisizione delle immagini è stata utilizzata la fotocamera digitale di uno smartphone comunemente disponibile sul mercato (HUAWEI Mate 20 lite SNE-LX1). I campioni sono stati posizionati a 40 cm ortogonalmente all'obiettivo della fotocamera e fotografati utilizzando un foglio bianco per l'omogeneizzazione dello sfondo (Aquino et al., 2017). Successivamente, è stato effettuato il conteggio manuale degli acini per grappolo per valutare l'efficacia dell'analisi. Per ogni grappolo sono stati misurati anche i seguenti parametri: lunghezza del rachide (cm), lunghezza della prima ala (cm), lunghezza della seconda ala (cm), numero totale di ali (n). L'indice di compattezza (CI) è stato calcolato secondo il metodo proposto da Tello e Ibáñez (2014):

$$CI = \frac{BB}{BL(cm) + 1RL(cm) + 2RL(cm)} \quad (1)$$

Dove BB indica il numero di acini per grappolo, BL la lunghezza del grappolo, $1RL$ e $2RL$ la lunghezza della prima e della seconda ala del grappolo.

Il metodo di analisi delle immagini per la rilevazione e il conteggio degli acini nei grappoli è stato sviluppato con il software open-source FIJI/Imagej®. Il diagramma di flusso delle fasi per la stima del numero di acini è mostrato in Fig. 2.

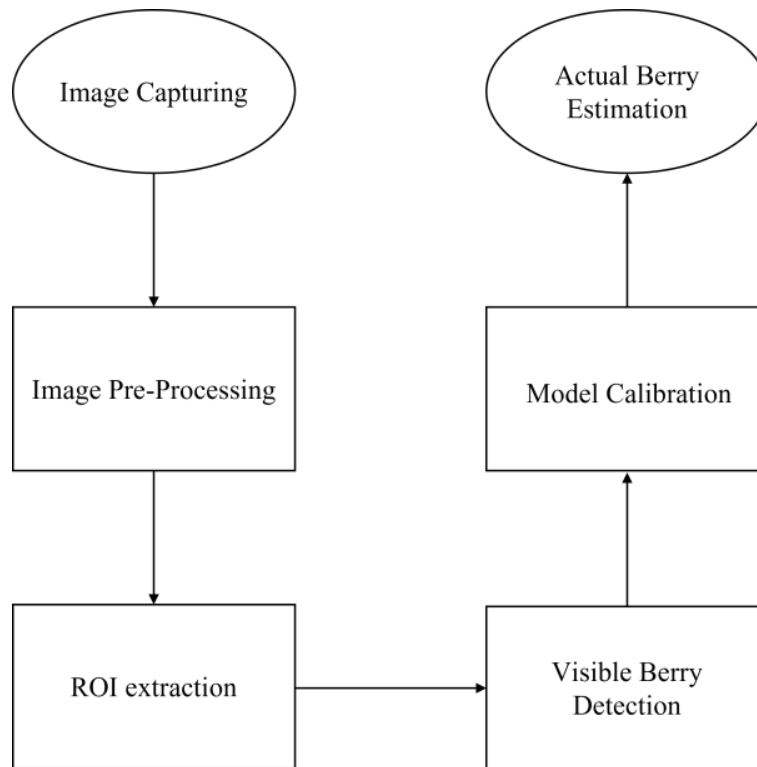


Figura 2 Diagramma di flusso delle principali fasi dell'analisi delle immagini utilizzato nel presente studio.

Le principali fasi dell'algorithmo proposto, basato sulla segmentazione dell'immagine in regioni di interesse (ROI) in base alla morfologia degli acini sono illustrate graficamente in Fig. 3. Ogni immagine, con una risoluzione di 3840 x 5120 pixel, è stata prima pre-processata. Il contrasto è stato accentuato attraverso la funzione *Enhance Contrast* e impostando una saturazione dei pixel del 0,3% (Fig. 3-A). Successivamente, i grappoli sono stati separati dallo sfondo utilizzando la funzione *Subtract Background* impostando un raggio di *rolling ball* di 50 pixel per schiarire lo sfondo (Fig. 3-B). Mentre altri autori hanno utilizzato colore e luminosità come discriminante per la segmentazione degli acini all'interno del grappolo o la ricostruzione 3-D per l'identificazione dei fiori/acini (Liu et al., 2015; Millan et al., 2017), in questo studio gli acini sono stati segmentati mettendo la loro forma in relazione a forme di riferimento utilizzando il processo di segmentazione morfologica implementato nella libreria MorphoLibJ di FIJI/Imagej (Serra and Vincent, 1992; Legland et al., 2016). Di conseguenza, questa fase si basa sulla morfologia matematica. L'idea di

base è quella di confrontare gli acini con un oggetto di forma nota, chiamato “elemento strutturante”. Nello specifico, è stata eseguita un'operazione di *Closing* con un raggio di 20 pixel (una dilatazione seguita da un'erosione) su elementi di forma approssimabile a quella discoidale presenti nelle immagini, per delineare morfologicamente gli acini ed escluderli dagli elementi esterni (Fig. 3-C). Le immagini sono state quindi convertite in *8-bit* per escludere informazioni legate alla luminosità non utili all'analisi, binarizzate mediante la sogliatura automatica dell'immagine utilizzando il metodo di Otsu (Otsu, 1975; Otsu, 1979) per ottenere immagini con il minor numero di informazioni, ossia le forme e lo sfondo (Fig. 3-D, E). Successivamente, è stata eseguita una segmentazione attraverso l'algoritmo *Watershed* per separare eventuali acini contigui o sovrapposti (Fig. 3-F). Gli acini sono stati quindi conteggiati utilizzando la funzione *Analyze Particles*, considerando particelle con un'area compresa tra 500 e 10000 pixel e un valore di *Circularity* del 78%, dove un valore del 100% indica un cerchio perfetto e un valore dello 0% indica un poligono (Fig. 3-F).




Figura 3 Principali fasi dell'algoritmo sviluppato per l'estrazione della ROI. A: aumento del contrasto; B: rimozione dello sfondo; C: filtro morfologico; D: conversione 8-bit; E: binarizzazione; F: segmentazione *Watershed* e conta acini.

Di seguito è riportata la macro dell'algoritmo utilizzato per l'analisi:

```
1 run("Enhance Contrast...", "saturated=0.3");
2 run("Subtract Background...", "rolling=50 light");
3 run("Morphological Filters", "operation=Closing element=Disk radius=20");
4 run("8-bit");
5 setAutoThreshold("Default");
6 //run("Threshold...");
7 //setThreshold(0, 190);
8 setOption("BlackBackground", true);
9 run("Convert to Mask");
10 run("Watershed");
11 run("Analyze Particles...", "size=500-10000 circularity=0.78-1.00 display");
```

Il numero di acini ottenuto dall'analisi dell'immagine (CBN) è stato correlato con quello ottenuto dal conteggio manuale (ABN) utilizzando una regressione lineare, al fine di stimare il numero di acini occlusi in base a quelli visibili rilevati. Successivamente, l'equazione ottenuta dalla regressione lineare è stata utilizzata per costruire il modello:

$$ABN = -1,4702 + 0,9915 * CNB \quad (2)$$

Il coefficiente di determinazione (R^2) è stato considerato significativo per $P \leq 0,01$. Per una valutazione più accurata del modello, è riportato il valore R^2 adattato. Il *Root Mean Square Error* (RMSE) e il *Mean Absolute Percentage Error* (MAPE) sono stati calcolati per l'errore stimato in accordo con Tello e Ibáñez Marcos, (2014). Tutte le analisi sono state eseguite utilizzando il software statistico Minitab[®] (versione 19).

4.2 Risultati e discussione

Il metodo di analisi delle immagini sviluppato in questo lavoro si basa principalmente su due fasi: nella prima viene segmentata l'immagine per estrarre una forma specifica (circolare) escludendola dallo sfondo e dagli oggetti di forma diversa visibili nell'immagine (es: raspo); nella seconda, attraverso l'algoritmo *Watershed* sono stati segmentati gli elementi estratti per separarli come

oggetti singoli conteggiabili. Questa procedura ha permesso di evitare il conteggio singolo di due oggetti sovrapposti. In media, con una procedura semiautomatica, un'immagine è stata elaborata in circa un minuto ma, automatizzandola, l'intera procedura richiederebbe non più di tre secondi. L'analisi del dataset ha permesso di valutare una correlazione apprezzabile tra il numero effettivo di acini e quelli rilevati dall'analisi delle immagini (Fig. 4).

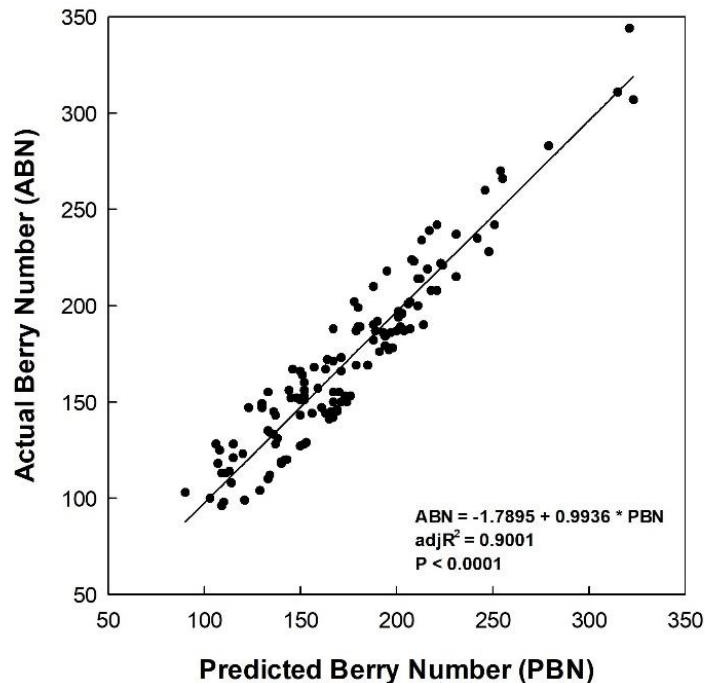


Figura 3 Correlazione fra il numero di acini stimato dall'analisi di immagini e il numero effettivo di acini contato manualmente sui grappoli.

Per ottenere un modello lineare più accurato, sono stati eliminati i valori considerati outlier come risultato dell'analisi dei residui. Il valore adattato di R^2 , il RMSE e il MAPE erano tutti nell'intervallo dei valori riportati da altri autori che utilizzano algoritmi diversi (Tello et al., 2020; Liu et al., 2018; Millan et al., 2016). Le principali differenze trovate tra i valori osservati e predetti erano attribuibili agli acini non visibili su un'immagine 2D e quindi non rilevabili dall'algoritmo. Gli outlier identificati ed eliminati dal dataset hanno permesso di generare un'equazione di regressione con un coefficiente di determinazione più accurato (Tab. 1).

Tabella 1. Caratterizzazione biometrica dei grappoli utilizzati per l’acquisizione e l’analisi delle immagini.

Parametro	Media	± Deviazione standard	Minimo	Massimo
Acini per grappolo (n)	174,97	47,53	96,00	344,00
Lunghezza del grappolo (cm)	13,39	3,58	4,00	27,00
Ali per grappolo (n)	22,04	5,07	11,00	39,00
Lunghezza I ala (cm)	13,40	1,53	10,16	15,50
Lunghezza II ala (cm)	12,00	1,46	9,03	13,88
Indice di compattezza	4,03	1,49	1,02	7,91

Infatti, gli outlier possono essere attribuiti a quei grappoli che avevano gli indici più alti di compattezza (Liu et al., 2018) (Tab. 2). Considerando l'ampia variabilità di compattezza dei grappoli analizzati è possibile ipotizzare l'implementazione di tale metodologia per la stima del numero di acini anche in varietà con grappoli più compatti. Ciò significa che potrebbe non essere necessario un modello individuale per ogni varietà. Inoltre, la metodologia utilizzata in questo lavoro potrebbe consentire di rilevare gli acini indipendentemente dalle caratteristiche morfologiche del grappolo.

Tabella 2. Metriche di valutazione del modello relative alla stima del numero di acini sui grappoli.

n	n-o	ABN	PBN	adjR ²	adjR ² -o	RMSE (n)	MAPE (%)
150	146	172,3 ± 46,77	175,26 ± 44,75	0,88	0,90	14,84	8,14

I valori di ABN e PBN sono *riportati* come media ± deviazione standard. n, numero di grappoli; n-o, numero di grappoli al netto di outliers ABN, numero reale di acini; PBN, numero di acini stimati dal modello. adjR², adjusted R²; adjR²-o, adjusted R² al netto di outliers; RMSE, Root Mean Square Error; MAPE, Mean Absolute Percentage Error.

4.3 Conclusioni

Il procedimento di analisi delle immagini sviluppato, basato su una piattaforma open-source, non richiede elevate capacità di calcolo e si dimostra efficace nello stimare il numero di acini. Potrebbe rappresentare un'opportunità per la sua implementazione su dispositivi mobili e per l'applicazione in tempo reale nelle condizioni di pieno campo per valutare le componenti della resa dell'uva da tavola. Le future applicazioni richiederanno tuttavia prove su diverse varietà al fine di ottenere un modello che rifletta eventualmente la differente variabilità morfologica del grappolo in termini di compattezza.

4.4 Riferimenti bibliografici

- Aquino, A., Diago, M. P., Millán, B., and Tardáguila, J. (2017). A new methodology for estimating the grapevine-berry number per cluster using image analysis. *Biosyst. Eng.* 156, 80–95. doi: 10.1016/j.biosystemseng.2016.12.011.
- Aquino, A., Millan, B., Diago, M.-P., and Tardaguila, J. (2018). Automated early yield prediction in vineyards from on-the-go image acquisition. *Comput. Electron. Agric.* 144, 26–36. doi: 10.1016/j.compag.2017.11.026.
- Aquino, A., Millan, B., Gutiérrez, S., and Tardáguila, J. (2015). Grapevine flower estimation by applying artificial vision techniques on images with uncontrolled scene and multi-model analysis. *Comput. Electron. Agric.* 119, 92–104.
- Buayai, P., Saikaew, K. R., and Mao, X. (2020). End-to-end automatic berry counting for table grape thinning. *Access* 9, 4829–4842.
- Diago, M. P., Sanz-Garcia, A., Millan, B., Blasco, J., and Tardaguila, J. (2014). Assessment of flower number per inflorescence in grapevine by image analysis under field conditions. *J. Sci. Food Agric.* 94, 1981–1987. doi: 10.1002/jsfa.6512.
- Dunn, G. M., and Martin, S. R. (2004). Yield prediction from digital image analysis: A technique with potential for vineyard assessments prior to harvest. *Aust. J. Grape Wine Res.* 10, 196–198. doi: 10.1111/j.1755-0238.2004.tb00022.x.
- Karoglan, M., Osrečak, M., Maslov, L., and Kozina, B. (2014). Effect of cluster and berry thinning on Merlot and Cabernet Sauvignon wines composition. *Czech J. Food Sci.* 5, 470–476.
- Legland, D., Arganda-Carreras, I., and Andrey, P. (2016). MorphoLibJ: integrated library and plugins for mathematical morphology with ImageJ. *Bioinformatics* 32, 3532–3534. doi: 10.1093/bioinformatics/btw413.
- Liu, S., Li, X., Wu, H., Xin, B., Tang, J., Petrie, P. R. (2018). A robust automated flower estimation system for grape vines. *Biosyst. Eng.* 172, 110–123.
- Liu, S., Whitty, M., and Cossell, S. (2015). A lightweight method for grape berry counting based on automated 3D bunch reconstruction from a single image. *CRA, International conference on robotics and automation, workshop on robotics in agriculture*. May, 2015. 4.
- Liu, S., Zeng, X., and Whitty, M. (2020). A vision-based robust grape berry counting algorithm for fast calibration-free bunch weight estimation in the field. *Comput. Electron. Agric.* 173, 105360.
- Lopes, C., Graça, J., and Monteiro, A. (2021). Accurate estimation of grapevine bunch weight using image analysis: a case study with two portuguese cultivars. *Acta Hort.*, November 18, 2021, No. 1314, 117-124.
- Lorenz, D., Eichhorn, K., Bleiholder, H., Klose, R., Meier, U., and Weber, E. (1994). Phänologische Entwicklungsstadien der Weinrebe (*Vitis vinifera* L. ssp. *vinifera*). Codierung und Beschreibung nach der erweiterten BBCH-Skala. *Wein-Wiss.* 49, 66–70.
- Millan, B., Aquino, A., Diago, M. P., and Tardaguila, J. (2017). Image analysis-based modelling for flower number estimation in grapevine. *J. Sci. Food Agric.* 97, 784–792.
- Nobuyuki, O. (1979). A Threshold Selection Method From Gray-Level Histograms. *Transactions On Systems, Man, And Cybernetics*, Vol. 9, 62.
- Otsu, N. (1975). A threshold selection method from gray-level histograms. *Automatica* 11, 23–27.
- Reis, M. J., Morais, R., Peres, E., Pereira, C., Contente, O., Soares, S. (2012). Automatic detection of bunches of grapes in natural environment from color images. *J. Appl. Log.* 10, 285–290.
- Serra, J., and Vincent, L. (1992). An overview of morphological filtering. *Circuits Syst. Signal Process.* 11, 47–108. doi: 10.1007/BF01189221.

Tello, J., and Ibáñez Marcos, J. (2014). Evaluation of indexes for the quantitative and objective estimation of grapevine bunch compactness. *Vitis*. 53 (1), 9–16.

5 Stima del peso del legno di potatura in *Vitis vinifera* L. attraverso l'analisi d'immagini RGB

La conoscenza del peso del legno di potatura è di fondamentale importanza nella gestione del vigneto (*Vitis vinifera* L.). Essendo coinvolta nella determinazione degli equilibri vegeto-produttivi e utilizzata nel calcolo dell'Indice di Ravaz, conoscerne l'entità è un fattore chiave per ottenere uve dalla qualità adeguata agli obiettivi enologici e una produzione soddisfacente per gli standard aziendali (Viala e Ravaz, 1908; Smart and Robinson, 1991; Petrie et al., 2000 a; Petrie et al., 2000 b; Howell, 2001). Gestendo la potatura sulla base del monitoraggio della massa di legno che di anno in anno il vigneto produce, vari aspetti concernenti l'equilibrio delle piante possono essere regolati grazie alla scelta di potature più o meno ricche. Questi aspetti includono l'emissione di germogli fertili, il numero e il peso dei grappoli, il mantenimento di un equilibrio vegeto-produttivo e la riduzione della necessità di potature in verde. Fattori che hanno una ricaduta sulla regolazione della produzione e della qualità a lungo termine e sul contenimento dei costi di produzione (Kliewer and Dokoozlian, 2005; Poni et al., 2016; Palliotti et al., 2018; Tomasi et al., 2020). La potatura ha un'influenza anche nell'ottenimento di una struttura equilibrata della chioma e una migliore circolazione dell'aria, utile a ridurre il rischio di insorgenza di parassiti e malattie fungine (Calonnec et al., 2013). In più, la pratica agronomica che prevede l'interramento dei residui di potatura come strumento sostenibile per aumentare la sostanza organica nel suolo, beneficia di una valutazione accurata della sua massa (Pisciotta et al., 2021). A causa dell'influenza di molteplici fattori sulla variabilità del sistema vigneto (quali profondità e fertilità del suolo o la sua pendenza, pratiche agronomiche, clima) la valutazione del peso del legno di potatura è uno strumento utile nel comprendere questi aspetti, consentendo una gestione più efficace (Dobrowski et al., 2003).

Nella maggior parte dei casi, il processo di misurazione manuale del peso del legno di potatura può essere dispendioso in termini di tempo e mano d'opera a causa della necessità di separare i tralci appartenenti alle singole viti e interrompere il normale flusso del lavoro di potatura per poter raccogliarli, pesarli e registrarne il peso (Taylor e Bates, 2021). Tecniche non distruttive capaci di acquisire questo dato potrebbero portare benefici considerevoli sia ai ricercatori che ai viticoltori nella quantificazione della variabilità spaziale in termini di vigore (Bramley et al., 2011; Urretavizcaya et al., 2015, 2017; Santesteban, 2019). Ciò avrebbe implicazioni su un uso più efficiente degli input e sulla possibilità di effettuare operazioni culturali e di vendemmia più selettive (Aquino et al., 2015). Per questo motivo è utile l'adozione di metodologie in grado di ridurre i costi e i tempi di stima di tale parametro (Archer e Schalkwyk, 2007; Diago et al., 2016). Negli ultimi anni, l'analisi delle immagini si è affermata come una tecnica promettente per la caratterizzazione non distruttiva delle piante e la valutazione delle componenti della resa (Fiorani e

Schurr, 2013). Inoltre, l'introduzione di fotocamere digitali economiche, maggiore capacità di archiviazione dei dati e progressi tecnologici nell'elaborazione delle immagini sono stati fondamentali nel facilitare il progresso di questo specifico ambito (Mohimont et al., 2022). Ad oggi sono stati proposti vari metodi per l'implementazione dell'analisi di immagini anche in viticoltura. Questi approcci includono tecniche di elaborazione delle classiche immagini RGB, come algoritmi di segmentazione, riconoscimento di forme ed estrazione di caratteristiche specifiche all'interno delle immagini. Ad esempio, alcuni studi hanno riguardato la stima delle componenti della resa, come il numero di acini per grappolo (Aquino et al., 2018; Millan et al., 2018; Íñiguez et al., 2021), il numero di fiori per infiorescenza (Diago et al., 2014; Aquino et al., 2015; Palacios et al., 2020) o il numero e il peso dei grappoli sulla pianta (Dunn and Martin, 2004; Diago et al., 2012; Luo et al., 2016; Victorino et al., 2020, 2022; Casser, 2016). Altri studi hanno messo a punto metodi semi-automatici o automatici per la stima del vigore e porosità della chioma (Diago et al., 2012; Klodt et al., 2015; De Bei et al., 2016; Gatti et al., 2016), per l'automazione della potatura utilizzando piattaforme mobili accoppiate a sensori prossimali (Gao and Lu, 2006; Botterill et al., 2017; Fernandes et al., 2021; Guadagna et al., 2023) o per la rilevazione delle componenti qualitative delle uve tramite sensori prossimali e da remoto (Hall and Wilson, 2013; Cubero et al., 2015). Solo pochi studi sono stati condotti per valutare il peso del legno di potatura se si escludono quelli in cui vengono utilizzate piattaforme *Unmanned Aerial Vehicle* (UAV) e sensori *Light Detection and Ranging* (LIDAR), strumentazioni che operano prevalentemente da remoto o che comunque richiedono un investimento economico considerevole (Dobrowski et al., 2003; Siebers et al., 2018; Tagarakis et al., 2018; García-Fernández et al., 2021). Alcuni ricercatori (Kicherer et al. 2017) hanno sperimentato un approccio semi-automatico direttamente in vigneto per l'acquisizione delle immagini, utilizzando un prototipo di acquisizione dotato di un complesso sistema multicamera per acquisire e analizzare immagini RGB, ottenendo i primi interessanti risultati nella relazione tra il numero di pixel segmentati come legno di potatura e il peso effettivo dello stesso, su alcune accessioni di *Vitis vinifera* non innestate. Millan et al., (2018) hanno ottenuto risultati ancor più promettenti impiegando l'analisi digitale su RGB acquisite tramite una camera economica, sia manualmente che in movimento tramite un mezzo all'interno di un vigneto della cv Tempranillo allevato a controspalliera, utilizzando sia uno sfondo artificiale di giorno che illuminazione artificiale di notte, confermando la capacità di questa metodologia nel prevedere il peso del legno di potatura e mappare la variabilità di questo all'interno di un vigneto. Pochi studi esistono su approcci diversi per il monitoraggio diretto in vigneto su più varietà e che affrontino il problema dell'uso di sfondi artificiali e l'influenza di diverse condizioni di illuminazione della scena, ad oggi una delle

principali sfide nell'analisi delle immagini nel contesto della viticoltura. Inoltre, quando si utilizzano tecniche di analisi delle immagini per valutare il peso del legno, l'occlusione visiva prodotta tra i tralci che si sovrappongono può rappresentare un'ulteriore sfida significativa. Tuttavia, queste criticità possono essere superate con algoritmi di segmentazione più accurati, metodi di ricostruzione 3D o approcci di apprendimento automatico. Incorporando queste strategie, diventa possibile migliorare la precisione ed efficienza della valutazione, consentendo decisioni più accurate nella gestione del vigneto (Millan et al., 2018; Victorino et al., 2020; Íñiguez et al., 2021). Pertanto, è cruciale esplorare approcci alternativi che possano superare queste limitazioni e consentire l'automazione dei processi su scala vigneto (Diago et al., 2012; Roscher et al., 2014; Herzog, 2023).

Alla luce di ciò, gli obiettivi del presente studio sono i seguenti: (i) contribuire allo sviluppo di un metodo pratico e applicabile per la valutazione non distruttiva del peso del legno di potatura in vigneto mediante analisi delle immagini; (ii) identificare le condizioni di luce naturale più idonee per l'acquisizione delle immagini; (iii) superare le limitazioni associate all'uso di uno sfondo artificiale, considerando l'automazione futura a livello aziendale; e (iv) valutare se l'accuratezza della stima è influenzata dalla componente varietale. Puntando a questi obiettivi e fornendo quindi ulteriori utili informazioni, lo studio mira a migliorare l'efficienza e l'efficacia delle pratiche di gestione del vigneto.

5.1 Materiale e Metodi

5.1.1 Disegno sperimentale e acquisizione di immagini

L'acquisizione delle immagini è stata effettuata tra dicembre 2022 e gennaio 2023, prima della potatura invernale, in quattro vigneti commerciali delle cultivar Catarratto, Nero d'Avola, Merlot e Tannat (*Vitis vinifera* L.) innestate su portinnesto 1103P. Il vigneto di Catarratto (8116 m²) si trovava a Camporeale (37°55'12,82"N, 13°04'28,33"E; 320 m s.l.m.; Palermo, Italia). Le viti erano allevate a controspalliera, con sistema di potatura a doppio cordone speronato, irrigate attraverso un sistema d'irrigazione a goccia (2 L/h) su un terreno franco-argilloso. Le distanze d'impianto erano di 0,9 m sulla fila e 2,2 m tra le file e l'orientamento dei filari nord/est-sud/ovest. I vigneti di Nero d'Avola (14799 m²), Merlot (13264 m²) e Tannat (10141 m²) erano invece ubicati a Sambuca di Sicilia (37°40'47,93"N; 13°04'28,96"E; 252 m s.l.m.; Agrigento, Italia). Tutte le viti anche in questo caso erano allevate a controspalliera ma potate a cordone speronato singolo con distanze d'impianto 0,9 m sulla fila e 2,5 m tra le file con orientamento dei filari nord-ovest-sud-est. La gestione fitosanitaria, della chioma e della concimazione sono state applicate rispettivamente secondo le

pratiche viticole standard di un vigneto biologico. Tutti e quattro i vigneti erano condotti in irriguo con un sistema di irrigazione a goccia. Tra tutti i vigneti sono state scelte un totale di 174 viti per includere la maggiore variabilità possibile in termini di peso del legno di potatura e condizioni di occlusione tra i tralci (36 viti di Catarratto, 50 di Nero d'Avola, 48 di Merlot e 40 di Tannat) (Fig. 1).



Figura 1. Siti presso i quali è stato condotto lo studio. Contrassegnate in giallo le aree dei vigneti dalle quali le immagini delle piante sono state acquisite.

Le viti sono state fotografate manualmente utilizzando una fotocamera reflex digitale Canon 1300D (Canon, Tokyo, Giappone) montata su cavalletto, dotata di un obiettivo Canon 18–55 mm f/3.5-5.6 DC. La fotocamera è stata configurata con una sensibilità di 400 ISO, un'apertura di f/5,6 e una lunghezza focale di 24 mm. Il tempo di esposizione è stato determinato automaticamente. Per stimare la possibilità di evitare l'utilizzo di sfondi artificiali e la migliore condizione di luce per l'acquisizione e successiva analisi delle immagini, è stato condotto un test pilota sulle 36 viti della cultivar Catarratto. Le viti sono state fotografate su entrambi i lati della chioma (chiamati A e B) attraverso due modalità di acquisizione (Fig. 2): (1) la fotocamera è stata posizionata perpendicolarmente alla fila a 1,5 m dalle viti e a 1 m di altezza dal suolo, ed un pannello bianco è stato utilizzato alle spalle delle viti per l'omogeneizzazione dello sfondo (WB); (2) la fotocamera è stata posizionata perpendicolarmente alla fila a 1,2 m dalle viti e 0,7 m circa dal suolo con un'inclinazione di 35° rispetto al piano di campagna per ottenere immagini delle piante che avessero il cielo come sfondo (NB).




Figura 2. Immagini delle viti (cv Catarratto) acquisite manualmente (mattina). (a, b) esempio della modalità d’acquisizione con presenza di sfondo artificiale (WB) su entrambi i lati della chioma. (c, d) esempio della modalità d’acquisizione senza sfondo con fotocamera inclinata (NB), su entrambi i lati della chioma. Si noti come nonostante il momento del giorno sia il medesimo il sole, determini in *b* la proiezione di ombre sullo sfondo perché alle spalle della fotocamera e in *d* variabilità di colore tra i pixel riferiti ai tralci. Mentre nei casi *a* e *c*, con il sole di fronte alla fotocamera, un maggiore contrasto e quindi uniformità.

Le stesse immagini sono state acquisite in tre diverse condizioni di luce (Fig. 3): a. sul lato A della chioma il sole era di fronte all'operatore e diretto verso l'obiettivo della fotocamera (alle 09.00 ± 20 minuti); b. il sole era quasi allo zenit (alle 12.00 ± 20 minuti); c. il sole era dietro l'operatore e diretto verso le viti e lo sfondo (alle 15.00 ± 20 minuti), situazione opposta sul lato B della chioma, dove il sole era diretto verso le viti alle 09.00 ± 20 minuti.




Figura 3. Immagini delle viti (cv Catarratto) acquisite manualmente durante tre momenti del giorno con presenza di sfondo artificiale. *(a, b)* acquisizione effettuata sui due lati della chioma al mattino. *(c, d)* acquisizione effettuata sui due lati della chioma a mezzogiorno. *(e, f)* acquisizione effettuata sui due lati della chioma nel pomeriggio. Si noti come al variare della posizione del sole rispetto l'obiettivo della fotocamera, le ombre proiettate dai tralci sullo sfondo artificiale creino un disturbo d'intensità differente. Quasi nullo *(a, c, f)*, consistente *(b, d, e)*.

Dopo l'analisi delle immagini e la valutazione dei risultati ottenuti, le immagini di Nero d'Avola, Merlot e Tannat sono state acquisite in una singola condizione di luce (quella in cui sono stati ottenuti i migliori risultati nella prova su Catarratto) per ciascuna modalità di acquisizione (WB e NB) (Fig. 4). Successivamente, dopo l'acquisizione delle immagini, le viti sono state potate e il peso del legno è stato misurato utilizzando un dinamometro digitale per permettere il processo di validazione dei dati.




Figura 4. Immagini delle viti acquisite manualmente con e senza ausilio di sfondo artificiale nella condizione di illuminazione con sole posto frontalmente rispetto la fotocamera. (a, b) cv Merlot. (c, d) cv Nero d'Avola. (e, f) cv Tannat.

5.1.2 Analisi delle immagini

Le immagini acquisite sono state pre-processate e analizzate utilizzando il software open-source FIJI/ImageJ® e il suo plug-in *Trainable Weka Segmentation* (TWS) (Lormand et al., 2018). Il plug-in TWS utilizza algoritmi di apprendimento automatico per classificare gruppi di pixel di immagini RGB o in scala di grigi in diverse classi basate su caratteristiche visive simili, come colore, forma e texture. Il diagramma di flusso dei principali passaggi per stimare il peso del legno di potatura è mostrato nella Figura 5. Prima della segmentazione, è stata necessaria una segmentazione supervisionata, addestrando manualmente il classificatore a riconoscere insiemi di pixel di addestramento sulla regione di interesse (ROI) per ciascuna classe. Prima di tutto, poiché la velocità di processo di addestramento, segmentazione e misurazione può essere influenzata dalla risoluzione dell'immagine, tutte le immagini sono state ridimensionate da 5184 x 3456 a 1773 x 1182 pixel. Queste sono poi state caricate su FIJI/Imagej®, attivato il plug-in *Trainable Weka Segmentation* dalla barra dei menu (*Plugins > Segmentation > Trainable Weka Segmentation*) e sono state utilizzate le seguenti funzioni: *Gaussian blur*, per sfocare l'immagine; *Sobel filter*, per riconoscere i bordi dell'immagine; *Hessian matrix*, per identificare la forma degli oggetti; *Difference of gaussians*, per evidenziare i bordi e altri dettagli nell'immagine che variano in dimensione;

Membrane projections, per migliorare il contrasto lungo i bordi; *FastRandomForest*, un algoritmo ad albero decisionale che costruisce un albero di regole "if-then" per classificare i pixel dell'immagine in base al colore, alla forma e alla texture. Per l'addestramento, è stata selezionata un'immagine casuale dal dataset e utilizzata come campione. Sono state definite quattro classi all'interno dell'immagine denominate "legno di potatura" la ROI, "fusto e cordone", "fili di supporto" e "sfondo" disegnando manualmente dieci linee per ciascuna classe (lunghezza di circa 50 pixel e larghezza di 1 pixel). Il processo di addestramento ha prodotto quattro immagini (una per classe). Successivamente, il modello di segmentazione è stato applicato a tutte le immagini del dataset analizzando una serie di sei immagini per volta. Dalle immagini ottenute come risultato della segmentazione di TWS sono state utilizzate solamente quelle contenenti la classe ROI. Questo insieme di immagini è stato convertito in 8-bit e trasformato nel formato binario per ridurre la quantità di informazioni (*Image > Type > 8-Bit*). Successivamente, è stata estratta la ROI dall'immagine mediante la sogliatura automatica dell'immagine utilizzando il metodo di Otsu (Nobuyuki, 1979). Questo metodo calcola la soglia ottimale per un'immagine in scala di grigi, T_{otsu} , assumendo l'esistenza di due distribuzioni, lo sfondo e il primo piano, e massimizzando la loro varianza tra le classi. *If* I_b rappresenta un'immagine in scala di grigi b^* come una funzione bidimensionale nello spazio discreto i cui valori rientrano nell'intervallo $[0, \dots, 255]$:

$$ROI = \begin{cases} 0 & \text{if } I_b(x, y) \leq T_{otsu} \\ 255 & \text{otherwise} \end{cases} \quad (1)$$

In questo modo si è ottenuta un'immagine binaria (0 = nero e 255 = bianco) contenente solo la regione di interesse (ROI), ossia il legno di potatura, e i pixel dello sfondo (*Image > Adjust > Auto Threshold*). Per rimuovere manualmente le viti adiacenti a quella oggetto di studio è stato utilizzato lo strumento *Pencil*. Questo passaggio ha mirato ad impedire l'interferenza di tralci estranei alla vite oggetto di studio e ad evitare di influire sulla precisione del processo di validazione dei dati. Il numero di pixel della ROI è stato quindi conteggiato (*Analyze > Measure*).




Figura 5. Diagramma di flusso delle principali fasi del processo di analisi delle immagini. (a) immagine originale. (b) risultato della classificazione automatica. (c) estrazione automatica della *Region of Interest* (ROI). (d) binarizzazione dell'immagine per la conta dei pixel relativi alla ROI.

5.1.3 Analisi statistica

I dati ottenuti sono stati analizzati utilizzando il software statistico Minitab[®] versione 19 (Minitab, USA). La statistica descrittiva è stata applicata per valutare la variabilità dei dati e delle misurazioni del peso della potatura effettuato manualmente e tramite analisi delle immagini. Per valutare la correlazione tra il numero di pixel ottenuto dall'analisi e il peso della potatura misurato manualmente nelle diverse condizioni di acquisizione delle immagini e tra le cultivar, sono stati utilizzati modelli di regressione lineare, e i relativi coefficienti di determinazione (R^2) considerati significativi per $P \leq 0,01$. La precisione dei modelli elaborati sulla cultivar Catarratto, attraverso i quali è stato possibile determinare la condizione di acquisizione più idonea è stata valutata mediante il confronto di pendenza e intercetta delle rette di regressione e mediante il *Root Mean Square Error* (RMSE) e per i modelli globali tra le cultivar è stato calcolato anche il *Mean Absolute Percentage Error* (MAPE) in accordo con Paulus et al., (2014) attraverso le seguenti formule:

$$RMSE = \sqrt{\text{mean}(t - a)^2} \quad (2)$$

$$MAPE = mean \left(\left| \frac{t-a}{t} * 100 \right| \right) \quad (3)$$

Dove t (*target*) è il valore di riferimento, a (*actual*) il valore stimato.

Le misurazioni del peso del legno di potatura tra le cultivar sono state confrontate utilizzando una procedura di analisi della varianza (ANOVA) a un fattore e il test post-hoc di Tukey ($p < 0,05$).

5.2 Risultati

I risultati delle misurazioni preliminari del peso del legno di potatura ottenuto manualmente sono riportati nella Tabella 1. L'analisi della varianza e il test di Tukey mostrano come, tra le cultivar sussistessero significative differenze in termini di peso del legno, e le 174 piante coprissero un *range* che andava dai 55 g nella cultivar Tannat ai 1310 g nella cultivar Nero d'Avola. Per la cultivar Catarratto, sulla quale è stato condotto il test pilota, il peso del legno andava dagli 85 ai 955 g.

Tabella 1. Analisi della varianza del peso del legno di potatura per pianta misurato manualmente tra le cultivar. Max, valore massimo; Min, valore minimo.

Cultivar	Piante (n°)	Legno di potatura (g)	Min (g)	Max (g)
Catarratto	36	276,9 ± 27,1 b	85	955
Merlot	48	203,2 ± 14,2 bc	95	510
Nero d'Avola	50	568,7 ± 38,8 a	145	1310
Tannat	40	148,0 ± 9,1 c	55	270

Lettere differenti tra le cultivar indicano differenze statisticamente significative per $p < 0,05$ secondo il test di Tukey. I valori sono riportati come media ± errore standard.

5.2.1 Valutazione delle modalità di acquisizione delle immagini

Lo studio ha indagato la relazione lineare tra il numero di pixel estratto dalle immagini come legno di potatura e il peso effettivo della potatura valutato in vigneto, secondo diverse modalità d'acquisizione e condizione di luce. Il fine è stato di stabilire la migliore combinazione che permettesse una segmentazione e una stima più accurate. Il processo di segmentazione automatica ha permesso di escludere dalle immagini gli elementi relativi al fusto, ai fili di sostegno della struttura e allo sfondo (naturale o artificiale) senza richiedere intervento manuale, che è stato necessario invece ad escludere solamente gli elementi correttamente segmentati ma appartenenti a piante contigue. Il processo di segmentazione ha richiesto circa due minuti per essere completato per ogni gruppo di sei immagini processate simultaneamente (venti secondi per immagine). Per la modalità WB, le misurazioni del mattino hanno mostrato differenze significative tra i lati nord-ovest (A) e sud-est (B) della chioma in termini di valori di pendenza e intercetta. Il lato A ha generato un R^2 nettamente più elevato rispetto al lato B, dove il RMSE indicava una scarsa precisione nella stima del peso. Allo stesso modo, a mezzogiorno sono state osservate differenze significative tra i lati A e B in termini di valori di pendenza e intercetta, ma con un'accuratezza simile e più moderata su entrambi i lati della chioma. Nel pomeriggio, sono state riscontrate differenze significative tra i lati A e B in termini di valori di pendenza e intercetta in maniera opposta a quella del mattino. In

questo caso, il lato A ha generato un R^2 minore, mentre il lato B ha presentato l'accuratezza più elevata di tutti i casi studiati e il più basso RMSE (Tab. 2; Fig. 6).

Analogie sono state riscontrate nella modalità NB. Le acquisizioni del mattino hanno mostrato differenze significative tra i lati A e B in termini di valori di pendenza e intercetta e il lato A ha restituito l' R^2 maggiore. Le acquisizioni effettuate a mezzogiorno hanno mostrato nuovamente un'accuratezza moderata per entrambi i lati, mentre nel pomeriggio si è presentata nuovamente un'inversione nell'accuratezza tra i lati A e B, analogamente al caso della modalità WB, il lato A ha mostrato un'accuratezza inferiore, mentre il lato B ha mostrato l'accuratezza più elevata tra tutti i casi (Tab 3; Fig. 7).

Tabella 2. Metriche di valutazione dei modelli elaborati per ogni combinazione di illuminazione e lato della chioma con presenza di sfondo artificiale (WB).

Momento del giorno	Lato della chioma	n	p-value Pendenza	p-value Intercetta	RMSE (g)	R^2
Mattina	A	36	0,00	0,00	66,57	0,84
	B	36	0,00	0,14	138,25	0,30
Mezzogiorno	A	36	0,00	0,01	91,34	0,69
	B	36	0,00	0,10	125,23	0,42
Pomeriggio	A	36	0,00	0,11	141,25	0,27
	B	36	0,00	0,00	55,80	0,89

n, numero di casi; RMSE, Root mean square error; R^2 , coefficiente di determinazione.

Tabella 3. Metriche di valutazione dei modelli elaborati per ogni combinazione di illuminazione e lato della chioma con presenza di sfondo artificiale (NB).

Momento del giorno	Lato della chioma	n	p-value Pendenza	p-value Intercetta	RMSE (g)	R^2
Mattina	A	36	0,00	0,13	100,29	0,63
	B	36	0,00	0,20	123,76	0,44
Mezzogiorno	A	36	0,00	0,04	92,31	0,69
	B	36	0,00	0,16	105,54	0,59
Pomeriggio	A	36	0,00	0,14	100,29	0,63
	B	36	0,00	0,19	85,95	0,73

n, numero di casi; RMSE, Root mean square error; R^2 , coefficiente di determinazione.

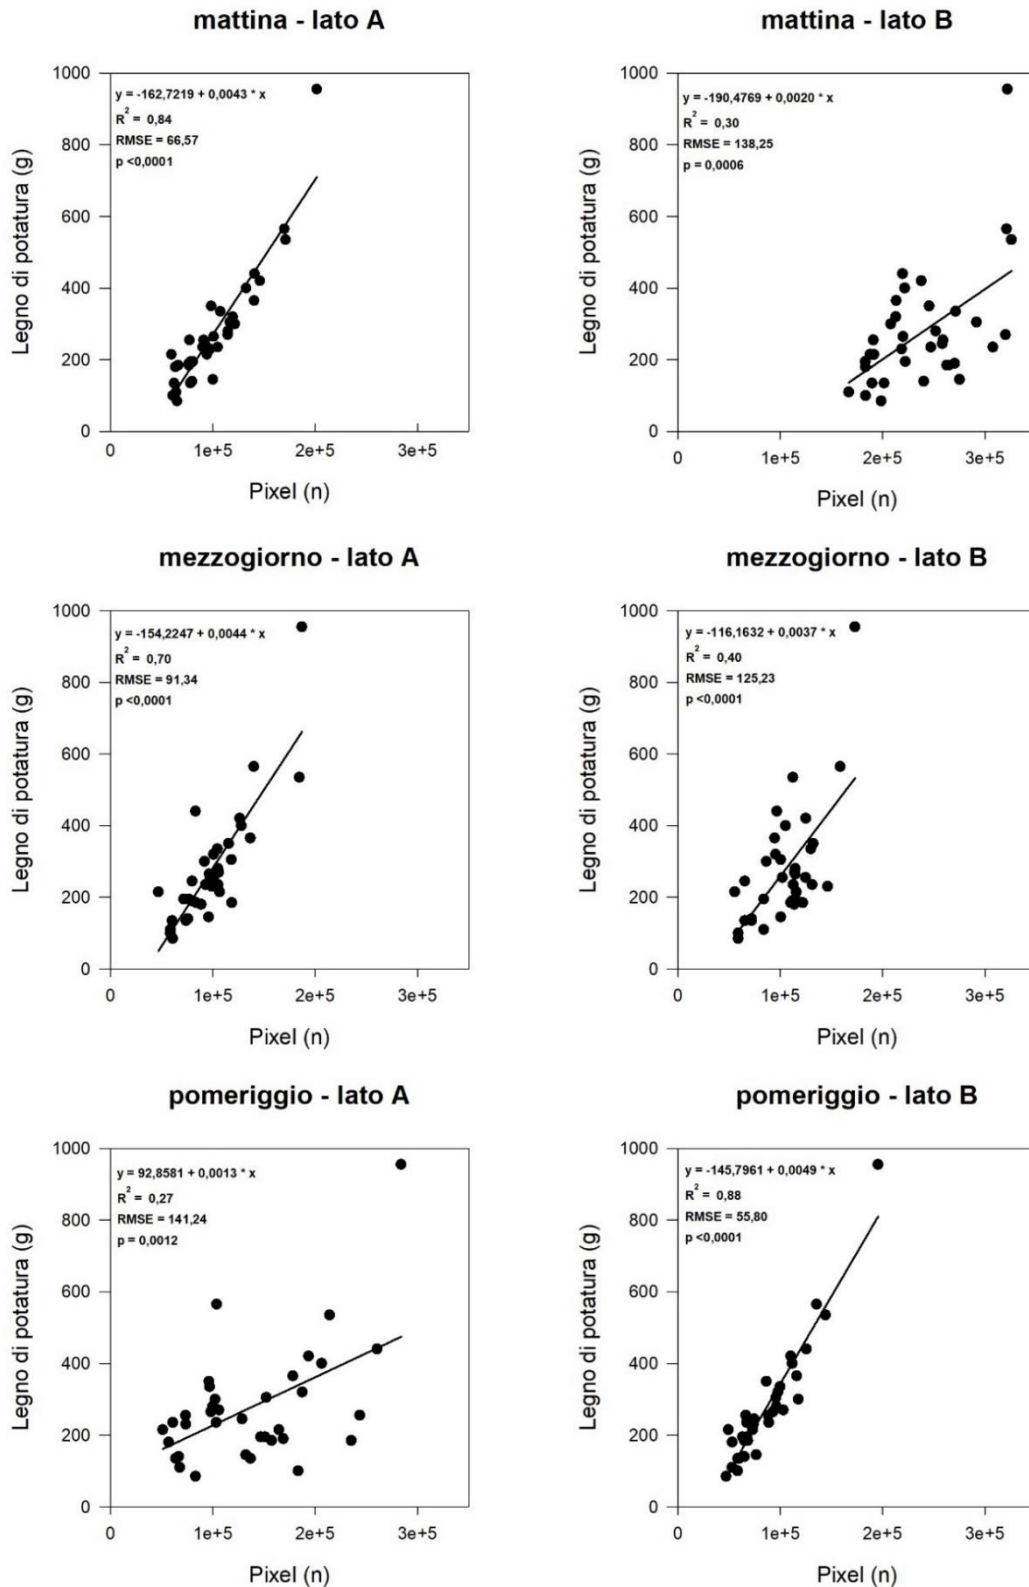


Figura 6. Correlazione tra il peso effettivo del legno di potatura (y) e il numero di pixel segmentato come “legno di potatura” (x) durante mattina, mezzogiorno e pomeriggio su entrambi i lati della chioma (A e B) utilizzando lo sfondo artificiale (WB). RMSE, *Root mean square error*; R^2 , coefficiente di determinazione.

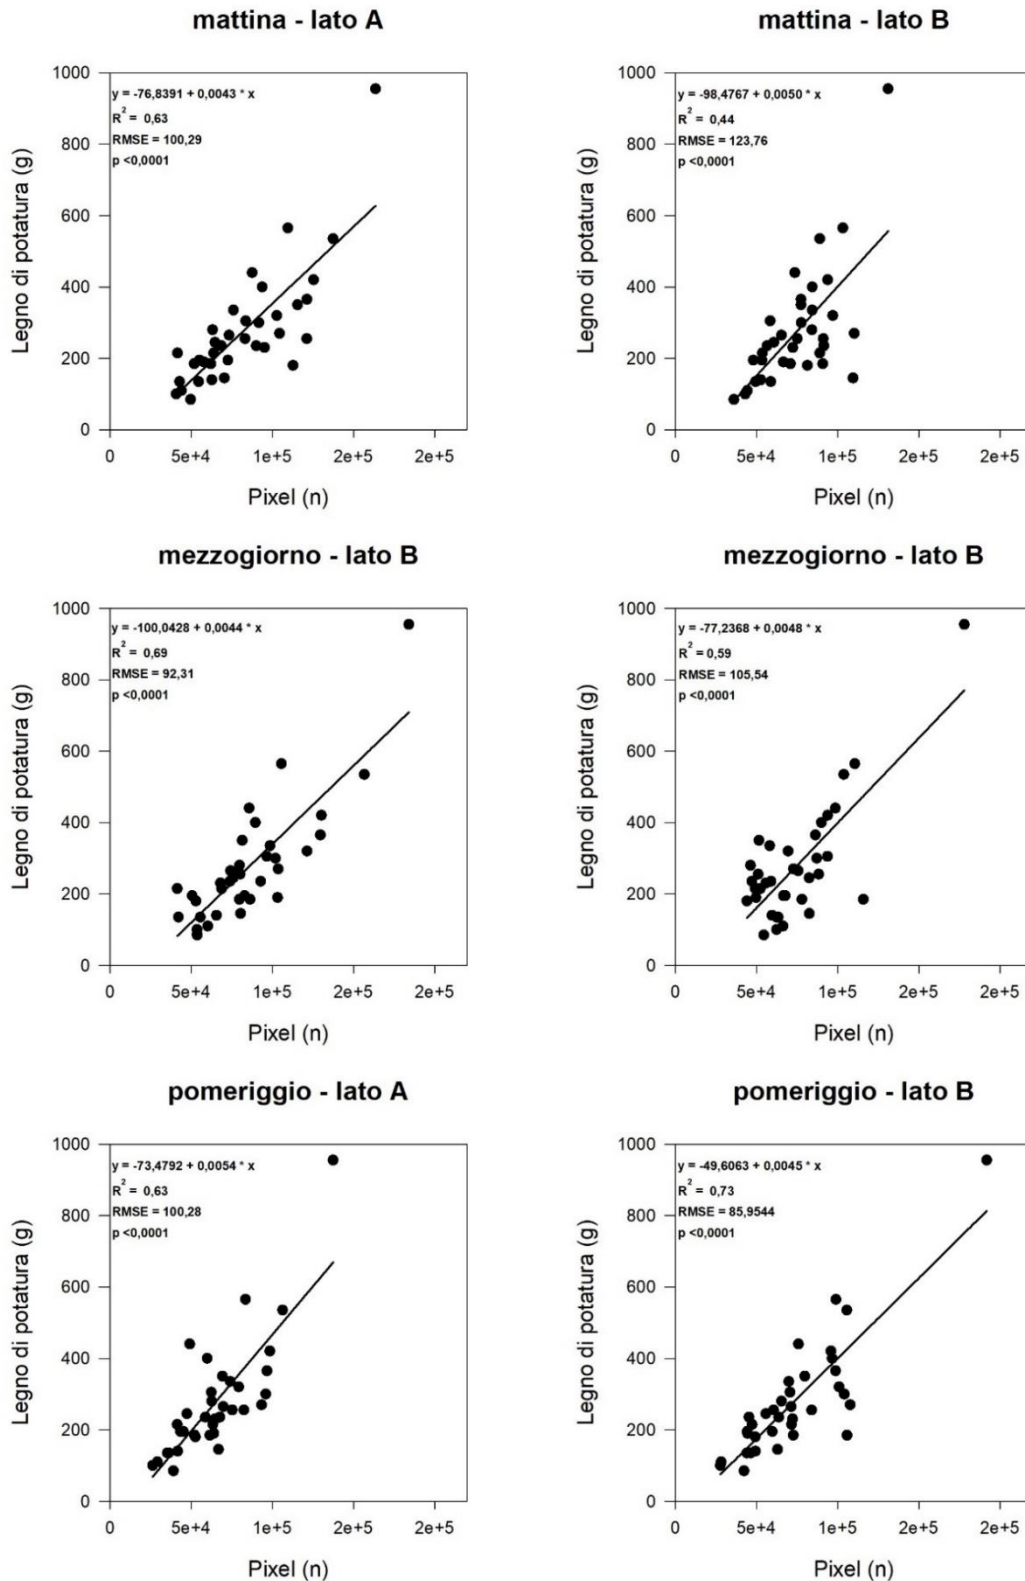


Figura 7. Correlazione tra il peso effettivo del legno di potatura (y) e il numero di pixel segmentato come “legno di potatura” (x) durante mattina, mezzogiorno e pomeriggio su entrambi i lati della chioma (A e B) senza l’utilizzo dello sfondo artificiale. (NB). RMSE, *Root mean square error*; R^2 , coefficiente di determinazione.

5.2.2 Effetto dello sfondo ed effetto della cultivar

Avendo stabilito dall'analisi delle immagini acquisite sulla cv Catarratto la condizione di illuminazione più efficace, che è risultata essere quella che prevedeva la fotocamera posizionata frontalmente alla posizione del sole in direzione delle piante (lato A della chioma al mattino e lato B della chioma nel caso del pomeriggio), sulle immagini delle altre tre cultivar così acquisite con e senza ausilio di sfondo artificiale, è stato eseguito lo stesso processo di segmentazione e correlazione acquisite. Le figure 8 e 9 mostrano un confronto fra le quattro cultivar nelle due modalità di acquisizione. I valori restituiti dalle correlazioni nelle modalità WB e NB sono risultati simmetrici. Nelle cultivar Catarratto e Merlot la modalità WB ha generato un R^2 di poco superiore rispetto alla modalità NB, differenza che invece è risultata trascurabile per il Nero d'Avola e il Tannat. Per quest'ultima, tuttavia, la correlazione tra le variabili non è risultata significativa.

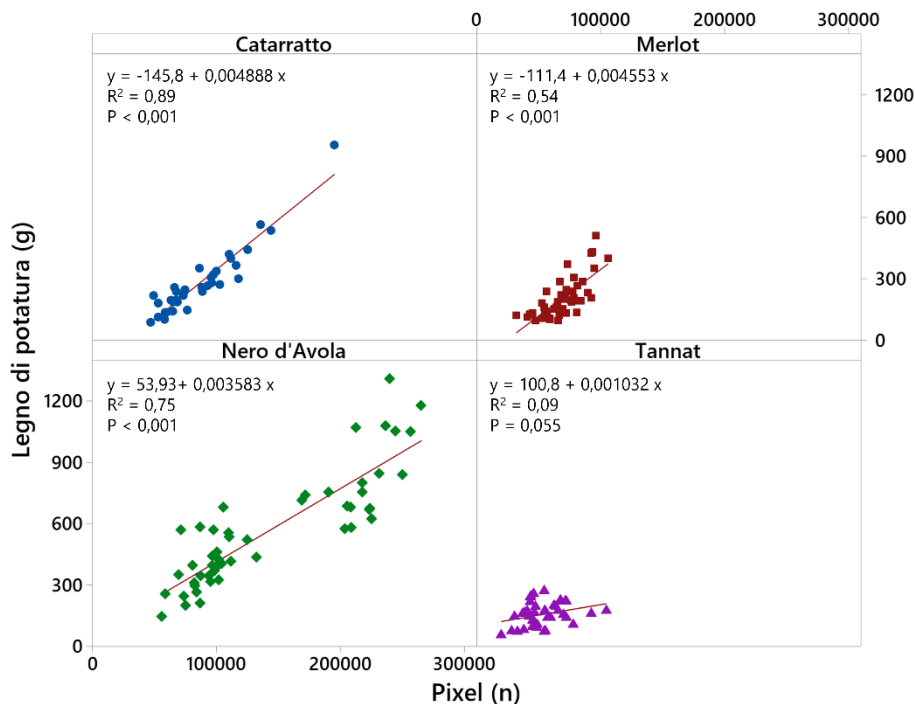


Figura 8. Correlazione tra il peso effettivo del legno di potatura (y) e il numero di pixel segmentato come “legno di potatura” (x) con utilizzo di sfondo artificiale (WB) nelle cultivar Catarratto, Merlot e Nero d'Avola. Per la cultivar Catarratto è riportato il modello che presentava la migliore precisione tra le modalità d'acquisizione illustrate. R^2 , coefficiente di determinazione.

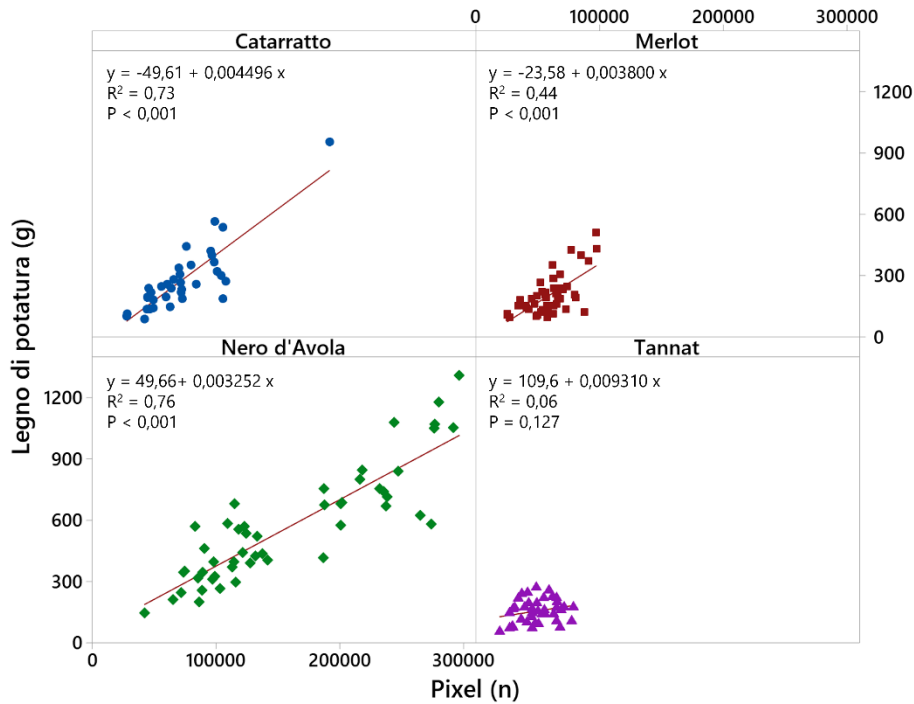


Figura 9. Correlazione tra il peso effettivo del legno di potatura (y) e il numero di pixel segmentato come “legno di potatura” (x) senza utilizzo di sfondo artificiale (NB) nelle cultivar Catarratto, Merlot e Nero d’Avola. Per la cultivar Catarratto è riportato il modello che presentava la migliore precisione tra le modalità d’acquisizione illustrate. R², coefficiente di determinazione.

I modelli di regressione globali (Fig. 10 e 11) tra le tre cultivar che presentavano una correlazione significativa tra pixel e peso del legno mostrano come indipendentemente dall'uso dello sfondo artificiale, l'accuratezza della stima sia simile per le due modalità di acquisizione. Un R² di 0,84 per la modalità WB e di 0,83 per la modalità NB, con un RMSE di 102,3 e 104,1 g e un MAPE del 24,5 e 25,9% rispettivamente.




Figura 10. Modello di regressione globale tra il peso effettivo del legno di potatura (y) e il numero di pixel (x) segmentato come “legno di potatura” con utilizzo di sfondo artificiale (WB) nelle cultivar Catarratto, Merlot e Nero d’Avola. *Root Mean Square Error* (RMSE) = 102,3 g; *Mean Absolute Percentage Error* (MAPE) = 24,5%. R^2 , coefficiente di determinazione. $adjR^2$, coefficiente di determinazione adattato.




Figura 11. Modello di regressione globale tra il peso effettivo del legno di potatura (y) e il numero di pixel segmentato come “legno di potatura” (x) senza utilizzo di sfondo artificiale (NB) nelle cultivar Catarratto, Merlot e Nero d’Avola. *Root mean square error* (RMSE) = 104,2 g; *Mean Absolute Percentage Error* (MAPE) = 25,9%. R^2 , coefficiente di determinazione. $adjR^2$, coefficiente di determinazione adattato.

5.3 Discussione

I risultati ottenuti contribuiscono con nuove informazioni alla possibilità di utilizzare l'analisi delle immagini per stimare il peso del legno di potatura in vigneto senza ricorrere a metodi distruttivi. Come riscontrato in altri studi che supportano tali possibilità, una delle principali limitazioni legate a questa esigenza, operando in condizioni di pieno campo, è l'influenza delle condizioni di luce, ovviamente non controllabili, e di oggetti di disturbo all'interno delle immagini oggetto di analisi (altre piante sullo sfondo, pali e fili di sostegno, elementi naturali di vario genere) e quindi, la necessità di utilizzare sfondi o illuminazione artificiale (Kicherer et al., 2017; Millan et al., 2018). L'uso di uno sfondo artificiale aiuta a creare un ambiente controllato per l'acquisizione delle immagini, rendendo più facile la segmentazione e l'analisi di parti specifiche della pianta come ad esempio le infiorescenze, i grappoli, i tralci o le foglie poiché l'accuratezza della stima automatica può variare a seconda della presenza di oggetti di disturbo naturalmente presenti in un ambiente caratterizzato da condizioni di illuminazione diverse e sfondi non omogenei (Millan et al., 2018; Victorino et al., 2020; Íñiguez et al., 2021). Allo stesso modo, l'illuminazione artificiale migliora la qualità dell'immagine, il contrasto tra i colori e l'efficacia degli algoritmi di estrazione delle informazioni. Questi accorgimenti, tuttavia, potrebbero non essere pratici e applicabili nel contesto vigneto (Millan et al., 2018; Victorino et al., 2020; Íñiguez et al., 2021). In questo studio, si è cercato di superare tali limitazioni valutando l'effetto di tre condizioni di illuminazione che si verificano durante il giorno e inoltre indagando un diverso angolo di acquisizione per la fotocamera. Una delle principali variabili che influenzavano la qualità delle immagini, e quindi la stima, era l'ombra proiettata dai tralci su altri oggetti all'interno dell'immagine. Infatti, laddove l'immagine presentava variazioni eccessive in termini di colore e consistenza per una data classe (ad esempio, "legno di potatura", la ROI), si è osservata una sovrastima del peso del legno. Ciò si è verificato nei casi in cui il sole si trovava alle spalle della fotocamera (indipendentemente dai casi WB o NB anche se più accentuato nel primo), nel pomeriggio per il lato A della chioma e al mattino nel lato B della chioma. In questi casi, i pixel relativi alla classe di segmentazione denominata "legno di potatura" sono risultati variabili in termini di colore e le ombre proiettate sullo sfondo sono risultate un elemento di disturbo influente poiché l'algoritmo di segmentazione automatica le ha identificate come tralci veri e propri. Per questo motivo, stabilire quale modalità di acquisizione sia migliore in un contesto così variabile come quello di pieno campo, permette indirettamente di ottenere immagini che contengono già a monte meno dettagli e quindi, più facilmente segmentabili. Al contrario, nei casi in cui il sole era di fronte alla fotocamera (al mattino sul lato A e al pomeriggio sul lato B), si sono ottenute immagini con un maggiore contrasto, con i tralci che risaltavano

maggiormente sullo sfondo e che erano rappresentati da pixel più omogenei in termini di colore. Dopo aver determinato la modalità di acquisizione più efficace per la segmentazione sulla sola cultivar Catarratto, i risultati ottenuti della segmentazione e la relativa correlazione sulle altre cultivar (Nero d'Avola, Tannat e Merlot) sono stati valutati per generare un modello globale che mettesse a confronto modalità WB e NB. Si è evidenziato che la presenza o meno dello sfondo, in questo caso, è stata irrilevante nel determinare differenze sostanziali nella correlazione. Tale risultato, come già proposto da Millan et al., (2018) che hanno operato in condizioni notturne con luce artificiale, fa emergere come sia potenzialmente possibile adottare il metodo di stima anche di giorno e senza l'utilizzo dello sfondo. Indipendentemente dall'uso dello sfondo artificiale, il processo di segmentazione ha dato risultati comparabili in termini di R^2 ed errore nella stima del peso del legno, suggerendo che l'applicazione di tale strategia per minimizzare la complessità della scena è un'opzione valida. Una possibile limitazione da superare per applicazione di questo metodo di stima, tuttavia, potrebbe essere rappresentata dall'occlusione, ovvero la situazione in cui parti dei tralci sono nascoste o oscurate da altri tralci o dai cordoni, rendendo difficile la determinazione delle loro dimensioni o del loro peso. L'occlusione può verificarsi a causa della normale distribuzione nello spazio dei germogli durante le fasi vegetative in cui i tralci si sovrappongono l'uno all'altro, per densità via via maggiori con l'aumentare del vigore delle piante, o per via di un portamento decombente tipico della cultivar. Ciò porta ad ottenere immagini in cui i pixel dei tralci sono inevitabilmente sottostimati. Infatti, come si può notare dai risultati ottenuti nel presente studio, all'aumentare del vigore e del peso del legno la precisione della stima tende a diminuire. Questo risultato conferma quanto riscontrato in altri studi simili in cui sono state analizzate immagini scattate con sfondi artificiali o di notte con illuminazione artificiale (Kicherer et al., 2017; Millan et al., 2018). Kicherer et al., (2017) hanno valutato un set di 39 immagini acquisite senza sfondo in condizioni di luce diurna e hanno riscontrato un R^2 di 0,84 e un RMSE di 120 g operando una segmentazione manuale ma solo un R^2 di 0,44 e un RMSE di 230 g operando con una segmentazione automatizzata, a causa della difficoltà dell'algorithmo di identificare viti caratterizzate da tralci sottili e viticci abbondanti. Ciò avvalorava i risultati ottenuti nel presente studio in cui la segmentazione è avvenuta automaticamente incorporando a priori informazioni sulla scena, grazie alla definizione delle quattro classi di segmentazione e adottando caratteristiche che tengono conto del colore per distinguere meglio la pianta in primo piano rispetto lo sfondo. Millan et al., (2018) hanno operato su un set di 44 immagini ottenendo un R^2 di 0,91 e un RMSE di 87,7 g utilizzando uno sfondo artificiale, mentre un R^2 di 0,77 e un RMSE di 148 g su immagini acquisite di notte senza l'uso dello sfondo, a causa del rumore prodotto dell'acquisizione in movimento delle

immagini (camera montata su mezzo). Anche questi risultati sono leggermente al di sotto di quelli del presente studio, per quanto l'assenza di un valore medio di peso del legno in cui gli autori hanno operato rende poco confrontabili i RMSE. Millan et al., (2018) hanno evidenziato, inoltre, che il coefficiente di determinazione è diminuito quando sono stati rimossi i valori di peso del legno di potatura al di sotto dei 150 g. In definitiva, l'aumento della variabilità contribuisce ad ottenere un risultato più solido, ed i risultati ottenuti sul Tannat lo confermano. Ciò suggerisce che un set di dati più ampio può contribuire a ottenere un modello più stabile. Negli studi di Kricherer et al., (2017) e Millan et al., (2019) non è stato esplorato l'effetto della cultivar. In particolare, i primi hanno analizzato le immagini di 39 piante di vite non innestate di diverse accessioni senza specificare quali. Millan et al., (2019) invece, hanno operato sulla cv. Tempranillo. Nel presente studio si è osservato che seppur non in maniera prevalente, la cultivar può avere un effetto nel determinare la correlazione tra il numero di pixel e il peso effettivo del legno, anche se questo effetto tende a confondersi con una semplice differenza in termini di variabilità del dataset, infatti i valori di R^2 più alti sono stati generati nei modelli del Catarratto e del Nero d'Avola, ossia quelli che presentavano un'ampiezza maggiore tra la pianta col minore e col maggiore peso del legno. Ciò spinge a pensare che future analisi dovrebbero concentrarsi sulla determinazione delle migliori condizioni di acquisizione che consentano di facilitare il processo di segmentazione e quindi estrazione del numero di pixel laddove le piante presentano alti livelli di occlusione e sulla valutazione di un più largo numero di cultivar, prendendo in considerazione il vigore e l'habitus vegetativo che possono contribuire a causare condizioni di occlusione molto variabili e quindi valutare se un modello globale e cultivar-indipendente possa essere generato.

5.4 Conclusioni

Il presente studio ha contribuito: (i) allo sviluppo di un metodo pratico, applicabile e ripetibile, per la valutazione non distruttiva del peso del legno di potatura in vigneto, attraverso l'analisi delle immagini; (ii) i risultati ottenuti indicano che acquisire le immagini attraverso specifiche modalità migliora considerevolmente i processi di segmentazione e stima del peso del legno; (iii) l'uso dello sfondo artificiale, una delle maggiori limitazioni dell'analisi di immagini in viticoltura può essere scongiurato attraverso la semplice inclinazione della fotocamera; (iv) la componente cultivar non sembrerebbe rappresentare una limitazione. I risultati ottenuti evidenziano il potenziale di questa metodologia nell'automazione dei processi di gestione del vigneto. Tuttavia, ulteriori ricerche sono necessarie per affinare il modello proposto, esplorare ulteriori variabili influenti e valutare l'adattabilità pratica dell'approccio in contesti aziendali reali anche grazie allo sviluppo di app per

supporto mobile che possano permettere l'arricchimento delle casistiche attraverso l'utilizzo da parte di una più ampia utenza. Con il progresso continuo della tecnologia e l'innovazione nel settore agricolo, l'analisi delle immagini potrebbe svolgere un ruolo sempre più importante nella gestione sostenibile e intelligente dei vigneti, contribuendo a ottimizzare le pratiche colturali e migliorare le prestazioni vitivinicole.

5.5 Riferimenti bibliografici

- Aquino, A., Millan, B., Diago, M.-P., and Tardaguila, J. (2018). Automated early yield prediction in vineyards from on-the-go image acquisition. *Comput. Electron. Agric.* 144, 26–36. doi: 10.1016/j.compag.2017.11.026.
- Aquino, A., Millan, B., Gutiérrez, S., and Tardaguila, J. (2015). Grapevine flower estimation by applying artificial vision techniques on images with uncontrolled scene and multi-model analysis. *Comput. Electron. Agric.* 119, 92–104. doi: 10.1016/j.compag.2015.10.009.
- Archer, E., and Schalkwyk, D. van (2007). The Effect of Alternative Pruning Methods on the Viticultural and Oenological Performance of Some Wine Grape Varieties. *South Afr. J. Enol. Vitic.* 28, 107–139. doi: 10.21548/28-2-1466.
- Botterill, T., Paulin, S., Green, R., Williams, S., Lin, J., Saxton, V. (2017). A Robot System for Pruning Grape Vines. *J. Field Robot.* 34, 1100–1122. doi: 10.1002/rob.21680.
- Bramley, R. g. v., Trought, M. c. t., and Praat, J.-P. (2011). Vineyard variability in Marlborough, New Zealand: characterising variation in vineyard performance and options for the implementation of Precision Viticulture. *Aust. J. Grape Wine Res.* 17, 72–78. doi: 10.1111/j.1755-0238.2010.00119.x.
- Calonnec, A., Burie, J. B., Langlais, M., Guyader, S., Saint-Jean, S., Sache, I., et al. (2013). Impacts of plant growth and architecture on pathogen processes and their consequences for epidemic behaviour. *Eur. J. Plant Pathol.* 135, 479–497.
- Casser, V. (2016). Using Feedforward Neural Networks for Color Based Grape Detection in Field Images. Proceedings of the CSCUBS. 23-33.
- Cubero, S., Diago, M. p., Blasco, J., Tardaguila, J., Prats-Montalbán, J. m., Ibáñez, J., et al. (2015). A new method for assessment of bunch compactness using automated image analysis. *Aust. J. Grape Wine Res.* 21, 101–109. doi: 10.1111/ajgw.12118.
- De Bei, R., Fuentes, S., Gilliham, M., Tyerman, S., Edwards, E., Bianchini, N., et al. (2016). VitiCanopy: A Free Computer App to Estimate Canopy Vigor and Porosity for Grapevine. *Sensors* 16, 585. doi: 10.3390/s16040585.
- Diago, M. P., Krasnow, M., Bubola, M., Millan, B., and Tardaguila, J. (2016). Assessment of Vineyard Canopy Porosity Using Machine Vision. *Am. J. Enol. Vitic.* 67, 229–238. doi: 10.5344/ajev.2015.15037.
- Diago, M. P., Sanz-Garcia, A., Millan, B., Blasco, J., and Tardaguila, J. (2014). Assessment of flower number per inflorescence in grapevine by image analysis under field conditions. *J. Sci. Food Agric.* 94, 1981–1987. doi: 10.1002/jsfa.6512.
- Diago, M.-P., Correa, C., Millán, B., Barreiro, P., Valero, C., and Tardaguila, J. (2012). Grapevine Yield and Leaf Area Estimation Using Supervised Classification Methodology on RGB Images Taken under Field Conditions. *Sensors* 12, 16988–17006. doi: 10.3390/s121216988.
- Dobrowski, S. Z., Ustin, S. L., and Wolpert, J. A. (2003). Grapevine dormant pruning weight prediction using remotely sensed data. *Aust. J. Grape Wine Res.* 9, 177–182. doi: 10.1111/j.1755-0238.2003.tb00267.x.

- Dunn, G. M., and Martin, S. R. (2004). Yield prediction from digital image analysis: A technique with potential for vineyard assessments prior to harvest. *Aust. J. Grape Wine Res.* 10, 196–198. doi: 10.1111/j.1755-0238.2004.tb00022.x.
- Fernandes, M., Scaldaferrì, A., Fiameni, G., Teng, T., Gatti, M., Poni, S., et al. (2021). Grapevine Winter Pruning Automation: On Potential Pruning Points Detection through 2D Plant Modeling using Grapevine Segmentation., in *11th Annual International Conference on CYBER Technology in Automation, Control, and Intelligent Systems (CYBER)*. 27-31 July 2021. 13–18. doi: 10.1109/CYBER53097.2021.9588303.
- Fiorani, F., and Schurr, U. (2013). Future scenarios for plant phenotyping. *Annu. Rev. Plant Biol.* 64, 267–291.
- Gao, M., and Lu, T. (2006). Image Processing and Analysis for Autonomous Grapevine Pruning., in *2006 International Conference on Mechatronics and Automation*, 922–927. doi: 10.1109/ICMA.2006.257748.
- García-Fernández, M., Sanz-Ablanedo, E., Pereira-Obaya, D., and Rodríguez-Pérez, J. R. (2021). Vineyard Pruning Weight Prediction Using 3D Point Clouds Generated from UAV Imagery and Structure from Motion Photogrammetry. *Agronomy* 11, 2489. doi: 10.3390/agronomy11122489.
- Gatti, M., Dosso, P., Maurino, M., Merli, M. C., Bernizzoni, F., José Pirez, F., et al. (2016). MECS-VINE®: A New Proximal Sensor for Segmented Mapping of Vigor and Yield Parameters on Vineyard Rows. *Sensors* 16, 2009. doi: 10.3390/s16122009.
- Guadagna, P., Fernandes, M., Chen, F., Santamaria, A., Teng, T., Frioni, T., et al. (2023). Using deep learning for pruning region detection and plant organ segmentation in dormant spur-pruned grapevines. *Precis. Agric.* 24, 1547–1569.
- Hall, A., and Wilson, M. A. (2013). Object-based analysis of grapevine canopy relationships with winegrape composition and yield in two contrasting vineyards using multitemporal high spatial resolution optical remote sensing. *Int. J. Remote Sens.* 34, 1772–1797. doi: 10.1080/01431161.2012.726753.
- Herzog, K. (2023). Initial steps for high-throughput phenotyping in vineyards. *Aust. N. Z. Grapegrow. Winemak.*, 54–59. doi: 10.3316/informit.256250437348632.
- Howell, G. S. (2001). Sustainable Grape Productivity and the Growth-Yield Relationship: A Review. *Am. J. Enol. Vitic.* 52, 165–174. doi: 10.5344/ajev.2001.52.3.165.
- Íñiguez, R., Palacios, F., Barrio, I., Hernández, I., Gutiérrez, S., and Tardaguila, J. (2021). Impact of Leaf Occlusions on Yield Assessment by Computer Vision in Commercial Vineyards. *Agronomy* 11, 1003. doi: 10.3390/agronomy11051003.
- Karoglan, M., Osrečak, M., Maslov, L., and Kozina, B. (2014). Effect of cluster and berry thinning on Merlot and Cabernet Sauvignon wines composition. *Czech J. Food Sci.*, 32 (5).
- Kicherer, A., Klodt, M., Sharifzadeh, S., Cremers, D., Töpfer, R., and Herzog, K. (2017). Automatic image-based determination of pruning mass as a determinant for yield potential in grapevine management and breeding. *Aust. J. Grape Wine Res.* 23, 120–124. doi: 10.1111/ajgw.12243.
- Kliwer, W. M., and Dokoozlian, N. K. (2005). Leaf Area/Crop Weight Ratios of Grapevines: Influence on Fruit Composition and Wine Quality. *Am. J. Enol. Vitic.* 56, 170–181. doi: 10.5344/ajev.2005.56.2.170.
- Klodt, M., Herzog, K., Töpfer, R., and Cremers, D. (2015). Field phenotyping of grapevine growth using dense stereo reconstruction. *BMC Bioinformatics* 16, 143. doi: 10.1186/s12859-015-0560-x.
- Lopes, C., Graça, J., and Monteiro, A. (2021). Accurate estimation of grapevine bunch weight using image analysis: a case study with two Portuguese cultivars. *Acta Hort.*, 1314, 117-124.
- Lormand, C., Zellmer, G. F., Németh, K., Kilgour, G., Mead, S., Palmer, A. S., et al. (2018). Weka Trainable Segmentation Plugin in ImageJ: A Semi-Automatic Tool Applied to Crystal Size Distributions of Microlites in Volcanic Rocks. *Microsc. Microanal.* 24, 667–675. doi: 10.1017/S1431927618015428.

- Luo, L., Tang, Y., Zou, X., Wang, C., Zhang, P., and Feng, W. (2016). Robust Grape Cluster Detection in a Vineyard by Combining the AdaBoost Framework and Multiple Color Components. *Sensors* 16, 2098. doi: 10.3390/s16122098.
- Millan, B., Velasco-Forero, S., Aquino, A., and Tardaguila, J. (2018). On-the-Go Grapevine Yield Estimation Using Image Analysis and Boolean Model. *J. Sens.* 2018, e9634752. doi: 10.1155/2018/9634752.
- Mohimont, L., Alin, F., Rondeau, M., Gaveau, N., and Steffanel, L. A. (2022). Computer Vision and Deep Learning for Precision Viticulture. *Agronomy* 12, 2463. doi: 10.3390/agronomy12102463.
- Palacios, F., Bueno, G., Salido, J., Diago, M. P., Hernández, I., and Tardaguila, J. (2020). Automated grapevine flower detection and quantification method based on computer vision and deep learning from on-the-go imaging using a mobile sensing platform under field conditions. *Comput. Electron. Agric.* 178, 105796. doi: 10.1016/j.compag.2020.105796.
- Palliotti, A., Poni, S., and Silvestroni, O. (2018). *Manuale di viticoltura*. Edagricole. New Business Media, 3, 39–57.
- Petrie, P. R., Trought, M. C., and Howell, G. S. (2000). Growth and dry matter partitioning of Pinot Noir (*Vitis vinifera* L.) in relation to leaf area and crop load. *Aust. J. Grape Wine Res.* 6, 40–45.
- Petrie, P. R., Trought, M. C. t., and Howell, G. S. (2000). Fruit composition and ripening of Pinot Noir (*Vitis vinifera* L.) in relation to leaf area. *Aust. J. Grape Wine Res.* 6, 46–51. doi: 10.1111/j.1755-0238.2000.tb00161.x.
- Pisciotta, A., Di Lorenzo, R., Novara, A., Laudicina, V. A., Barone, E., Santoro, A., et al. (2021). Cover crop and pruning residue management to reduce nitrogen mineral fertilization in mediterranean vineyards. *Agronomy* 11, 164.
- Poni, S., Tombesi, S., Palliotti, A., Ughini, V., and Gatti, M. (2016). Mechanical winter pruning of grapevine: Physiological bases and applications. *Sci. Hortic.* 204, 88–98. doi: 10.1016/j.scienta.2016.03.046.
- Roscher, R., Herzog, K., Kunkel, A., Kicherer, A., Töpfer, R., and Förstner, W. (2014). Automated image analysis framework for high-throughput determination of grapevine berry sizes using conditional random fields. *Comput. Electron. Agric.* 100, 148–158.
- Santesteban, L. G. (2019). Precision viticulture and advanced analytics. A short review. *Food Chem.* 279, 58–62. doi: 10.1016/j.foodchem.2018.11.140.
- Siebers, M. H., Edwards, E. J., Jimenez-Berni, J. A., Thomas, M. R., Salim, M., and Walker, R. R. (2018). Fast Phenomics in Vineyards: Development of GRover, the Grapevine Rover, and LiDAR for Assessing Grapevine Traits in the Field. *Sensors* 18, 2924. doi: 10.3390/s18092924.
- Smart, R., and Robinson, M. (1991). Sunlight into wine: a handbook for winegrape canopy management. *Sunlight Wine Handb. Winegrape Canopy Manag.* Winetitles: Adelaide, Australia, 1991.
- Tagarakis, A., Koundouras, S., Fountas, S., and Gemtos, T. (2018). Evaluation of the use of LIDAR laser scanner to map pruning wood in vineyards and its potential for management zones delineation. *Precis. Agric.* 19, 334–347.
- Taylor, J. A., and Bates, T. R. (2021). Comparison of Different Vegetative Indices for Calibrating Proximal Canopy Sensors to Grapevine Pruning Weight. *Am. J. Enol. Vitic.* 72, 279–283. doi: 10.5344/ajev.2021.20042.
- Tomasi, D., Gaiotti, F., Petoumenou, D., Lovat, L., Belfiore, N., Boscaro, D., et al. (2020). Winter Pruning: Effect on Root Density, Root Distribution and Root/Canopy Ratio in *Vitis vinifera* cv. Pinot Gris. *Agronomy* 10, 1509. doi: 10.3390/agronomy10101509.
- Urretavizcaya, I., Miranda, C., Royo, J. b., and Santesteban, L. g. (2015). “Within-vineyard zone delineation in an area with diversity of training systems and plant spacing using parameters of vegetative growth and crop load,” in *Precision agriculture '15*, (Wageningen Academic Publishers), 479–486. doi: 10.3920/978-90-8686-814-8_59.
- Urretavizcaya, I., Royo, J. B., Miranda, C., Tisseyre, B., Guillaume, S., and Santesteban, L. G. (2017). Relevance of sink-size estimation for within-field zone delineation in vineyards. *Precis. Agric.* 18, 133–144. doi: 10.1007/s11119-016-9450-0.

Viala, P., and Ravaz, L. (1908). *American vines (resistant stock): their adaptation, culture, grafting and propagation*. Press of Freygang-Leary: San Francisco, CA, USA, 1908.

Victorino, G., Braga, R., Santos-Victor, J., and Lopes, C. M. (2020). Yield components detection and image-based indicators for non-invasive grapevine yield prediction at different phenological phases. *OENO One*. 54 (4), 833-848
doi: 10.20870/oeno-one.2020.54.4.3616

Victorino, G., Poblete-Echeverría, C., and Lopes, C. M. (2022). A multicultivar approach for grape bunch weight estimation using image analysis. *Horticulturae* 8 (3), 233.

6 Modelli suolo-pianta-atmosfera per la stima del potenziale idrico del germoglio (Ψ_{stem}) in *Vitis vinifera* L. (cv Touriga Nacional)

Il cambiamento climatico ha determinato e determinerà nei prossimi anni temperature più elevate nella maggior parte delle aree viticole del mondo (Schultz, 2000; Lee et al., 2023). Le regioni idonee per lo sviluppo della vite sono convenzionalmente situate tra i 30° e i 50° di latitudine nord e tra i 30° e i 40° di latitudine sud, e l'aumento termico potrebbe spostare questa fascia verso latitudini più elevate (Amerine et al., 1980; Jones et al., 2005; Jones e Webb, 2010; Moriondo et al., 2013). I cambiamenti, tuttavia, non riguardano solamente slittamenti delle medie termiche tra una stagione all'altra su scala globale, ma anche un'accentuazione degli eventi climatici estremi su scala locale, come piogge torrenziali non ben distribuite e lunghi periodi di siccità durante la stagione (Easterling et al., 2000; Ramos et al., 2008; Cogato et al., 2019), oltre che una crescente domanda evapotraspirativa (Fraga et al., 2016). Le variazioni dei modelli climatici esercitano una pressione sempre maggiore anche sulle risorse idriche, limitando ulteriormente il loro utilizzo per scopi agricoli, specie nelle regioni caratterizzate da climi caldo-aridi dove la disponibilità idrica è storicamente limitata (Costa et al., 2007, 2016). Lo sviluppo della vite è altamente sensibile alle variazioni nei regimi termici e la crescente scarsità di acqua potrebbe compromettere gli equilibri complessivi del suo ciclo annuale e vitale nel contesto vigneto (Malek et al., 2018; Rocha et al., 2020; Tian et al., 2023), specie se si considera che in contrasto a tale scarsità, la viticoltura dipenderà sempre di più dall'irrigazione nei momenti di maggiore stress della stagione (Fraga et al., 2016, 2018). Sebbene la vite sia una specie che si adatta alla siccità (Chaves et al., 2010) e deficit idrici moderati aumentino il potenziale produttivo della pianta e la qualità dell'uva (van Leeuwen et al., 2009; Attia et al., 2010; Sofu et al., 2013; Pons et al., 2017; Pisciotta et al., 2018; Triolo et al., 2019; Barbagallo et al., 2021), deficit più gravi possono indurre una riduzione dell'efficienza fotosintetica, un conseguente rallentamento nello sviluppo vegetativo, una riduzione delle rese, ed un peggioramento della qualità complessiva di uva e vino (Escalona et al., 2000; Ojeda et al., 2001; Pellegrino et al., 2005a; van Leeuwen et al., 2009; Lovisolo et al., 2010; Zarrouk et al., 2012; Triolo et al., 2018). In più, deficit idrici precoci in prossimità della fioritura possono anche compromettere la fertilità delle gemme per la stagione successiva, e di conseguenza le condizioni di un'annata possono influenzare le successive (Guilpart et al., 2014). Tutto ciò chiaramente può avere effetti negativi sulla sostenibilità dell'intero sistema vigneto. Negli ultimi anni il deficit idrico controllato (RDI) è emerso come una tecnica efficace per mitigare gli impatti della limitata disponibilità idrica, attraverso l'imposizione di condizioni di stress in momenti specifici del ciclo annuale che non compromettano le fasi cruciali dello sviluppo (Pritchard et al., 1995; Chaves et al., 2007; Intrigliolo

e Castel, 2010). In letteratura sono largamente documentate soglie dello stato idrico ottimali in relazione allo stadio fenologico che permettono di stabilire il momento teorico dell'intervento irriguo (Scholander et al., 1965; Choné et al., 2001; Ojeda et al., 2002; Deloire et al., 2004, 2020; Pellegrino et al., 2006; van Leeuwen e Seguin, 2006; Bahar et al., 2011; Deloire e Heyns, 2011). A monte di ciò, il monitoraggio del sistema suolo-pianta-atmosfera svolge quindi un ruolo cruciale nel determinare un effettivo uso più efficiente dell'acqua mantenendo invariati gli obiettivi di qualità e di produttività (Koundouras et al., 2009; van Leeuwen et al., 2009; Acevedo-Opazo et al., 2010; Resco et al., 2016; van Leeuwen e Darriet, 2016). L'ottimizzazione della programmazione dell'irrigazione (specie attraverso RDI) richiede quindi il mantenimento di specifiche soglie di contenuto idrico del suolo (SWC) per non incorrere in stress eccessivi. Quando è possibile misurare il SWC, lo stato idrico della vite può essere definito dalla frazione di acqua trasportabile del suolo (FTSW) (Lebon et al., 2003; van Leeuwen et al., 2009). Tale indice è definito come il rapporto tra l'acqua disponibile in un dato momento (ASW) e l'acqua traspirabile totale (TTSW) di una data combinazione coltura/suolo (Pellegrino et al., 2005a). Di norma, infatti, la capacità di una coltura di assorbire l'acqua dal suolo è inferiore al volume teorico di acqua che quel suolo può immagazzinare. In base a ciò, la FTSW dovrebbe rimanere elevata durante la crescita vegetativa per evitare stress che compromettono le performance delle piante e solo dopo la fioritura, diminuire per generare uno stress idrico moderato che favorisca lo sviluppo riproduttivo (Pellegrino, 2003; Pellegrino et al., 2005b). Per diagnosticare lo stress idrico della vite direttamente su pianta, diversi indicatori sono stati proposti: tra questi, il potenziale idrico fogliare *pre-dawn* (Ψ_{PD}) è stato ampiamente utilizzato (Schultz, 2000; Lebon et al., 2003) tuttavia, tale indice restituisce più verosimilmente lo stato idrico dello strato più umido del suolo e non un dato effettivo dello stress della pianta, in più tende a sovrastimare la disponibilità stessa di acqua nel suolo, a prescindere dal contenuto idrico dello stesso (Améglio et al., 1999; Donovan et al., 2001; Mirás-Avalos et al., 2014). Inoltre, risulta molto variabile e richiede un largo numero di misurazioni per essere ritenuto affidabile (Santesteban et al., 2019). Non presentano tale problema il potenziale idrico *leaf* (Ψ_L) e il potenziale idrico del germoglio (Ψ_{Stem}), ma sebbene entrambi siano stati utilizzati con buoni risultati nella stima dello stress idrico, il primo, più facilmente misurabile, restituisce però il potenziale idrico di una sola foglia a fronte dello stato dell'intero germoglio che viene misurato col secondo. Il Ψ_L è stato riscontrato essere maggiormente influenzato dalle fluttuazioni climatiche che si verificano durante il giorno, problema che è meno evidente per il potenziale Ψ_{Stem} , il quale viene ritenuto ad oggi il più idoneo indicatore precoce dello stress in regioni climatiche caldo-aride (Jones, 2007; Cole e Pagay, 2015; Santesteban et al., 2019). Oltre ciò, nonostante entrambi gli indici

siano ben correlati col contenuto idrico del suolo, il primo sembrerebbe correlato maggiormente all'assimilazione netta di CO₂ ed influenzato dalla traspirazione fogliare al momento della misurazione (Williams, 2013; Lanari et al., 2014). A prescindere da ciò, si tratta di indici misurabili attraverso metodi distruttivi e laboriosi che non consentono misurazioni in grado di fornire rapide informazioni in relazione alla necessità di intervenire attraverso l'irrigazione. Negli ultimi anni sono stati proposti modelli per la stima del Ψ_{Stem} della vite che incorporano alcune variabili ambientali (e.g. temperatura e VPD) e il Ψ_{PD} come riferimento per il potenziale idrico del suolo (Suter et al., 2019), oppure variazioni del diametro del fusto e dell'acino, temperatura fogliare e SWC (Ohana-Levi et al., 2022) o ancora spettroscopia nel vicino infrarosso e conduttanza stomatica (De Bei et al., 2011). Modelli di stima del potenziale idrico che includono la FTSW e il SWC sono stati proposti su pesco e agrumi (Hussein-Mounzer et al., 2008; Martí et al., 2013), e in vigneto modelli per la stima della stessa FTSW senza considerare lo stato idrico delle piante (Alibabaei et al., 2023a). Esistono comunque lacune riguardo modelli per la stima del Ψ_{Stem} in relazione alle variabili ambientali e variabili del suolo come SWC e FTSW estratte tramite sensori (Ohana-Levi et al., 2022). Quest'ultimo indice può essere calcolato attraverso i dati ottenuti con sonde FDR ed è associato a diminuzione dell'attività fotosintetica e può rappresentare un indice di stress della vite su un'ampia variabilità di SWC e su più cultivar (Lebon et al., 2001; Pellegrino, 2003; Pellegrino et al., 2006). Inoltre, fare luce su come modelli di predizione rispondono a diverse condizioni pedoclimatiche potrebbe essere utile nell'implementazione di *decision support system* (DSS) basati su strategie irrigue a deficit controllato.

Alla luce di ciò, gli obiettivi del presente studio sono stati: (i) implementare modelli per la stima del Ψ_{Stem} durante la stagione basati sul contenuto idrico del suolo (SWC), sulla frazione di acqua traspirabile del suolo (FTSW) e su differenti variabili climatiche valutandone l'interdipendenza e l'influenza sullo stato idrico; (ii) valutare se la bontà di predizione dei modelli vari all'utilizzo di parametri climatici relativi al giorno antecedente la stima del Ψ_{Stem} ; (iii) testare l'efficacia di stima dei modelli al variare della FTSW e valutare il peso (varianza spiegata) che le variabili suolo-clima ricoprono in relazione a tali variazioni.

6.1 Materiale e metodi

6.1.1 Disegno sperimentale

La prova è stata condotta durante la stagione 2023 presso due vigneti commerciali (Colinas do Douro) della cultivar a bacca nera Touriga Nacional/110R (*Vitis vinifera* L.), gestiti in regime

colturale biologico (A) e convenzionale (B) e ubicati nella regione vitivinicola del Douro Superiore, Portogallo (40°59'14"N 6°58'39"O, A; 40°59'30"N, 6°59'09"O, B), a un'altitudine di circa 504 e 472 m s.l.m. rispettivamente (Fig. 1). Il clima della regione è di tipo mediterraneo con influenza continentale, e presenta estati molto calde e secche (Jones e Alves, 2012). In entrambi i vigneti le viti erano allevate a controspalliera con sistema di potatura a cordone speronato monolaterale, irrigate attraverso un sistema di irrigazione a goccia (portata gocciolatore di 1 L/h; distanza tra i gocciolatori 80 cm) su un terreno di origine scistosa con tessitura franco-sabbiosa (Alibabaei et al., 2023b). Le distanze d'impianto erano di 1,0 m sulla fila e 2,3 m tra le file e l'orientamento dei filari nord/est-sud/ovest (A) e nord/ovest-sud/est (B) con una pendenza del 18% e del 9% rispettivamente. Per ogni vigneto sono stati selezionati quattro plot costituiti da cinque piante consecutive sulla base del gradiente di pendenza per rappresentare la variabilità dei vigneti. In entrambi i vigneti, l'irrigazione è stata gestita mantenendo una soglia minima di Ψ_{stem} di -0,8 MPa fino all'invasatura e di -1,4 MPa fino alla vendemmia (van Leeuwen et al., 2009). Gli interventi irrigui (7,6 mm) sono stati effettuati ai DOY 101, 103, 109, 121, 124, 136, 138, 180, 188, 194, 206, 217, 223 e 233 in A e 136, 150, 186, 191, e 202 in B. Nei due vigneti l'ultimo intervento irriguo è stato effettuato 28 giorni (A) e 54 giorni (B) prima della data probabile di vendemmia. La gestione fitosanitaria, della chioma e della concimazione sono state applicate secondo le pratiche viticole standard di un vigneto biologico (A) e convenzionale (B). La gestione del suolo ha previsto un inerbimento naturale poiché era in corso uno studio parallelo sulla flora spontanea nei vigneti.




Figura 1. Siti presso i quali è stato condotto lo studio. Delimitati in giallo, A e B, i due vigneti della cultivar Touriga Nacional. Contrassegnati con numerazione progressiva i plot presso i quali sono state installate le sonde capacitive di livello e monitorato lo stato idrico delle piante (Ψ_{stem}) durante il corso della stagione.

6.1.2 Dati climatici

La temperatura (T , °C) e l'umidità relativa (UR , %) dell'aria, il deficit di pressione di vapore (VPD), la radiazione solare (R_s , W/m^2), la velocità del vento (VV , Km/h), e l'evapotraspirazione di riferimento (ET_0 , mm , Penman–Monteith) e la durata della bagnatura fogliare (BF , h) sono stati acquisiti durante la stagione a cadenza oraria attraverso una stazione meteorologica (iMetos, AquAgri, Portogallo) collocata in ciascun vigneto. La somma termica (GDD) è stata calcolata a partire dal primo giorno del mese di aprile fino alla data di vendemmia in accordo con la formula proposta da Arnold (1959):

$$GDD = \left[\frac{(T_{max} - T_{min})}{2} \right] - T_b \quad (1)$$

Dove T_{max} e T_{min} sono la temperatura massima e minima giornaliera e $T_b = 10^\circ C$. Il deficit di pressione di vapore (VPD , KPa) massimo è stato calcolato utilizzando il valore massimo di temperatura e minimo di umidità relativa giornalieri in accordo con la formula descritta da Abtew e Melesse (2013):

$$VPD_{max} = e_s \left(1 - \frac{UR_{min}}{100} \right) \quad (2)$$

Dove e_s è la pressione di saturazione del vapore calcolata con la seguente formula:

$$e_s = 6,112 e^{\frac{17,67 \times T_{max}}{T_{max} + 243,5}} \quad (3)$$

Dove e è la base del logaritmo naturale e T_{max} la temperatura massima giornaliera.

6.1.3 Stato idrico del suolo

Il contenuto idrico del suolo è stato misurato durante la stagione a cadenza giornaliera per ciascun vigneto utilizzando una sonda in situ (Enviroscan, Sentek Technologies, Australia), composto da quattro sensori di livello capacitivi poste a 20, 40, 60 e 80 cm di profondità (p_1 , p_2 , p_3 e p_4 , rispettivamente e p_{sum} la quota cumulata delle quattro sonde, mm) (Fig. 2) e collegati a un *data logger* e ad un'unità di comunicazione GPRS. I dati memorizzati erano espressi come contenuto volumetrico di acqua (m^3). Il contenuto idrico per ogni strato di suolo, espresso in mm , è stato calcolato moltiplicando il contenuto volumetrico per l'altezza dello strato di terreno corrispondente

(20 cm). Le sonde erano collocate sulla fila di ciascun plot di ogni vigneto (per un totale di otto sonde).



Figura 2. Esempio di sonda capacitativa di livello utilizzata per il monitoraggio del SWC. L'immagine non si riferisce al presente studio (fonte: sentektechnologies.com).

Il SWC_{min} di ciascun plot è stato ottenuto considerando il più basso valore di ASW raggiunto al termine della stagione precedente, prima del primo evento piovoso occorso. A differenza del punto di appassimento (WP), il SWC_{min} tiene conto della capacità delle piante di estrarre l'umidità dal suolo, che può essere limitata dalla bassa densità delle radici (Ratliff et al., 1983; Lacape et al., 1998). È frequentemente più alto del punto di appassimento perché al di sotto di una certa profondità la densità delle radici diventa limitante per l'estrazione dell'acqua (Ritchie, 1981; Cabelguenne e Debaeke, 1998; Lacape et al., 1998; Pellegrino et al., 2006). Il SWC_{fc} è stato ottenuto considerando il più alto valore di ASW raggiunto durante l'anno, il 10 gennaio 2023, in seguito al maggiore evento piovoso invernale e dopo aver fatto drenare il suolo per un giorno senza che si verificassero eventi piovosi. La FTSW è stata calcolata per ciascun giorno come il rapporto tra ASW_d e TTSW, con ASW_d definito come la differenza (sulla profondità di 80 cm) tra il SWC in quel giorno e il SWC_{min} , in accordo con Pellegrino et al., (2006), attraverso la seguente formula:

$$FTSW (\%) = \frac{ASW_d * 100}{TTSW} \quad (4)$$

Il TTSW, fino ad una profondità di 80 cm, è stato calcolato come differenza tra il contenuto idrico del suolo alla capacità idrica di campo (SWC_{fc}) e il contenuto minimo di acqua nel suolo (SWC_{min}), in accordo con Pellegrino et al., (2006), attraverso la seguente formula:

$$TTSW = SWC_{fc} - SWC_{min} \quad (5)$$

6.1.4 Stato idrico delle piante

Lo stato idrico delle piante è stato monitorato tra le 14:00 e le 15:00, range orario che garantisce fluttuazioni termiche minori rispetto le ore precedenti in cui il raggiungimento della temperatura massima giornaliera non è ancora avvenuto (Santesteban et al., 2019). L'indice di riferimento utilizzato è stato il potenziale idrico del germoglio (Ψ_{Stem} , MPa) (Begg e Turner, 1976). Per le misurazioni è stata utilizzata una camera a pressione di Scholander (Instruments Co., Albany, NY, USA). Ad ogni rilievo sono state selezionate casualmente due piante da ogni plot e il loro potenziale Ψ_{Stem} è stato misurato su due foglie espanse prelevate dalla parte centrale della chioma, sesto-ottavo nodo del germoglio (due per esposizione). Le foglie selezionate sono state coperte con fogli di alluminio e poste in sacchetti di polietilene trasparente per farle adattare al buio un'ora prima delle misurazioni. Tra il distacco della foglia dalla pianta e la misurazione non sono mai intercorsi più di trenta secondi. I rilievi sono stati effettuati dalla medesima persona per ridurre al minimo la variabilità generata dall'errore umano (Levin, 2019). Infine, è stato calcolato un valore medio per ogni plot. I rilievi sono stati effettuati i giorni dell'anno (DOY) 118, 150, 172, 192, 214, 235 e 256 coprendo il ciclo annuale delle piante dal germogliamento (DOY 118) alla vendemmia (DOY 256). In media ogni rilievo di Ψ_{Stem} è stato effettuato dieci giorni dopo l'ultimo intervento irriguo.

6.1.5 Analisi statistica ed elaborazione dei modelli

I dati ottenuti sono stati analizzati utilizzando il software statistico Minitab® versione 19 (Minitab, USA). I parametri climatici e i valori del Ψ_{Stem} sono stati confrontati tra le date attraverso l'analisi della varianza (ANOVA) utilizzando il test post-hoc Tukey ($P < 0,05$). Le correlazioni tra Ψ_{Stem} , SWC, FTSW e le variabili climatiche sono state valutate attraverso il coefficiente di correlazione di Pearson e considerate per i modelli solo se altamente significative ($P \leq 0,01$). I modelli sono stati implementati mediante un approccio *theory-driven* inserendo sempre all'interno dei modelli una variabile di controllo, ossia nota per avere un effetto sullo stato idrico delle piante (Copas, 1983; Antonakis and Dietz, 2011). L'inclusione delle variabili nei modelli ha seguito, oltre il criterio della significatività (P-value) e del contributo nella varianza spiegata, anche quello di non multicollinearità: il *Variance Inflation Factor* (VIF) è stato valutato per ogni variabile e per valori superiori a 5 queste sono state escluse dai modelli e/o utilizzate per modelli alternativi (Neter et al., 1996; Santesteban et al., 2011; Suter et al., 2019). Sono state valutate anche le interazioni e i relativi

termini quadratici delle variabili. I modelli sono stati quindi comparati utilizzando l'*Akaike's Information Criterion* (AIC), il *Bayesian Information Criterion* (BIC) e la percentuale di varianza spiegata (Greenwood et al., 1985; Parker et al., 2011). La varianza dei residui è stata valutata plottando i residui standardizzati con i valori stimati e i modelli sono stati presi in considerazione solo in caso di omoschedasticità (Rosopa et al., 2013). L'accuratezza predittiva dei modelli è stata valutata attraverso validazione incrociata, *leave one out cross-validation* (LOOCV). Per elaborare i modelli, i dati sono stati convertiti in scala [-1; 1] per evitare che le variabili con maggiore varianza avessero un'influenza eccessiva sulla precisione di stima. I modelli risultati significativamente migliori sono stati comparati calcolando il *Root Mean Squared Error* (RMSE) e il *Mean Absolute Percentage Error* in accordo con Paulus et al., (2014) attraverso le seguenti formule:

$$RMSE = \sqrt{\text{mean}(t - a)^2} \quad (5)$$

$$MAPE = \text{mean} \left(\left| \frac{t-a}{t} \right| * 100 \right) \quad (6)$$

Dove t (*target*) è il valore di riferimento, a (*actual*) il valore stimato.

6.2 Risultati

6.2.1 Clima, stato idrico del suolo e stato idrico delle piante




Figura 3. Pattern stagionale delle precipitazioni, degli apporti irrigui, dell'evapotraspirazione di riferimento (ET₀) (asse principale) e delle temperature massime mensili (T_{max}) (asse secondario) tra aprile e settembre 2023 nei due vigneti presso i quali è stata condotta la prova (A e B).

Data la non eccessiva distanza tra i due vigneti (~1 km), il pattern delle variabili climatiche misurate durante il periodo compreso tra aprile e settembre 2023 è risultato simile (Fig. 3). Tuttavia, in B si sono registrate temperature medie giornaliere superiori di 1°C rispetto ad A (21,2 e 20,3°C rispettivamente) e temperature massime superiori di quasi 3°C (30,5 e 27,6 °C rispettivamente) (Tab. 1). L'umidità relativa minima è risultata in media di 5,4 punti percentuali superiore in A rispetto B con un conseguente deficit di pressione di vapore medio inferiore. Non sono risultate differenze significative per i valori di radiazione solare, ET_0 e precipitazioni. La velocità media del vento è stata invece superiore in A, fattore che spiega in parte le differenze in termini di VPD. Una tendenza simile si è verificata nei giorni delle misurazioni, durante le quali nel vigneto A le temperature medie e massime sono state più basse eccetto che al DOY 118. Il delta maggiore si è verificato al DOY 192 per le temperature medie (-1,3°C in A) e al DOY 150 per le massime (-3,8°C in A). Le temperature massime maggiori si sono registrate al DOY 235 (40,5°C in A e 42,2°C in B). In accordo con le medie giornaliere il VPD, soprattutto il massimo giornaliero, è risultato superiore in B per tutti i giorni delle misurazioni con un delta massimo di 1 kPa al DOY 192 e lungo l'intero periodo è variato da un minimo di 1,4 ad un massimo di 6,6 kPa in A e da un minimo di 1,7 ad un massimo di 7,4 kPa in B. Trascurabili sono risultate le differenze in termini di ET_0 . Solo nei DOY 150 e 172 i valori delle precipitazioni sono stati superiori a zero. In particolare, al DOY 150, giornata caratterizzata da piogge intense al mattino, si sono registrati 21,2 mm (A) e 18,2 mm (B) di pioggia; al DOY 172 la giornata è stata caratterizzata da copertura nuvolosa intermittente ma con solamente 0,3 mm di pioggia. Le differenze tra temperature medie e massime e conseguentemente in termini di *Growing Degree Days*, non hanno avuto effetto nel determinare differenze sulle fasi fenologiche delle piante in entrambi i vigneti (Tab. 2). Nonostante valori simili in termini di piovosità nei due siti (Tab. 3), il vigneto A, gestito in regime biologico, ha richiesto maggiori interventi irrigui, a causa del vigore inferiore che le piante manifestavano ma anche al fatto che il vigneto A presentava una pendenza maggiore, che in condizioni di tessitura franco-sabbiosa causa una maggiore perdita degli apporti meteorici per scorrimento superficiale.

Tabella 1. Confronto tra i valori medi delle variabili climatiche giornaliere dal primo giorno di aprile all'ultimo di settembre.

Vigneto	T _{media} (°C)	T _{max} (°C)	UR _{min} (%)	VPD _{medio} (kPa)	Rs (W/m ²)	ET ₀ (mm)	VV (km/h)	Prec. (mm)
A	20,3 ± 0,3 ^b	27,7 ± 0,4 ^b	29,7 ± 0,9 ^a	1,2 ± 0,0 ^b	286,2 ± 5,3 ^{n.s.}	5,1 ± 0,1 ^{n.s.}	1,8 ± 0,1 ^a	1,1 ± 0,2 ^{n.s.}
B	21,3 ± 0,3 ^a	30,5 ± 0,4 ^a	24,4 ± 0,9 ^b	1,5 ± 0,0 ^a	300,2 ± 5,7	5,1 ± 0,1	1,2 ± 0,0 ^b	1,0 ± 0,3

T_{media} e T_{max}, temperatura media e massima dell'aria; UR, umidità relativa minima dell'aria; VPD deficit di pressione di vapore; Rs, radiazione solare; ET₀, evapotraspirazione di riferimento; VV, velocità del vento. Prec., precipitazioni. Lettere differenti tra i vigneti indicano differenze statisticamente significative per P < 0,05 secondo il test di Tukey. n.s. indica assenza di significatività. I valori sono riportati come media ± errore standard.

Tabella 2. Date delle fasi fenologiche della cultivar Touriga Nacional (*Vitis vinifera* L.) nella stagione 2023 nei due vigneti oggetto di studio.

Stadio fenologico ¹	Vigneto		DOY
	A	B	
Germogliamento	24-mar	24-mar	83
Fioritura	19-mag	19-mag	139
Invaiaura	27-lug	27-lug	208
Maturazione (vendemmia)	13-set	13-set	256

¹Le fasi fenologiche si riferiscono alla scala BBCH di Lorenz (1995). Germogliamento (BBCH 09), Fioritura (BBCH 65), Invaiaura (BBCH 83), Maturazione (BBCH 85). DOY, giorno dell'anno.

Tabella 3. Peso del legno di potatura delle piante oggetto di studio, variabili ambientali e apporti idrici nei due vigneti (A e B) durante il periodo dell'esperimento.

Vigneto	Peso del legno ¹ (g)	GDD ² (°C)	ET ₀ ³ (mm)	Precipitazioni (mm)	PI (DOY)	UI (DOY)	VI (mm)
A	150 ± 12 ^b	1806	891	186	111	233	107
B	260 ± 6 ^a	1990	874	168	136	202	37

GDD, *Growing Degree Days*; ET₀, evapotraspirazione di riferimento; PI, data del primo intervento irriguo; UI, data dell'ultimo intervento irriguo; VI, volume irriguo. ¹Lettere differenti sui valori di peso del legno tra i vigneti indicano differenze statisticamente significative per P < 0,05 secondo il test di Tukey. I valori sono riportati come media ± errore standard. ²Il valore è stato calcolato dal primo giorno di aprile (DOY 91) alla data della vendemmia (DOY 256). ³I valori sono cumulati dal primo giorno di aprile al giorno della vendemmia. A e B, i due vigneti presso i quali è stata condotta la prova.

Il valore del Ψ_{stem} misurato durante il ciclo annuale delle viti è stato compreso tra un massimo di -0,39 e un minimo di -1,47 MPa in A, e tra un massimo di -0,41 e un minimo di -1,39 MPa in B, manifestando un decremento costante indipendentemente dai valori di SWC ma più in linea con la diminuzione della percentuale di FTSW, dal DOY 172 in poi (Fig. 4). I livelli di minor stress sono stati registrati proprio in quella data, caratterizzata da copertura nuvolosa e delle massime termiche più basse dell'intero periodo (22,4 e 24,9 °C). Anche al DOY 150 le piante di entrambi i vigneti presentavano Ψ_{stem} minori rispetto alla prima data di misurazioni, e ciò è attribuibile agli eventi piovosi verificatisi nei giorni immediatamente precedenti e che hanno infatti reintegrato il SWC. È

interessante notare come nonostante i valori di SWC fossero notevolmente diversi tra le due date di misurazione, le temperature massime più basse al DOY 172 hanno avuto una considerevole influenza sul Ψ_{stem} . Lo stress idrico più elevato di contro è stato raggiunto al DOY 256, data durante la quale non si sono registrate le temperature massime più elevate, ma le percentuali di FTSW erano prossime allo zero e sia apporti irrigui che precipitazioni erano assenti da 28 giorni (A) e 54 giorni (B).

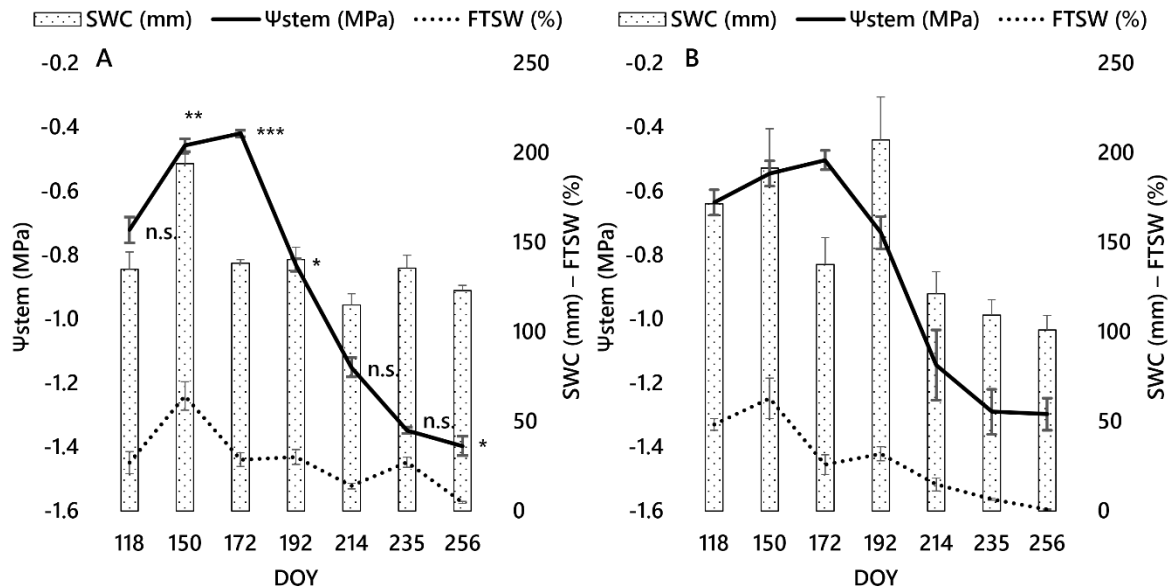


Figura 4. Pattern stagionale del potenziale idrico del germoglio (Ψ_{stem}) (asse principale), del contenuto idrico del suolo (0-0,8 m) (SWC) e della frazione traspirabile di acqua nel suolo (FTSW) (asse secondario) nei due vigneti oggetto di studio (A e B). I simboli sui valori di Ψ_{stem} indicano differenze statisticamente significative tra le stesse date nei due vigneti per $P < 0,05$ secondo il test di Tukey. *, $P < 0,05$; **, $P < 0,01$; ***, $P < 0,001$; n.s., non significativo. Le barre indicano + errore standard.

Più nel dettaglio, considerata una gestione irrigua che prevedeva stress moderati ($> -0,8$ MPa) fino all'invasiatura (DOY 208) e più severi ($> -1,4$ MPa) fino alla vendemmia, le piante di A sono state sottoposte a stress minori (pressoché nulli) fino al DOY 172, con un Ψ_{stem} medio di $-0,42$ MPa riscontrato in quella data; quelle di B, alla stessa data, presentavano un Ψ_{stem} medio di $-0,50$ MPa. Dopo quella data, si è avuta un'inversione, infatti le piante di B hanno manifestato stress minori, eccetto per i DOY 214 e 235 durante i quali le piante di A erano ancora supportate dall'irrigazione (si noti il valore in FTSW di A al DOY 235), differenza che si è però riproposta all'ultima data, in cui le piante di A presentavano un Ψ_{stem} medio di $-0,41$ MPa e quelle di B di $-0,30$ MPa.

6.2.2 Modelli di stima del Ψ_{stem}

La modellizzazione per la stima del Ψ_{stem} ha previsto una preliminare valutazione delle correlazioni tra questo e le variabili relative al suolo e al clima monitorate durante l'intera durata dello studio. Il Ψ_{stem} , il DOY e i GGD hanno evidenziato una forte correlazione negativa, ossia, al progredire della stagione e all'aumentare della somma termica, i valori di Ψ_{stem} diminuivano (Tab. 4). Altrettanto forte ma positiva è stata la correlazione con la FTSW, il SWC totale (p_{sum}) e quello misurato alle diverse profondità del suolo. L'indice di correlazione di Pearson, tuttavia, è risultato più alto per la FTSW rispetto p_{sum} (0,72 vs 0,61) in ragione della frazione non traspirabile inclusa nel SWC che, quindi, non spiegava nella stessa misura le variazioni in Ψ_{stem} . Nonostante ciò, la correlazione tra Ψ_{stem} e SWC è cresciuta linearmente all'aumentare della profondità e i valori di SWC misurati a 80 cm (p_4) sono risultati quelli più simili alla FTSW. La correlazione più forte tra il SWC nel profilo 0-80 cm è stata quella con i valori di SWC intermedi (p_2 e p_3), in ragione del fatto che a 20 cm (p_1) i valori fluttuavano maggiormente per via dell'effetto dell'evaporazione e degli apporti idrici meteorici e irrigui, mentre a 80 cm (p_4) sono risultati più stabili tra una data e l'altra e hanno contribuito meno alla variazione di p_{sum} (Fig. 5). La correlazione tra il SWC, la FTSW e il la data di misurazione (DOY), seppur molto significativa ($P < 0,001$), aveva indici più bassi, risultato atteso a meno che non si considerino vigneti in asciutto in assenza di precipitazioni. Ciò fa intuire come il Ψ_{stem} non è diminuito col progredire della stagione per via di una proporzionale diminuzione di SWC e FTSW e che, a parità di valori di stato idrico del suolo, una parte della variabilità del Ψ_{stem} era da attribuire all'effetto del clima.

Tabella 4. Matrice di correlazione di Pearson fra i valori di SWC alle diverse profondità, FTSW, dello stato idrico delle piante e dei GDD nei giorni delle misurazioni (DOY).

	Ψ_{stem} (MPa)	p_1 (mm)	p_2 (mm)	p_3 (mm)	p_4 (mm)	p_{sum} (mm)	FTSW (%)	GDD (°C)
p_1	0,52							
p_2	0,60	0,86						
p_3	0,63	0,72	0,91					
p_4	0,67	0,62	0,77	0,88				
p_{sum}	0,61	0,84	0,92	0,91	0,85			
FTSW	0,72	0,75	0,82	0,80	0,70	0,84		
GDD	-0,87	-0,43	-0,53	-0,59	-0,64	-0,53	-0,72	
DOY	-0,83	-0,44	-0,50	-0,57	-0,65	-0,51	-0,70	0,99

Tutte le correlazioni sono altamente significative ($P \leq 0,001$). Ψ_{stem} , potenziale idrico del germoglio; p_1 , SWC a 20 cm; p_2 , SWC a 40 cm; p_3 , SWC a 60 cm; p_4 , SWC a 80 cm. FTSW, frazione traspirabile di acqua nel suolo; DOY, giorno dell'anno; GDD, *growing degree days*.




Figura 5. Variazione del contenuto idrico del suolo (SWC, mm) misurata nel corso della stagione a diverse profondità. p_1 , SWC a 20 cm; p_2 , SWC a 40 cm; p_3 , SWC a 60 cm; p_4 , SWC a 80 cm. Le barre indicano \pm errore standard. DOY, giorno dell'anno in cui è stato misurato il Ψ_{stem} .

Le variabili climatiche misurate nei giorni dei rilievi del Ψ_{stem} , e prese in considerazione per l'implementazione dei modelli sono state la temperatura media (T , °C) e massima dell'aria (T_{max} , °C), il deficit di pressione di vapore medio (VPD, kPa) e massimo (VPD, kPa), l'umidità relativa media UR, (%) e minima (UR_{min} , %) dell'aria, la radiazione solare (R_s , W/m^2), l'evapotraspirazione di riferimento cumulata per giorno (ET_0 , mm), la velocità media (VV, km/h) e massima del vento (VV_{max} , km/h) all'altezza di 1,8 m e la durata della bagnatura fogliare (BF, h). Tuttavia, alcune di queste non hanno presentato correlazioni altamente significative ($P < 0,001$) con il Ψ_{stem} (VV, UR, BF) o, nel caso in cui derivate dallo stesso parametro (T e T_{max} , VPD e VPD_{max}) hanno mostrato livelli di correlazione più bassi. Per questo motivo sono state incluse nei modelli solo le variabili significative e con indice di correlazione di Pearson maggiore nel caso di variabili della stessa natura (e. g. T e T_{max}). Il Ψ_{stem} mostrava correlazioni negative con T_{max} , VPD_{max} , R_s ed ET_0 (in ordine decrescente dell'indice) e positive con VV_{max} e UR_{min} (Tab. 5). La correlazione fra le variabili termiche e il DOY indica che tutte eccetto UR_{min} e VV_{max} sono aumentate con il progredire della stagione.

Tabella 5. Matrice di correlazione di Pearson fra i parametri climatici e il Ψ_{stem} nei giorni delle misurazioni dello stato idrico delle piante.

	Ψ_{stem} (MPa)	T_{max} (°C)	VPD _{max} (kPa)	UR _{min} (%)	Rs (W/m ²)	VV _{max} (km/h)	ET ₀ (mm)	GDD (°C)
T_{max}	-0,66							
VPD_{max}	-0,57	0,97						
UR_{min}	0,44	-0,79	-0,86					
Rs	-0,50	0,73	0,67	-0,71				
VV_{max}	0,57	-**	-**	0,50	0,50			
ET₀	-0,47	0,87	0,82	-0,72	0,90	-*		
GDD	-0,87	0,59	0,49	-*	0,45	n.s.	*	
DOY	-0,83	0,54	0,44	n.s.	0,43	n.s.	0,36	0,99

Le correlazioni mostrate sono altamente significative ($P \leq 0,001$). * e **, correlazione significativa ($P \leq 0,05$ e $P \leq 0,01$ rispettivamente); n.s., non significativa. Ψ_{stem} , potenziale idrico del germoglio; T_{max} , temperatura massima dell'aria; VPD deficit massimo di pressione di vapore; UR, umidità relativa minima dell'aria; Rs, radiazione solare; VV_{max}, velocità massima del vento; ET₀, evapotraspirazione di riferimento; DOY, giorno dell'anno; GDD, *growing degree days*.

Le medesime variabili relative misurate il giorno precedente alle misurazioni del Ψ_{stem} mostravano le stesse dinamiche di interdipendenza ma con indici di correlazione più bassi (Tab. 6). La relazione tra le variabili climatiche e lo stato idrico del suolo mostrava invece assenza di alta significatività (Tab. 7), indice del fatto che per l'implementazione dei modelli la presenza di variabili dell'una e dell'altra natura è utile a spiegare una diversa frazione della variazione del Ψ_{stem} . Nello specifico le uniche variabili climatiche correlate con le variabili del suolo erano T_{max} e VV_{max}.

Tabella 6. Matrice di correlazione di Pearson tra i parametri climatici e il Ψ_{stem} nel giorno precedente alle misurazioni dello stato idrico delle piante.

	Ψ_{stem} (MPa)	T_{max} (°C)	VPD _{max} (kPa)	UR _{min} (%)	Rs (W/m ²)	VV _{max} (km/h)
T_{max}	-0,53					
VPD_{max}	-0,43	0,98				
UR_{min}	n.s.	-0,88	-0,89			
Rs	-0,34	0,80	0,74	-0,83		
VV_{max}	n.s.	n.s.	n.s.	n.s.	n.s.	
ET₀	-0,34	0,80	0,72	-0,79	0,98	n.s.

Le correlazioni mostrate sono altamente significative ($P \leq 0,001$). n.s., non significativa. Ψ_{stem} , potenziale idrico del germoglio; T_{max} , temperatura massima dell'aria; VPD deficit massimo di pressione di vapore; UR, umidità relativa minima dell'aria; Rs, radiazione solare; VV_{max}, velocità massima del vento; ET₀, evapotraspirazione di riferimento. ¹Le variabili climatiche si riferiscono al giorno precedente ai rilievi di Ψ_{stem} .

Tabella 7. Indici di correlazione di Pearson tra i valori giornalieri di temperatura massima dell'aria (T_{max}), deficit massimo di pressione di vapore atmosferico (VPD), umidità relativa minima dell'aria (UR), radiazione solare (Rs), velocità del vento (VV) ed evapotraspirazione di riferimento (ET_0) e i valori di SWC e FTSW.

	T_{max} (°C)	VPD _{max} (kPa)	UR _{min} (%)	Rs (W/m ²)	VV _{max} (km/h)	ET ₀ (mm)
p_1 (mm)	n.s.	n.s.	n.s.	n.s.	0,62	n.s.
p_2 (mm)	n.s.	n.s.	n.s.	n.s.	0,51	n.s.
p_3 (mm)	n.s.	n.s.	n.s.	n.s.	0,44	n.s.
p_4 (mm)	-*	n.s.	n.s.	n.s.	n.s.	n.s.
FTSW (%)	-*	-*	n.s.	-*	n.s.	-*

*, correlazione significativa ($P \leq 0,05$); n.s., non significativa. T_{max} , temperatura massima dell'aria; VPD deficit massimo di pressione di vapore; UR, umidità relativa minima dell'aria; Rs, radiazione solare; VV_{max}, velocità massima del vento; ET_0 , evapotraspirazione di riferimento; p_4 , SWC a 80 cm di profondità; FTSW, frazione traspirabile di acqua nel suolo.

L'implementazione dei modelli è avvenuta inserendo una variabile per volta e valutando la sua significatività all'interno del modello considerando anche i termini quadratici e l'interazione con le variabili già presenti. Questo ha permesso di valutare la percentuale di varianza del Ψ_{stem} ulteriormente spiegata, ossia quanto l'aggiunta di una variabile in più, che comporta un aumento della complessità del modello, ha restituito in termini di effettiva capacità predittiva. L'inserimento contemporaneo di tutte le variabili nello stesso modello ha generato sì un valore di R^2 molto alto (0,95), questo si è rivelato però iperbolico se considerati i valori altrettanto alti di VIF nell'ordine delle migliaia (dati non mostrati) che indicano multicollinearità. I modelli sono stati implementati seguendo il seguente schema in cui il Ψ_{stem} è progressivamente funzione dello stato idrico del suolo, del clima e del decorrere della stagione:

$$\Psi_{stem}=f(S) \quad (7);$$

$$\Psi_{stem}=f(C) \quad (8);$$

$$\Psi_{stem}=f(S, C) \quad (9);$$

$$\Psi_{stem}=f(S, C, t) \quad (10)$$

Dove S rappresenta le variabili del suolo, C le variabili del clima e t , il decorso della stagione (DOY e GGD).

Le prime variabili considerate (Tab. 8), sono state il SWC a diverse profondità, il SWC tra 0 e 80 cm (p_{sum}) e la FTSW. L'abilità predittiva di queste variabili è stata in ordine crescente di AIC e BIC: FTSW, p_4 , p_{sum} , p_3 , p_2 e p_1 (modelli da 1 a 6). FTSW e p_4 erano le variabili che generavano i più alti R^2 in seguito la LOOCV spiegando da sole il 60% della variabilità del Ψ_{stem} , ed evidenziando chiaramente la risposta delle piante alle variazioni nello stato idrico del suolo. Le variabili climatiche che da sole hanno prodotto modelli che hanno superato i criteri di valutazione erano T_{max}

e VPD_{max} e spiegavano il 50 e il 36% di variabilità, rispettivamente. Seppur significative, R_s e ET_0 presentavano residui eteroschedastici, mentre VV_{max} e UR_{min} generavano modelli con $P > 0,05$. L'aggiunta delle variabili climatiche ai modelli 5 e 6 ha permesso però di ottenere una buona percentuale aggiuntiva di varianza spiegata. I modelli con i valori di AIC e BIC più bassi e R^2 più alti risultavano quelli che includevano T_{max} e R_s (modelli 9, 12, 13 e 16). L'aggiunta di queste variabili climatiche ha aggiunto tra il 19 e il 24% in più di varianza spiegata nei modelli, ed F-value che eguagliavano quelli delle variabili legate al suolo. L'aggiunta di VPD_{max} ed ET_0 aggiungeva invece +16 e +15% rispettivamente, valori di AIC e BIC più alti, ed F-value più bassi, dato interessante se si considera che queste ultime due variabili sono quelle legate direttamente alla domanda traspirativa. A prescindere dai valori ottenuti dai diversi modelli è stata testata l'aggiunta delle variabili DOY e GDD (intese come decorso della stagione). Tuttavia, hanno superato i criteri di valutazione (vedi paragrafo 6.1.5) quelli implementati a partire dai modelli 9, 12 e 13. Hanno generato R^2 superiori a 0,90 anche dopo la LOOCV solo i modelli 17, 18 e 19. I modelli 17 e 18 (T_{max} ed R_s) erano quelli che presentavano RMSE e MAPE più bassi: 0,1 MPa e 9,6%; 0,1 MPa e 10,7 %, rispettivamente (Fig. 6). Nessuno dei modelli implementati con le variabili climatiche del giorno precedente alle misurazioni del Ψ_{stem} ha generato valori predittivi equiparabili, ma anche in questo caso i modelli che includevano T_{max} e R_s sono risultati quelli con valori più alti (Tab. 9). Si potrebbe supporre che la predittività dei modelli elaborati con le variabili del giorno precedente non sia più da attribuire al fatto che queste erano solo di poco differenti a quelle del giorno delle misure, mantenendo la stessa proporzionalità, o al fatto che il Ψ_{stem} sia effettivamente meno influenzato dal clima del giorno precedente. Per rispondere a questo interrogativo, nei modelli sono stati mantenuti i valori di SWC e di FTSW del giorno delle misure come controllo, di conseguenza è lecito supporre che si tratti di un'influenza minore.

Tabella 8. Confronto della bontà di adattamento e della predittività dei modelli per la stima del Ψ_{stem} .

N	Equazione modello	AIC	BIC	R ²	R ² _{LOOCV}
1	$\Psi_{stem} = -1,381 + 0,02498 p_1$	33,35	38,96	0,27	0,23
2	$\Psi_{stem} = -2,640 + 0,1346 p_2 - 0,002137 p_2^2$	21,40	27,71	0,43	0,39
3	$\Psi_{stem} = -3,104 + 0,1651 p_3 - 0,00266 p_3^2$	15,74	23,06	0,49	0,45
4	$\Psi_{stem} = -3,542 + 0,2019 p_4 - 0,00333 p_4^2$	2,42	9,47	0,60	0,56
5	$\Psi_{stem} = -2,946 + 0,03884 p_{sum} - 0,000154 p_{sum}^2$	13,21	20,53	0,51	0,47
6	$\Psi_{stem} = -1,3904 + 0,02579 FTSW - 0,000178 FTSW^2$	1,53	8,85	0,60	0,57
7	$\Psi_{stem} = 3,03 - 0,2081 T_{max} + 0,00253 T_{max}^2$	14,85	22,17	0,50	0,46
8	$\Psi_{stem} = -0,175 - 0,307 VPD_{max} + 0,0219 VPD_{max}^2$	28,54	35,54	0,36	0,31
9	$\Psi_{stem} = 0,409 + 0,1238 p_4 - 0,1638 T_{max} - 0,001853 p_4^2 + 0,002067 T_{max}^2$	-29,26	-18,82	0,79	0,75
10	$\Psi_{stem} = -2,239 + 0,1419 p_4 - 0,2805 VPD_{max} - 0,002139 p_4^2 + 0,02327 VPD_{max}^2$	-21,28	-10,84	0,76	0,72
11	$\Psi_{stem} = -1,146 + 0,1579 p_4 - 0,6890 ET_0 - 0,002538 p_4^2 + 0,0581 ET_0^2$	-18,59	-8,15	0,75	0,68
12	$\Psi_{stem} = 1,039 + 0,1140 p_4 - 0,02402 R_s - 0,001786 p_4^2 + 0,000039 R_s^2$	-43,55	-33,12	0,84	0,81
13	$\Psi_{stem} = 1,294 + 0,02224 FTSW - 0,1356 T_{max} - 0,000175 FTSW^2 + 0,001611 T_{max}^2$	-34,62	-24,18	0,81	0,79
14	$\Psi_{stem} = -1,0664 + 0,02450 FTSW - 0,0828 VPD_{max} - 0,000188 FTSW^2$	-21,46	-12,53	0,74	0,70
15	$\Psi_{stem} = -0,952 + 0,02822 FTSW - 0,0864 ET_0 - 0,000235 FTSW^2$	-17,96	-9,03	0,73	0,72
16	$\Psi_{stem} = -0,7820 + 0,5348 FTSW + 0,3685 R_s^2 + 0,5720 FTSW R_s$	-38,53	-29,6	0,81	0,79
17	$\Psi_{stem} = 0,118 + 0,01542 p_4 - 0,1307 T_{max} + 0,01653 DOY + 0,001671 T_{max}^2 - 0,00055 DOY^2$	-78,85	-67,01	0,92	0,90
18	$\Psi_{stem} = 0,683 + 0,0096 p_4 - 0,01622 R_s + 0,01123 DOY + 0,000045 R_s^2 - 0,000056 R_s DOY$	-87,54	-75,69	0,93	0,91
19	$\Psi_{stem} = 2,127 + 0,01088 p_4 - 0,02072 R_s - 0,000310 GDD$	-80,75	-70,31	0,92	0,90
20	$\Psi_{stem} = 0,7963 + 0,4022 p_4 - 0,022272 T_{max} - 0,1964 T_{max}^2 + 0,4407 p_4 GDD$	-66,45	-56,01	0,89	0,87
21	$\Psi_{stem} = -1,477 + 0,00309 FTSW - 0,1262 T_{max} + 0,000091 GDD + 0,001648 T_{max}^2 - 0,00001 GDD^2$	-50,89	-39,05	0,86	0,83
22	$\Psi_{stem} = 0,121 + 0,00259 FTSW - 0,1101 T_{max} + 0,01594 DOY + 0,001376 T_{max}^2 - 0,000054 DOY^2$	-67,42	-55,57	0,90	0,88

N, numero modello; Ψ_{stem} , potenziale idrico del germoglio; p_1 , SWC a 20 cm di profondità; p_2 , SWC a 40 cm; p_3 , SWC a 60 cm; p_4 SWC a 80 cm; p_{sum} , SWC da 0 a 80 cm; FTSW, frazione traspirabile di acqua nel suolo; T_{max} , temperatura massima; VPD_{max} , deficit massimo di pressione del vapore; ET_0 , evapotraspirazione di riferimento; R_s , radiazione solare; UR_{min} , umidità relativa minima; DOY , giorno dell'anno; GDD , *growing degree days*; AIC *Akaike Information Criterion*; BIC, *Bayesian Information Criterion*; R², coefficiente di determinazione; coefficiente di determinazione della *cross-validation*.¹I modelli includono esclusivamente variabili climatiche relative al giorno delle misurazioni del Ψ_{stem} .

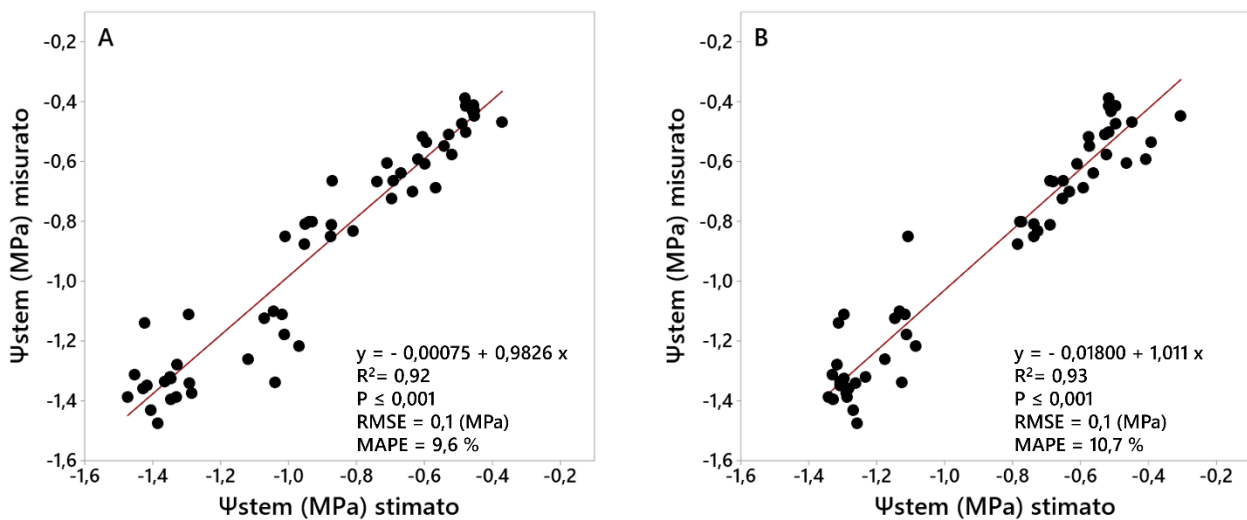


Figura 6. Correlazione tra il Ψ_{stem} misurato e quello stimato dai modelli 17 (A) e 18 (B) (n=56). RMSE, *Root Mean Squared Error*; MAPE, *Mean Absolute Percentage Error*.

Tabella 9. Confronto della bontà di adattamento e della predittività dei modelli per la stima del Ψ_{stem} .

N	Equazione modello ¹	AIC	BIC	R ²	R ² LOOCV
23	$\Psi_{\text{stem}} = -2,6150 + 0,1759 p_4 - 0,0194 T_{\text{max}} - 0,0028 p_4^2$	-18,65	-9,72	0,72	0,70
24	$\Psi_{\text{stem}} = -3,190 + 0,1886 p_4 - 0,0519 \text{VPD}_{\text{max}} - 0,003096 p_4^2$	-12,31	-3,38	0,68	0,66
25	$\Psi_{\text{stem}} = -2,366 + 0,1948 p_4 - 0,452 \text{ET}_0 - 0,003197 p_4^2 + 0,0416 \text{ET}_0^2$	-11,36	-0,92	0,71	0,69
26	$\Psi_{\text{stem}} = -1,408 + 0,1717 p_4 - 0,01302 \text{Rs} - 0,002826 p_4^2 + 0,000022 \text{Rs}^2$	-20,00	-9,56	0,75	0,73
27	$\Psi_{\text{stem}} = -0,731 + 0,02471 \text{FTSW} - 0,01967 T_{\text{max}-1} - 0,000185 \text{FTSW}^2$	-18,11	-9,18	0,73	0,67
28	$\Psi_{\text{stem}} = -1,1743 + 0,02573 \text{FTSW} - 0,0534 \text{VPD}_{\text{max}-1} - 0,000190 \text{FTSW}^2$	-12,19	-3,26	0,70	0,65
29	$\Psi_{\text{stem}} = 0,167 + 0,02429 \text{FTSW} \% - 0,01096 \text{Rs} - 0,000192 \text{FTSW}^2 + 0,000018 \text{Rs}^2$	-10,01	0,43	0,70	0,64
30	$\Psi_{\text{stem}} = -1,087 + 0,02737 \text{FTSW} - 0,0642 \text{ET}_0 - 0,000208 \text{FTSW}^2$	-8,57	0,36	0,68	0,63

¹I modelli includono esclusivamente variabili climatiche relative al giorno precedente alle misurazioni del Ψ_{stem} ma non le variabili del suolo. N, numero modello, Ψ_{stem} , potenziale idrico del germoglio; p_1 , SWC a 20 cm di profondità; p_2 , SWC a 40 cm; p_3 , SWC a 60 cm; p_4 SWC a 80 cm; p_{sum} , SWC da 0 a 80 cm; FTSW, frazione traspirabile di acqua nel suolo; T_{max} , temperatura massima; VPD_{max} , deficit massimo di pressione del vapore; ET_0 , evapotraspirazione di riferimento; Rs , radiazione solare; UR_{min} , umidità relativa minima; DOY , giorno dell'anno; GDD , *growing degree days*; AIC *Akaike Information Criterion*; BIC, *Bayesian Information Criterion*; R^2 , coefficiente di determinazione; coefficiente di determinazione della *cross-validation*.

Per valutare l'influenza delle variabili climatiche e di quelle relative al contenuto idrico del suolo nello stimare la variabilità del Ψ_{stem} , alcuni modelli (Tab. 10) sono stati testati nelle condizioni in cui la FTSW era superiore o inferiore al 25%, a prescindere dal momento della stagione e delle condizioni climatiche. Appare chiaro come i livelli di FTSW avessero un'influenza sulla stima a seconda che si trattasse di modelli basati su variabili del suolo o variabili climatiche. Quest'ultime, infatti, spiegavano molto bene la variazione del Ψ_{stem} finché il FTSW rimaneva al di sopra della soglia del 25%, al contrario, avendo un minor effetto sullo stato idrico delle piante al diminuire del SWC e della FTSW, esse perdevano l'abilità predittiva. In maniera diametralmente opposta invece, i modelli basati esclusivamente su SWC sono riusciti a stimare meglio le variazioni in Ψ_{stem} quando la FTSW è al di sotto del 25%. In queste condizioni modelli che incorporano sia variabili del suolo che climatiche hanno raggiunto valori AIC e BIC solo di poco più bassi e allo stesso modo i valori di R^2 della LOOCV erano equiparabili. Allo stesso modo, in condizioni di FTSW maggiore del 25%, la componente suolo nel modello ha aggiunto ben poco alla variabilità già spiegata dalla sola variabile climatica. Il modello 15 applicato in condizioni di $\text{FTSW} > 25\%$ generava addirittura un R^2 non significativo per via dell'ininfluenza della FTSW stessa nello stimare le variazioni in Ψ_{stem} .

Tabella 10. Confronto della bontà di adattamento e della predittività dei modelli per la stima del Ψ_{stem} in relazione alla FTSW (%) (<25%; > 25%).

N	Variabili	AIC		BIC		R ²		R ² _{Loocv}	
		<25%	>25%	<25%	>25%	<25%	>25%	<25%	>25%
5	p_4	6,08	2,11	9,67	5,70	0,48	0,40	0,35	0,24
6	FTSW	1,09	6,06	4,68	9,65	0,56	0,30 ^{n.s.}	0,45	0,17 ^{n.s.}
7	T_{max}	5,54	-40,98	9,31	-37,39	0,49	0,87	0,40	0,84
8	VPD_{max}	14,4	-41,55	17,63	-37,96	0,30	0,87	0,12	0,84
9	p_4, T_{max}	-1,68	-45,33	2,31	-41,34	0,68	0,91	0,56	0,85
10	p_4, VPD_{max}	4,72	-51,44	8,72	-47,45	0,60	0,93	0,44	0,89
11	p_4, ET_0	5,59	-13,64	9,59	-9,65	0,59	0,72	0,42	0,49
12	p_4, R_s	-16,51	-17,75	-12,52	-13,75	0,81	0,76	0,59	0,63
13	FTSW, T_{max}	-19,06	-41,81	-15,07	-37,82	0,83	0,90	0,75	0,84
16	FTSW, R_s	-18,21	-1,25	-14,22	2,74	0,82	0,57 ^{n.s.}	0,74	0,00 ^{n.s.}

N, numero modello, p_1 , SWC a 20 cm di profondità; FTSW, frazione traspirabile di acqua nel suolo; T_{max} , temperatura massima; VPD_{max} , deficit massimo di pressione del vapore; ET_0 , evapotraspirazione di riferimento; R_s , radiazione solare. AIC *Akaike Information Criterion*; BIC, *Bayesian Information Criterion*; R², coefficiente di determinazione; coefficiente di determinazione della *cross-validation*. n.s., R² non significativo.

6.3 Discussione

Lo studio ha riguardato l'indagine dell'adattamento di modelli non lineari per la stima del Ψ_{stem} che includevano variabili legate al sistema pianta-suolo-atmosfera in assenza di stress idrici limitanti in ambiente caldo-arido. Tra i modelli proposti, quelli che includevano le sole variabili legate al suolo spiegavano il 60% della variabilità del Ψ_{stem} in un intervallo compreso tra un minimo di -0,39 e un massimo di -1,41 MPa durante la stagione intera. L'aggiunta delle variabili climatiche ha permesso di spiegare fino all'80% di tale variabilità. Questo risultato, da leggere nelle condizioni specifiche del contesto in cui lo stato idrico della vite è stato monitorato, è però coerente con quelli ottenuti da altri autori in contesti differenti o in specie differenti; ad esempio, su agrumi, dove era spiegato l'85% della variabilità (Martí et al., 2013), su pesco (84%) (Abrisqueta et al., 2015) e su vite in regime colturale asciutto (70%) (Suter et al., 2019). Suter et al., (2019), analizzando un dataset relativo alle cultivar anisoidriche Merlot, Cabernet franc, e Cabernet Sauvignon, hanno proposto modelli non lineari che in assenza di variabili climatiche spiegavano il 66% della varianza (da -0,33 a -1,69 MPa) ma che con l'aggiunta di queste ha spiegato un +4%. Questa differenza è attribuibile principalmente ai valori maggiori di stress che sono stati rilevati in una finestra temporale più prossima ai mesi siccitosi (giugno-settembre); in queste condizioni infatti, la domanda atmosferica assume un peso minore nel governare le variazioni di Ψ_{stem} che sono influenzate maggiormente dalle variazioni del SWC; nonostante lo stato idrico della vite in condizioni di stress sia governato da fattori ambientali (e.g. T, VPD), quando l'acqua nel suolo scende oltre certe soglie e lo stato idrico diminuisce, i processi traspirativi in cultivar anisoidriche rallentano, ed il SWC diventa il

fattore dominante (Williams e Baeza, 2007; Olivo et al., 2009; Chaves et al., 2010). Nel presente studio, infatti, l'aggiunta delle variabili climatiche spiegava un ulteriore 10% della varianza, proprio in ragione dell'assenza di stress particolarmente severi per gran parte della stagione. Non è un caso, infatti, che il confronto dei modelli in condizioni differenti di FTSW abbia indicato come le variabili climatiche siano ottimi stimatori dello stato idrico quando il FTSW sia al di sopra del 25% e molto meno efficaci quando è al di sotto. Tra i modelli implementati, quello che includeva FTSW e T_{\max} (modello 13) sembrava però adattarsi indifferentemente alle due condizioni. Un risultato simile è stato ottenuto da Abrisqueta et al., (2015) su pesco, in cui la migliore correlazione tra SWC e Ψ_{stem} derivava dalle piante sottoposte a stress severi e, di contro, la componente atmosferica si adattava meglio alle tesi irrigate. Ciò farebbe intuire come l'utilizzo di un modello per la stima del Ψ_{stem} che tenga conto di questo doppio effetto sia da favorire in condizioni come quelle delle piante indagate nel presente studio. La cv Touriga Nacional è stata segnalata come cultivar a comportamento anisoidrico (Lovisolò et al., 2010; Costa et al., 2012b), tuttavia si è visto avere anche comportamento isoidrico a seconda del portinnesto, del clima e della durata degli stress idrici (Chaves et al., 2010; Costa et al., 2012a; Rodrigues et al., 2012). I risultati ottenuti farebbero propendere cautamente per un comportamento più vicino alla prima ipotesi. L'aggiunta di DOY e GDD nei modelli portava ad un 90% di variabilità spiegata. Anche questo risultato è assimilabile a quanto ottenuto da altri autori su Cabernet Sauvignon (Ohana-Levi et al., 2022), in cui lo stadio fenologico è stato incluso come variabile categorica, ottenendo un modello che dopo la *cross-validation* generava un RMSE di 1.5 MPa (12% d'errore in relazione all'ampiezza del dataset) equiparabile al valore di 1 MPa (9% di errore) ottenuto dal modello 16 nel presente studio. L'inclusione di queste variabili è giustificata dall'alta correlazione negativa con i valori di Ψ_{stem} , SWC e FTSW. È chiaro che il “decorso della stagione” è strettamente legato all'ambiente in cui si opera e all'annata, ed in condizioni idriche non limitanti tenderebbe a non cogliere le variazioni dello stato idrico delle piante, ma assumerebbe maggiore significato nei climi caldo-aridi, dove i pattern climatici (soprattutto temperature e precipitazioni) modificano ampiamente il range di Ψ_{stem} da aprile a settembre con un andamento decrescente dai mesi piovosi a quelli siccitosi (Suter et al., 2019). A prescindere dalla bontà predittiva dei modelli, la relazione tra Ψ_{stem} e le variabili T_{\max} , VPD_{\max} , R_s ed ET_0 è sempre stata descritta meglio da funzioni di tipo polinomiale, così come nel caso del SWC e della FTSW. La stessa non-linearità è stata riportata in vite da altri autori che hanno riscontrato una relazione di tipo esponenziale per T_{\max} (Suter et al., 2019) e di tipo logaritmico per i valori medi giornalieri di VPD (Gálvez et al., 2014). Inoltre, la scelta di utilizzare i valori massimi giornalieri per queste due variabili, derivata dalla migliore correlazione con il Ψ_{stem} , è supportata

anche da quanto riportato da Suter et al., (2019), i quali mettono in luce come non ci sia alcun vantaggio nell'utilizzare i valori medi giornalieri né valori puntuali relativi al preciso momento delle misurazioni, in quanto ritenuti troppo vincolanti e meno adatti alla stima del maggiore stress giornaliero. Proprio in ragione dell'effetto predominante della T_{\max} rispetto le altre variabili, si è visto come non sia vantaggioso ad utilizzare le variabili climatiche del giorno precedente. Potrebbe sorprendere che variabili come la T_{\max} e la R_s abbiano avuto maggiore impatto sulla stima dello stress rispetto a VPD_{\max} o ET_0 che sono strettamente legati alla domanda evapotraspirativa e quindi alle variazioni del Ψ_{stem} ; tuttavia, in condizioni in cui la temperatura varia maggiormente rispetto l'umidità relativa, le prime due variabili riescono ad identificare in maniera più precisa le variazioni (Soar et al., 2009; Santesteban et al., 2011). Risulta interessante evidenziare l'utilizzo da parte di Suter et al., (2015) del Ψ_{PD} come riferimento per il potenziale idrico del suolo, anziché l'effettivo SWC; tale parametro infatti tende ad equilibrarsi con gli strati più umidi del suolo interessati dalle radici (Ameglio et al., 1999; Donovan et al., 2001; Miras-Avalos et al., 2014). Questo dettaglio pone l'attenzione sul fatto che nel presente studio i valori di SWC che meglio si correlavano al Ψ_{stem} erano quelli misurati alla profondità compresa tra 0,6-0,8 m (p_4); sebbene non fossero ad ogni data gli strati più umidi, erano quelli in cui il SWC risultava più stabile e meno influenzato dalle condizioni atmosferiche. Risultati simili sono stati ottenuti in contesto di terreno a tessitura franco-argillosa, in cui la migliore correlazione tra SWC e Ψ_{stem} è stata ottenuta alla massima profondità indagata (0,4 m), e una tendenza simile è stata riscontrata su pesco (0,5-0,8 m) (Abrisqueta et al., 2015) e agrumi (0,6-0,8 m) (Martí et al., 2013). In suoli più leggeri, come quelli dei due vigneti oggetto del presente studio, è più comune una densità radicale maggiore a maggiori profondità, così come una distribuzione più omogenea dell'acqua lungo il profilo interessato dall'attività radicale (Soar and Loveys, 2007). Questi risultati calati nel contesto della letteratura di riferimento farebbero emergere come l'utilizzo di modelli per la stima del potenziale idrico sia una strada percorribile; tuttavia, l'utilizzo di modelli diversi adatti al contesto pedoclimatico e di gestione della coltura, sarebbe da preferire ad un modello unico.

6.4 Conclusioni

Lo studio ha dimostrato l'efficacia di modelli non lineari per stimare il Ψ_{stem} in un ambiente caldo-arido, considerando le interazioni complesse tra variabili legate al sistema pianta-suolo-atmosfera. I risultati ottenuti sono coerenti con studi precedenti condotti su vite ed altre specie vegetali in contesti diversi, confermando la robustezza dei modelli proposti. La variazione del Ψ_{stem} è stata influenzata principalmente dalle variazioni del contenuto di acqua nel suolo (SWC) in condizioni di

stress idrico moderato, mentre in situazioni di stress più severo, il ruolo delle variabili climatiche diventa preponderante. Questo suggerisce che la relativa importanza delle variabili ambientali dipende dal livello di stress idrico della pianta. L'analisi dei modelli ha evidenziato l'importanza di considerare la profondità del suolo in cui vengono misurati i parametri, con risultati migliori ottenuti a profondità dove il contenuto di acqua nel suolo è più stabile e meno influenzato dalle condizioni atmosferiche. L'adozione di sistemi decisionali di supporto (DSS) per la gestione dell'irrigazione potrebbe trarre vantaggio dai modelli non lineari sviluppati, i quali hanno dimostrato di essere efficaci nella stima del potenziale idrico delle piante in condizioni caldo-aride. Integrando i modelli di stima del Ψ_{stem} con dati in tempo reale sul contenuto di acqua nel suolo e le previsioni meteorologiche, i DSS potrebbero fornire indicazioni più precise e tempestive sull'esigenza di irrigare. La capacità dei modelli di spiegare fino al 90% della variabilità del Ψ_{stem} , inclusi parametri fenologici come DOY e GDD, potrebbe essere sfruttata per ottimizzare la programmazione dell'irrigazione in base alle fasi di crescita della vite e alle condizioni ambientali prevalenti. Ciò potrebbe consentire una gestione più mirata delle risorse idriche, riducendo al contempo il rischio di stress idrico e ottimizzando il rendimento e la qualità del raccolto. Inoltre, considerando l'importanza della profondità del suolo nella relazione tra il contenuto di acqua nel suolo e il Ψ_{stem} , i DSS potrebbero essere configurati per tenere conto delle specifiche caratteristiche del suolo e delle condizioni locali per fornire raccomandazioni personalizzate sull'irrigazione. L'implementazione di DSS per la gestione dell'irrigazione potrebbe quindi rappresentare un passo significativo verso una gestione più efficiente e sostenibile delle risorse idriche in viticoltura, contribuendo a migliorare la resilienza delle coltivazioni vitivinicole alle condizioni ambientali mutevoli e alla variabilità climatica.

6.5 Riferimenti bibliografici

Abrisqueta, I., Conejero, W., Valdés-Vela, M., Vera, J., Ortuño, M. F., and Ruiz-Sánchez, M. C. (2015). Stem water potential estimation of drip-irrigated early-maturing peach trees under Mediterranean conditions. *Comput. Electron. Agric.* 114, 7–13. doi: 10.1016/j.compag.2015.03.004.

Abtew, W., and Melesse, A. (2013). “Vapor Pressure Calculation Methods,” in *Evaporation and Evapotranspiration: Measurements and Estimations*, eds. W. Abtew and A. Melesse (Dordrecht: Springer Netherlands), 53–62. doi: 10.1007/978-94-007-4737-1_5.

Acevedo-Opazo, C., Ortega-Farias, S., and Fuentes, S. (2010). Effects of grapevine (*Vitis vinifera* L.) water status on water consumption, vegetative growth and grape quality: An irrigation scheduling application to achieve regulated deficit irrigation. *Agric. Water Manag.* 97, 956–964. doi: 10.1016/j.agwat.2010.01.025.

- Alibabaei, K., Gaspar, P. D., Campos, R. M., Rodrigues, G. C., and Lopes, C. M. (2023a). Evaluation of a Deep Learning Approach for Predicting the Fraction of Transpirable Soil Water in Vineyards. *Appl. Sci.* 13, 2815. doi: 10.3390/app13052815.
- Alibabaei, K., Gaspar, P. D., Campos, R. M., Rodrigues, G. C., and Lopes, C. M. (2023b). Evaluation of a Deep Learning Approach for Predicting the Fraction of Transpirable Soil Water in Vineyards. *Appl. Sci.* 13, 2815.
- Amerine, M., Kunkee, R., Ough, C., Singleton, V., and Webb, A. (1980). *Technology of Wine Making*, Westport, Connecticut, USA: AVI Publ. 185-703.
- Antonakis, J., and Dietz, J. (2011). Looking for validity or testing it? The perils of stepwise regression, extreme-scores analysis, heteroscedasticity, and measurement error. *Personal. Individ. Differ.* 50, 409–415. doi: 10.1016/j.paid.2010.09.014.
- Arnold, C. Y. (1959). The determination and significance of the base temperature in a linear heat unit system. *Proceedings. American Society for Horticultural Science.* vol. 74, pp. 430–445, 1959.
- Attia, F., Garcia, F., Mariem, F., Nuzzo, V., Dedieu, F., Garcia, M., et al. (2010). Water Stress In Tannat And Duras Grapevine Cultivars (*Vitis Vinifera* L.): Leaf Photosynthesis And Grape Phenolic Maturity. *J. Int. Sci. Vigne Vin.* J. 81-93.
- Barbagallo, M. G., Vesco, G., Di Lorenzo, R., Lo Bianco, R., and Pisciotta, A. (2021). Soil and Regulated Deficit Irrigation Affect Growth, Yield and Quality of ‘Nero d’Avola’ Grapes in a Semi-Arid Environment. *Plants* 10, 641. doi: 10.3390/plants10040641
- Bahar, E., Carbonneau, A., and Korkutal, I. (2011). The effect of extreme water stress on leaf drying limits and possibilities of recovering in three grapevine (*Vitis vinifera* L.) cultivars. *Afr. J. Agric. Res.* 6, 1151–1160.
- Cabelguenne, M., and Debaeke, P. (1998). Experimental determination and modelling of the soil water extraction capacities of crops of maize, sunflower, soya bean, sorghum and wheat. *Plant Soil* 202, 175–192.
- Chaves, M. m., Santos, T. p., Souza, C. r., Ortuño, M. f., Rodrigues, M. l., Lopes, C. m., et al. (2007). Deficit irrigation in grapevine improves water-use efficiency while controlling vigour and production quality. *Ann. Appl. Biol.* 150, 237–252. doi: 10.1111/j.1744-7348.2006.00123.x.
- Chaves, M., Zarrouk, O., Francisco, R., Costa, J., Santos, T., Regalado, A., et al. (2010). Grapevine under deficit irrigation: hints from physiological and molecular data. *Ann. Bot.* 105, 661–676. doi: 10.1093/aob/mcq030
- Choné, X., Van Leeuwen, C., Dubourdieu, D., and Gaudillère, J. P. (2001). Stem Water Potential is a Sensitive Indicator of Grapevine Water Status. *Ann. Bot.* 87, 477–483. doi: 10.1006/anbo.2000.1361.
- Cogato, A., Meggio, F., De Antoni Migliorati, M., and Marinello, F. (2019). Extreme weather events in agriculture: A systematic review. *Sustainability* 11, 2547.
- Cole, J., and Pagay, V. (2015). Usefulness of early morning stem water potential as a sensitive indicator of water status of deficit-irrigated grapevines (*Vitis vinifera* L.). *Sci. Hort.* 191, 10–14. doi: 10.1016/j.scienta.2015.04.034.
- Copas, J. B. (1983). Regression, prediction and shrinkage. *J. R. Stat. Soc. Ser. B Stat. Methodol.* 45, 311–335.
- Costa, J. M., Ortuño, M. F., and Chaves, M. M. (2007). Deficit irrigation as a strategy to save water: physiology and potential application to horticulture. *J. Integr. Plant Biol.* 49, 1421–1434.
- Costa, J. M., Ortuño, M. F., Lopes, C. M., and Chaves, M. M. (2012a). Grapevine varieties exhibiting differences in stomatal response to water deficit. *Funct. Plant Biol.* 39, 179–189.
- Costa, J. M., Ortuño, M. F., Lopes, C. M., Chaves, M. M., Costa, J. M., Ortuño, M. F., et al. (2012b). Grapevine varieties exhibiting differences in stomatal response to water deficit. *Funct. Plant Biol.* 39, 179–189. doi: 10.1071/FP11156

- Costa, J., Vaz, M., Escalona, J., Egipto, R., Lopes, C., Medrano, H., et al. (2016). Modern viticulture in southern Europe: Vulnerabilities and strategies for adaptation to water scarcity. *Agric. Water Manag.* 164, 5–18.
- De Bei, R., Cozzolino, D., Sullivan, W., Cynkar, W., Fuentes, S., Dambergs, R., et al. (2011). Non-destructive measurement of grapevine water potential using near infrared spectroscopy. *Aust. J. Grape Wine Res.* 17, 62–71. doi: 10.1111/j.1755-0238.2010.00117.x.
- Deloire, A., Carbonneau, A., Wang, Z., and Ojeda, H. (2004). Vine and water: a short review. *Oeno One* 38, 1–13.
- Deloire, A., and Heyns, D. (2011). The leaf water potentials: Principles, method and thresholds. *Wynboer* 265, 119–121.
- Deloire, A., Pellegrino, A., and Rogiers, S. (2020). A few words on grapevine leaf water potential : Original language of the article: English. *IVES Tech. Rev. Vine Wine*. doi: 10.20870/IVES-TR.2020.3620.
- Easterling, D. R., Evans, J., Groisman, P. Y., Karl, T. R., Kunkel, K. E., and Ambenje, P. (2000). Observed variability and trends in extreme climate events: a brief review. *Bull. Am. Meteorol. Soc.* 81, 417–426.
- Escalona, J. M., Flexas, J., and Medrano, H. (2000). Stomatal and non-stomatal limitations of photosynthesis under water stress in field-grown grapevines. *Funct. Plant Biol.* 27, 87–87.
- Fraga, H., de Cortázar Atauri, I. G., and Santos, J. (2018). Viticultural irrigation demands under climate change scenarios in Portugal. *Agric. Water Manag.* 196, 66–74.
- Fraga, H., García de Cortázar Atauri, I., Malheiro, A. C., and Santos, J. A. (2016). Modelling climate change impacts on viticultural yield, phenology and stress conditions in Europe. *Glob. Change Biol.* 22, 3774–3788.
- Gálvez, R., Callejas, R., Reginato, G., and Peppi, M. C. (2014). Irrigation schedule on table grapes by stem water potential and vapor pressure deficit allows to optimize Water Use. *Ciênc. E Téc. Vitivinícola* 29, 60–70. doi: 10.1051/ctv/20142902060.
- Greenwood, D., Neeteson, J., and Draycott, A. (1985). Response of potatoes to N fertilizer: dynamic model. *Plant Soil* 85, 185–203.
- Guilpart, N., Metay, A., and Gary, C. (2014). Grapevine bud fertility and number of berries per bunch are determined by water and nitrogen stress around flowering in the previous year. *Eur. J. Agron.* 54, 9–20. doi: org/10.1016/j.eja.2013.11.002
- Hussein-Mounzer, O., Mendoza-Hernández, J. R., Abrisqueta-Villena, I., Tapia-Vargas, L. M., Abrisqueta-García, J. M., Vera-Muñoz, J., et al. (2008). Soil water content measured by FDR probes and thresholds for drip irrigation management in peach trees. *Agric. Téc. En México* 34, 313–322.
- Intrigliolo, D. S., and Castel, J. R. (2010). Response of grapevine cv. ‘Tempranillo’ to timing and amount of irrigation: water relations, vine growth, yield and berry and wine composition. *Irrig. Sci.* 28, 113–125. doi: 10.1007/s00271-009-0164-1
- Jones, G. V., and Alves, F. (2012). Impact of climate change on wine production: a global overview and regional assessment in the Douro Valley of Portugal. *Int. J. Glob. Warm.* Available at: <https://www.inderscienceonline.com/doi/10.1504/IJGW.2012.049448> (Accessed May 7, 2024).
- Jones, G. V., and Webb, L. B. (2010). Climate Change, Viticulture, and Wine: Challenges and Opportunities. *J. Wine Res.* 21, 103–106. doi: 10.1080/09571264.2010.530091.
- Jones, G. V., White, M. A., Cooper, O. R., and Storchmann, K. (2005). Climate change and global wine quality. *Clim. Change* 73, 319–343. doi: 10.1007/s10584-005-4704-2.
- Jones, H. G. (2007). Monitoring plant and soil water status: established and novel methods revisited and their relevance to studies of drought tolerance. *J. Exp. Bot.* 58, 119–130.

- Koundouras, S., Hatzidimitriou, E., Karamolegkou, M., Dimopoulou, E., Kallithraka, S., Tsialtas, J. T., et al. (2009). Irrigation and rootstock effects on the phenolic concentration and aroma potential of *Vitis vinifera* L. cv. Cabernet Sauvignon grapes. *J. Agric. Food Chem.* 57, 7805–7813.
- Lacape, M., Wery, J., and Annerose, D. (1998). Relationships between plant and soil water status in five field-grown cotton (*Gossypium hirsutum* L.) cultivars. *Field Crops Res.* 57, 29–43.
- Lanari, V., Palliotti, A., Sabbatini, P., Howell, G. S., and Silvestroni, O. (2014). Optimizing deficit irrigation strategies to manage vine performance and fruit composition of field-grown ‘Sangiovese’ (*Vitis vinifera* L.) grapevines. *Sci. Hort.* 179, 239–247.
- Lebon, E., Dumas, V., Pieri, P., and Schultz, H. R. (2003). Modelling the seasonal dynamics of the soil water balance of vineyards. *Funct. Plant Biol.* 30, 699–710.
- Lebon, E., Pellegrino, A., Lecoeur, J., and Tardieu, F. (2001). Shoot architectural responses induced by controlled soil water deficit in vine (*Vitis vinifera* L. cv. Grenache noir). Proceedings of the 12th GESCO Conference. 1, pp. 229–244.
- Lee, H., Calvin, K., Dasgupta, D., Krinner, G., Mukherji, A., Thorne, P., et al. (2023). IPCC, 2023: Climate Change 2023: Synthesis Report, Summary for Policymakers. Contribution of Working Groups I, II and III to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change [Core Writing Team, H. Lee and J. Romero (eds.)]. IPCC, Geneva, Switzerland.
- Levin, A. D. (2019). Re-evaluating pressure chamber methods of water status determination in field-grown grapevine (*Vitis* spp.). *Agric. Water Manag.* 221, 422–429.
- Lovisolò, C., Perrone, I., Carra, A., Ferrandino, A., Flexas, J., Medrano, H., et al. (2010). Drought-induced changes in development and function of grapevine (*Vitis* spp.) organs and in their hydraulic and non-hydraulic interactions at the whole-plant level: a physiological and molecular update. *Funct. Plant Biol.* 37, 98–116.
- Malek, Ž., Verburg, P. H., Geijzendorffer, I. R., Bondeau, A., and Cramer, W. (2018). Global change effects on land management in the Mediterranean region. *Glob. Environ. Change* 50, 238–254.
- Martí, P., Gasque, M., and González-Altozano, P. (2013). An artificial neural network approach to the estimation of stem water potential from frequency domain reflectometry soil moisture measurements and meteorological data. *Comput. Electron. Agric.* 91, 75–86. doi: 10.1016/j.compag.2012.12.001.
- Moriondo, M., Jones, G., Bois, B., Dibari, C., Ferrise, R., Trombi, G., et al. (2013). Projected shifts of wine regions in response to climate change. *Clim. Change* 119, 825–839.
- Neter, J., Kutner, M. H., Nachtsheim, C. J., and Wasserman, W. (1996). Applied linear statistical models. 5th edition. McGraw-Hill/Irwin.
- Ohana-Levi, N., Zachs, I., Hagag, N., Shemesh, L., and Netzer, Y. (2022). Grapevine stem water potential estimation based on sensor fusion. *Comput. Electron. Agric.* 198, 107016. doi: 10.1016/j.compag.2022.107016.
- Ojeda, H., Andary, C., Kraeva, E., Carbonneau, A., and Deloire, A. (2002). Influence of pre-and postveraison water deficit on synthesis and concentration of skin phenolic compounds during berry growth of *Vitis vinifera* cv. Shiraz. *Am. J. Enol. Vitic.* 53, 261–267.
- Ojeda, H., Deloire, A., and Carbonneau, A. (2001). Influence of water deficits on grape berry growth. *VITIS-GEILWEILERHOF*- 40, 141–146.
- Olivo, N., Girona, J., and Marsal, J. (2009). Seasonal sensitivity of stem water potential to vapour pressure deficit in grapevine. *Irrig. Sci.* 27, 175–182. doi: 10.1007/s00271-008-0134-z.
- Parker, A. K., DE CORTÁZAR-ATAURI, I. G., Van Leeuwen, C., and Chuine, I. (2011). General phenological model to characterise the timing of flowering and veraison of *Vitis vinifera* L. *Aust. J. Grape Wine Res.* 17, 206–216.

- Paulus, S., Behmann, J., Mahlein, A.-K., Plümer, L., and Kuhlmann, H. (2014). Low-Cost 3D Systems: Suitable Tools for Plant Phenotyping. *Sensors* 14, 3001–3018. doi: 10.3390/s140203001.
- Pellegrino, A. (2003). Elaboration d'un outil de diagnostic du stress hydrique utilisable sur la vigne en parcelle agricole par couplage d'un modèle de bilan hydrique et d'indicateurs de fonctionnement de la plante. PhD Thesis. École nationale supérieure agronomique. Montpellier, 2003.
- Pellegrino, A., Gozé, E., Lebon, E., and Wery, J. (2006). A model-based diagnosis tool to evaluate the water stress experienced by grapevine in field sites. *Eur. J. Agron.* 25, 49–59. doi: 10.1016/j.eja.2006.03.003.
- Pellegrino, A., Lebon, E., Simonneau, T., and Wery, J. (2005a). Towards a simple indicator of water stress in grapevine (*Vitis vinifera* L.) based on the differential sensitivities of vegetative growth components. *Aust. J. Grape Wine Res.* 11, 306–315.
- Pellegrino, A., Lebon, E., Voltz, M., and Wery, J. (2005b). Relationships between plant and soil water status in vine (*Vitis vinifera* L.). *Plant Soil* 266, 129–142.
- Pisciotta, A., Di Lorenzo, R., Santalucia, G., and Barbagallo, M. G. (2018). Response of grapevine (Cabernet Sauvignon cv) to above ground and subsurface drip irrigation under arid conditions. *Agric. Water Manag.* 197, 122–131.
- Pons, A., Allamy, L., Schüttler, A., Rauhut, D., Thibon, C., and Darriet, P. (2017). What is the expected impact of climate change on wine aroma compounds and their precursors in grape? *OENO One* 51, 141–146.
- Pritchard, T., Verdegaal, P., and Rous, C. (1995). Modification of wine characteristics through irrigation management. *Grape Grow.* 5, 8–13.
- Ramos, M., Jones, G., and Martínez-Casasnovas, J. (2008). Structure and trends in climate parameters affecting winegrape production in northeast Spain. *Clim. Res.* 38, 1–15.
- Ratliff, L., Ritchie, J., and Cassel, D. (1983). Field-measured limits of soil water availability as related to laboratory-measured properties. *Soil Sci. Soc. Am. J.* 47, 770–775.
- Resco, P., Iglesias, A., Bardají, I., and Sotés, V. (2016). Exploring adaptation choices for grapevine regions in Spain. *Reg. Environ. Change* 16, 979–993.
- Ritchie, J. (1981). Soil water availability. *Plant Soil*, 327–338.
- Rocha, J., Carvalho-Santos, C., Diogo, P., Beça, P., Keizer, J. J., and Nunes, J. P. (2020). Impacts of climate change on reservoir water availability, quality and irrigation needs in a water scarce Mediterranean region (southern Portugal). *Sci. Total Environ.* 736, 139477.
- Rodrigues, P., Pedroso, V., Gouveia, J. P., Martins, S., Lopes, C., and Alves, I. (2012). Influence of soil water content and atmospheric conditions on leaf water potential in cv. “Touriga Nacional” deep-rooted vineyards. *Irrig. Sci.* 30, 407–417. doi: 10.1007/s00271-012-0350-4.
- Rosopa, P. J., Schaffer, M. M., and Schroeder, A. N. (2013). Managing heteroscedasticity in general linear models. *Psychol. Methods* 18, 335.
- Santesteban, L. G., Miranda, C., Marín, D., Sesma, B., Intrigliolo, D. S., Mirás-Avalos, J. M., et al. (2019). Discrimination ability of leaf and stem water potential at different times of the day through a meta-analysis in grapevine (*Vitis vinifera* L.). *Agric. Water Manag.* 221, 202–210. doi: 10.1016/j.agwat.2019.04.020.
- Santesteban, L. G., Miranda, C., and Royo, J. B. (2011). Suitability of pre-dawn and stem water potential as indicators of vineyard water status in cv. Tempranillo. *Aust. J. Grape Wine Res.* 17, 43–51. doi: 10.1111/j.1755-0238.2010.00116.x.
- Scholander, P. F., Bradstreet, E. D., Hemmingsen, E., and Hammel, H. (1965). Sap Pressure in Vascular Plants: Negative hydrostatic pressure can be measured in plants. *Science* 148, 339–346.

- Schultz, H. (2000). Climate change and viticulture: a European perspective on climatology, carbon dioxide and UV-B effects. *Aust. J. Grape Wine Res.* 6, 2–12.
- Soar, C. J., Collins, M. J., and Sadras, V. O. (2009). Irrigated Shiraz vines (*Vitis vinifera*) upregulate gas exchange and maintain berry growth in response to short spells of high maximum temperature in the field. *Funct. Plant Biol.* 36, 801–814.
- Soar, C. J., and Loveys, B. R. (2007). The effect of changing patterns in soil-moisture availability on grapevine root distribution, and viticultural implications for converting full-cover irrigation into a point-source irrigation system. *Aust. J. Grape Wine Res.* 13, 2–13. doi: 10.1111/j.1755-0238.2007.tb00066.x.
- Sofo, A., Nuzzo, V., Tataranni, G., Manfra, M., De Nisco, M., and Scopa, A. (2012). Berry morphology and composition in irrigated and non-irrigated grapevine (*Vitis vinifera* L.). *J. Plant Physiol.* 169, 1023–1031.
- Suter, B., Triolo, R., Pernet, D., Dai, Z., and Van Leeuwen, C. (2019). Modeling Stem Water Potential by Separating the Effects of Soil Water Availability and Climatic Conditions on Water Status in Grapevine (*Vitis vinifera* L.). *Front. Plant Sci.* 10. doi: 10.3389/fpls.2019.01485.
- Tian, X., Dong, J., Jin, S., He, H., Yin, H., and Chen, X. (2023). Climate change impacts on regional agricultural irrigation water use in semi-arid environments. *Agric. Water Manag.* 281, 108239.
- Triolo, R., Roby, J. P., Plaia, A., Hilbert, G., Buscemi, S., Di Lorenzo, R., et al. (2018). Hierarchy of factors impacting grape berry mass: separation of direct and indirect effects on major berry metabolites. *Am. J. Enol. Vitic.* 69, 103–112.
- Triolo, R., Roby, J. P., Pisciotta, A., Di Lorenzo, R., and van Leeuwen, C. (2019). Impact of vine water status on berry mass and berry tissue development of Cabernet franc (*Vitis vinifera* L.), assessed at berry level. *J. Sci. Food Agric.* 99, 5711–5719. doi: 10.1002/jsfa.9834.
- van Leeuwen, C., and Darriet, P. (2016). The impact of climate change on viticulture and wine quality. *J. Wine Econ.* 11, 150–167.
- van Leeuwen, C., and Seguin, G. (2006). The concept of terroir in viticulture. *J. Wine Res.* 17, 1–10.
- van Leeuwen, C., Trégoat, O., Choné, X., Bois, B., Pernet, D., and Gaudillère, J.-P. (2009). Vine water status is a key factor in grape ripening and vintage quality for red Bordeaux wine. How can it be assessed for vineyard management purposes? *Oeno One* 43, 121–134.
- Williams, L. (2013). Physiological tools to assess vine water status for use in vineyard irrigation management: review and update. *Acta Hortic.* 151–166. doi: 10.17660/ActaHortic.2017.1157.24.
- Williams, L. E., and Baeza, P. (2007). Relationships among Ambient Temperature and Vapor Pressure Deficit and Leaf and Stem Water Potentials of Fully Irrigated, Field-Grown Grapevines. *Am. J. Enol. Vitic.* 58, 173–181. doi: 10.5344/ajev.2007.58.2.173.
- Zarrouk, O., Francisco, R., Pinto-Marijuan, M., Brossa, R., Santos, R. R., Pinheiro, C., et al. (2012). Impact of irrigation regime on berry development and flavonoids composition in Aragonez (Syn. Tempranillo) grapevine. *Agric. Water Manag.* 114, 18–29. doi: 10.1016/j.agwat.2012.06.018.

7 Complementary Use of Ground-Based Proximal Sensing and Airborne/Spaceborne Remote Sensing Techniques in Precision Agriculture: A Systematic Review



Review

Complementary Use of Ground-Based Proximal Sensing and Airborne/Spaceborne Remote Sensing Techniques in Precision Agriculture: A Systematic Review

Angelos Alexopoulos ^{1,*}, Konstantinos Koutras ^{1,*}, Sihem Ben Ali ², Stefano Puccio ³, Alessandro Carella ³, Roberta Ottaviano ⁴ and Athanasios Kalogeras ¹

¹ Industrial Systems Institute, Athena Research Center, Platani, 26504 Patras, Greece; kalogeras@isi.gr

² Association de Sauvegarde de Matmata, Matmata 6070, Tunisia; sahoumba@gmail.com

³ Department of Agricultural, Food and Forest Sciences, University of Palermo, 90133 Palermo, Italy

⁴ FgTech, Via san Rocco 5, 40122 Bologna, Italy

* Correspondence: aggalexopoulos@isi.gr (A.A.); koutrask@athenarc.gr (K.K.)

1 Introduction

Worldwide food production is a more sensitive issue than ever before. The global population is expected to reach 10 billion by 2050, adding an extra 2.4 billion to the global urban population, and increasing overall demand for food production by 70 percent [1]. At the same time, reduced rural population, degraded farmlands [2], climate change decreasing agricultural productivity [3], and food waste [4] make this requirement quite difficult to meet unless the agricultural productive model changes dramatically. To this end, Agriculture 4.0, or the fourth Agricultural Revolution, promises a technological revolution for enhanced agricultural productivity and increased eco-efficiency [5]. Driven by the wider Industry 4.0 paradigm shift, Agriculture 4.0 brings to the agricultural sector a number of mainstream technologies, including sensing infrastructures, big data analytics, Artificial Intelligence, Blockchain, and robotics [6]. It thus engages in a unifying model pertinent to different domains of human activity [7,8], recognizing cyberphysical systems and their components as a key element in this transition [9] and targeting an increase in the overall quality of life leading to Society 5.0 paradigm [10].

Sensing plays an important role in the Agriculture 4.0 paradigm shift. Obtaining the necessary information from the field may be achieved by exploiting different technological options that

include ground-based sensors, or remote sensing techniques [11,12]. The former are strongly associated with technologies such as the Internet of Things (IoT) [13,14] and the Industrial Internet of Things (IIoT) [15], as well as Wireless Sensor Networks (WSNs) [16]. The latter may be distinguished from airborne remote sensing utilizing Unmanned Aerial Vehicles (UAVs) and spaceborne remote sensing exploiting satellite data. The present work performs a systematic review related to the three aforementioned main technologies with reference to their application in agriculture. The main research questions (RQs) that the authors wish to answer in this work are the following:

RQ1 What are the challenges of the three technologies that this work deals with?

RQ2 How can these three technologies be used in a complementary way so as to facilitate the transition to Agriculture 4.0?

The rest of the paper is structured as follows. An overview of the three aforementioned categories of sensing technologies is presented in Section 2. The methodology followed for the systematic review is showcased in Section 3. The outcome of the literature review performed is elaborated in Section 4 detailing the challenges and synergies found for the three technologies under investigation. Section 5 presents a discussion providing the paper's view on the research questions formulated. Finally, Section 6 presents conclusions and identifies potential future research directions.

2. Overview of Sensing Technologies

2.1. Ground-Based Sensing

Ground or proximal sensors play a key role in Precision Agriculture (PA). Proximal sensing is defined as the use of field sensors to obtain signals from the analyzed feature (e.g., climate, soil, or plant) when the sensor is in contact with or close to it (within a few meters) [17,18]. Nowadays, there are many types of proximal sensors capable of monitoring multiple parameters related mainly to the plant water, nutritional, and health status [19]. Another classification includes the division into static proximal sensors, which remain stationary in the field, or mobile proximal sensors, mounted on vehicles or robots [20].

It is well known that climate is one of the main aspects determining plant growth and outputs [21]. This occurs because each plant is sensitive to certain growing conditions such as air temperature, relative humidity, wind, soil temperature, and light. Thus, it is crucial for farmers to understand the

climatic conditions on their farms [22]. Hence, meteorological information may help the farmer make the most efficient use of natural resources to improve agricultural production. Among the most common proximal sensors are those that can assess climatic parameters. Usually, such sensors are mounted in small weather stations in the field, and a basic weather station usually consists of a temperature and humidity sensor, a wind speed sensor, a sensor that measures precipitation height, and one that can assess solar radiation information.

Another category of ground-based sensors is soil-based sensors. New-generation proximal soil-based sensors are able to monitor real-time physical and chemical soil parameters, such as moisture, temperature, pH, soil nutrients, and pollutants, providing key information to optimize crop cycle management, combat biotic and abiotic stresses, and improve crop yields.

One of the most common uses of such sensing is for irrigation management, through the capability of estimating the crop reference evapotranspiration (ET_0), returning to the plant the full or partial (depending on the farm irrigation strategy) amount of water lost by evapotranspiration, using the FAO-56 Penman–Monteith equation recommended by the United Nations (UN) Food and Agriculture Organization (FAO) [23]. Weather observations and forecasts, coupled with physical observations, can help predict the development of the main pests and can be used to schedule control actions to prevent pest development. Thanks to such information, it is possible to change plant microclimate and influence the habitability for pests, for example, through pruning operations to reduce internal canopy humidity and reduce the probability of infection by plant pathogens. Integrated pest management has been a response to reduce the environmental impact of chemical pesticides [24].

For irrigation scheduling nowadays, there is a tendency to focus on plant-based sensors. Common and reliable sensors capable of continuously estimating plant water status include leaf turgor sensors, devices capable of assessing leaf turgor pressure, a parameter directly related to plant water status; sapflow sensors, capable of providing indications of the plant transpiration flows; trunk dendrometers, capable of monitoring trunk fluctuations over time, dependent on the plant hydration status; and Linear Variable Differential Transformer (LVDT) fruit gauges [25]. The latter are low-cost devices that can continuously and very accurately monitor fruit development over the day, providing information about plant water and nutritional status during the fruit growth stage [26,27].

Although plant-based sensors for monitoring plant water status are among the most common, there are other devices that are very useful for crop management. Foliar wetness sensors are devices installed inside the canopy to assess its moisture status, preventing the rise of pathogens and

diseases [28]. Optical sensors, working in the visible/near-infrared band, can be useful for estimating the nutritional and health status of the plant [29,30]. On the other hand, Light Detection and Ranging (LiDAR) technology sensors can be used to assess and measure canopy shape and volume [31].

Last-generation sensors allow continuous data acquisition, greatly increasing the degree of information without increasing the farm workload. Moreover, these sensors can be used to create IoT networks for various applications [32]. IoT focuses primarily on providing many small, interconnected devices, mainly using WSN technology, that can work together with a common purpose [33]. A WSN has as a main target of offering sensing and monitoring capabilities utilizing wireless technologies to connect to sensing devices. In WSNs, data collection and transfer occur in four stages: collecting the data, processing the data, packaging the data, and transferring the data [34]. With the help of WSN technologies, farmers can analyze weather conditions, water use, energy use, soil conditions, and plant morpho-physiological parameters collected from their farm feeding decision-support systems (DSSs) [35]. WSN has to fulfill requirements such as long range, low energy, and adequate data rate. Several technologies, including Long-Range Wide Area Network (LoRaWAN) [36], Narrow Band IoT (NB-IoT) [37], SigFox [38], and Long-Term Evolution for Machines (LTE-M) [39], are arising as candidates in the upcoming transition to 5G communications [40].

In the context of this paper, and from this point on, we use the term IoT to collectively describe the different technologies associated with ground-based proximal sensing.

2.2. Remote Sensing Techniques

UAVs were used in agriculture in 1997 for the first time. This technology was first used in Japan and South Korea, where mountainous terrain and relatively small family- owned farms required lower-cost and higher-precision spraying. Historically, the use of aerial application of pesticides was prohibited by the European Union, inhibiting the growth of UAV application in agriculture. Later use of UAVs was centered mainly around aerial imagery.

Nowadays, UAVs are applied in PA to collect images of high quality, mounting adequate sensors to this end. Sensor choice is carried out carefully according to a number of parameters such as resolution, optical quality, weight, captured images, and price. UAVs may carry multiple types of sensors: RGB (red–green–blue), NIR (near-infrared), IR (infrared), multispectral (MS), and

hyperspectral (HS) cameras. RGB and NIR bands are useful for collecting information about vegetation stress and chlorophyll content [41]. Furthermore, LiDAR sensors can also be used in environmental sciences for terrestrial scanning, obtaining information on crop height or canopy size [42].

Each type of sensor can be utilized for monitoring diverse parameters in vegetation. RGB is low in cost and useful for UAV applications of precision farming, such as the creation of orthomosaics, as they can capture images with high resolution. In addition, they are useful in different conditions (sunny and cloudy weather). But they cannot analyze many vegetation indices due to their limited spectral range. MS and HS sensors,

compared to RGB, collect data in different spectral channels and acquire images with high quality that are useful for studying a multitude of physical and biological characteristics of plantations [43]. Therefore, MS and HS sensors are the most popular in PA, although they are expensive. Moreover, thermal sensors are used to collect temperature information. Their use proves to be optimal in irrigation-management applications [43]. The specific targeted application type is what dictates the adequate selection of sensors. For instance, MS sensors are suitable for the detection of diseases, offering many bands that can detect the sensitivity of symptoms. On the other hand, one RGB camera should be enough for data collection related to agricultural mapping.

The most well-known applications of UAVs for PA, as found in the literature, include weed mapping and management [44], irrigation management [45], crop spraying [46], vegetation health monitoring and diseases detection [47], and vegetation growth monitoring and yield estimation [43]. UAVs acquire information that can be useful for the measurement of different parameters such as the crop height and the Leaf Area Index (LAI), allowing crop growth control in crops such as cotton, wheat, or sorghum. UAVs can be used to calculate the most common vegetative index to determine the diseased tissue, i.e., the normalized difference vegetation index (NDVI), which is useful for monitoring crop health and detecting diseases at an early stage, also mapping the size of the defect. In addition, a very important field of UAV application is water management, as precision irrigation techniques improve the efficiency of water use resources [43]. UAVs have rapidly evolved into a common tool to increase agricultural output and overall efficiency, decreasing expensive inputs of water, fertilizers, and pesticides. They can also indicate damages in crops that cannot be easily detected from the ground and be applicable in areas of big dimensions [48].

Finally, spaceborne remote sensing satellites equipped with digital RGB cameras and MS or HS sensors are nowadays among the most widely used technologies in monitoring field variability,

which usually includes landscape monitoring, yield, field, soil and crop variability, or variability due to anomalous factors [49]. By measuring the reflectance of the light incident on soil and crops, they are used to assess their characteristics and behavior by acquiring information at different spatial, spectral, radiometric, and temporal resolutions. Similarly to UAV-based remote sensing, information acquired from satellites is usually expressed by indices, among which the NDVI index is one of the most widely used. Each index is calculated from values at visible and non-visible wavelengths: red, green, blue, near-infrared, red edge, and infrared bands are the most frequently used [12,50].

Every satellite and sensor is characterized by different spatial and temporal resolutions. Temporal resolution is associated with the satellite itself and can be considered as the time the satellite takes to complete an orbit and revisit the same observation area. Sensors, instead, can have high spatial resolution and tend to have small footprints, or they have low spatial resolution and tend to have larger footprints. As Vanguard 2 and TIROS 1 were launched in 1959 and 1960, respectively, and are used for assessing meteorological information, the history of satellites for agricultural use starts in 1972 with Landsat 1 (1972–1978), a satellite capturing multispectral data for earth-surface image acquisition. After that, a series of Landsat satellites (from 2 to 9) were launched. Used in many parts of the world, these satellites (Landsat-7, -8, and -9 are still active) provide high-quality images in order to classify land uses, monitor crop conditions, and estimate irrigation water requirements, resulting in more affordable imagery than the aerial photography once used to classify land use across large regions. Later, from the end of the 1990s to the 2010s, other satellites were launched, such as IKONOS (1999–2015), which provides 4 m spatial resolution images; Worldview-2 (2009–present); and GeoEye-1 (2008–present), with a ≤ 2 m resolution; Sentinel-2A (2014–present) and -2B (2015–present), with a 10 to 60 m resolution; and other satellites constellations such as Pleiades-1A (2011–present) and -1B (2012–present), SkySat-1 (2013–present) and -2 (2014–present), or Superview- 1 (2016–present), namely small satellites with compact, cheaper, and more replaceable sensors [51]. The primary benefits of this type of technology use are widely documented in the literature and include reduced environmental impact, increased crop yield, enhanced product quality, and input savings [52–54]. Despite the number and variety of satellite data being made available at various costs and for different purposes, there are certain challenges to using satellite imaging closely related to the purpose of the study.

3. **Methodology**

The present review was conducted following the guidelines set by the Preferred Reporting Items for the Systematic Reviews and Meta-Analyses (PRISMA 2020) methodology [55]. The PRISMA statement consists of a checklist of 27 items recommended for reporting in systematic literature reviews. This checklist was designed to help reviewers report the purpose of the review, the methodology that was followed, and the outcomes of their research. This section provides answers to the PRISMA 2020 statement item checklist, giving a comprehensive illustration of the methodology followed in the present work.

As the technology of sensors rapidly advances, a review of current literature in PA is needed to put into scope the available technologies, their competition, the cases that are most favorable for their application, and how to best utilize them in unison to maximize agricultural sustainability and profit for farmers. This review was conducted with the mindset of bringing to the fore the challenges of the three technologies that currently play a central role in the future of PA and sustainable development. To the knowledge of the authors, a systematic review with the scope of attempting to synthesize the literature for these three technologies has not been attempted before, testifying to the novelty of the current work. This study answers the two RQs that were mentioned in the introduction. According to the RQs, the following search query was formulated:

TITLE-ABS-KEY (“Precision Agriculture” AND (((UAV OR Satellite) AND “Remote Sensing”) OR IoT))

All results obtained from this query also had to fulfil the following criteria:

- Should be written in English,
- Should be published after 2017,
- Should be published in Q1 and Q2 journals.

All studies that met the criteria proceeded to the first screening phase. During this phase, all six authors split the remaining papers between themselves and skimmed through the abstract and the main text for phrases mentioning challenges or synergies for the three technologies. At this phase, only phrases were sought. All works that survived this stage passed through a second screening phase, during which remaining works were split between two reviewers and carefully read through. The reviewers had to ascertain to what degree each study analysed the challenge or the synergy it mentioned. If the analysis of the challenge or synergy was profound enough, the work was finally admitted for inclusion. The aforementioned query and exclusion criteria were applied in the Scopus database on 6 October 2022.

The explanation for the choice of this query was that the application of these three technologies in PA was sought for sensing purposes; therefore, “remote sensing” was added with an AND for UAVs and satellites to exclude other uses, e.g., spraying. Furthermore, the term “IoT” was regarded as more appropriate when paired with “Precision Agriculture” to provide a representative set of relevant works and was preferred over terms such as “Wireless Sensor Networks” or “Ground Sensors”.

The aforementioned query produced a result of 435 articles. Out of these, 383 were articles published in Q1 and Q2 journals. These 383 articles were divided equally among the six authors for the first screening phase. Articles that had no mention of challenges, or synergy of technologies, were eliminated. The first screening phase eliminated a further 172 works. Therefore, 211 works made it to the second screening phase, during which 24 works were excluded, leading to a total of 187 articles. Looking through these 187 records, it was evident that synergies were underrepresented, as only 6 works mentioned a substantial synergy. Citation searching had to be performed to ensure that the contemporary literature on synergies was adequately represented. Citation searching added a further 18 records, for a total of 205 records to be admitted for inclusion in the final review. Figure 1 presents a flowchart giving an overview of the screening phases and the steps followed for the systematic literature review.

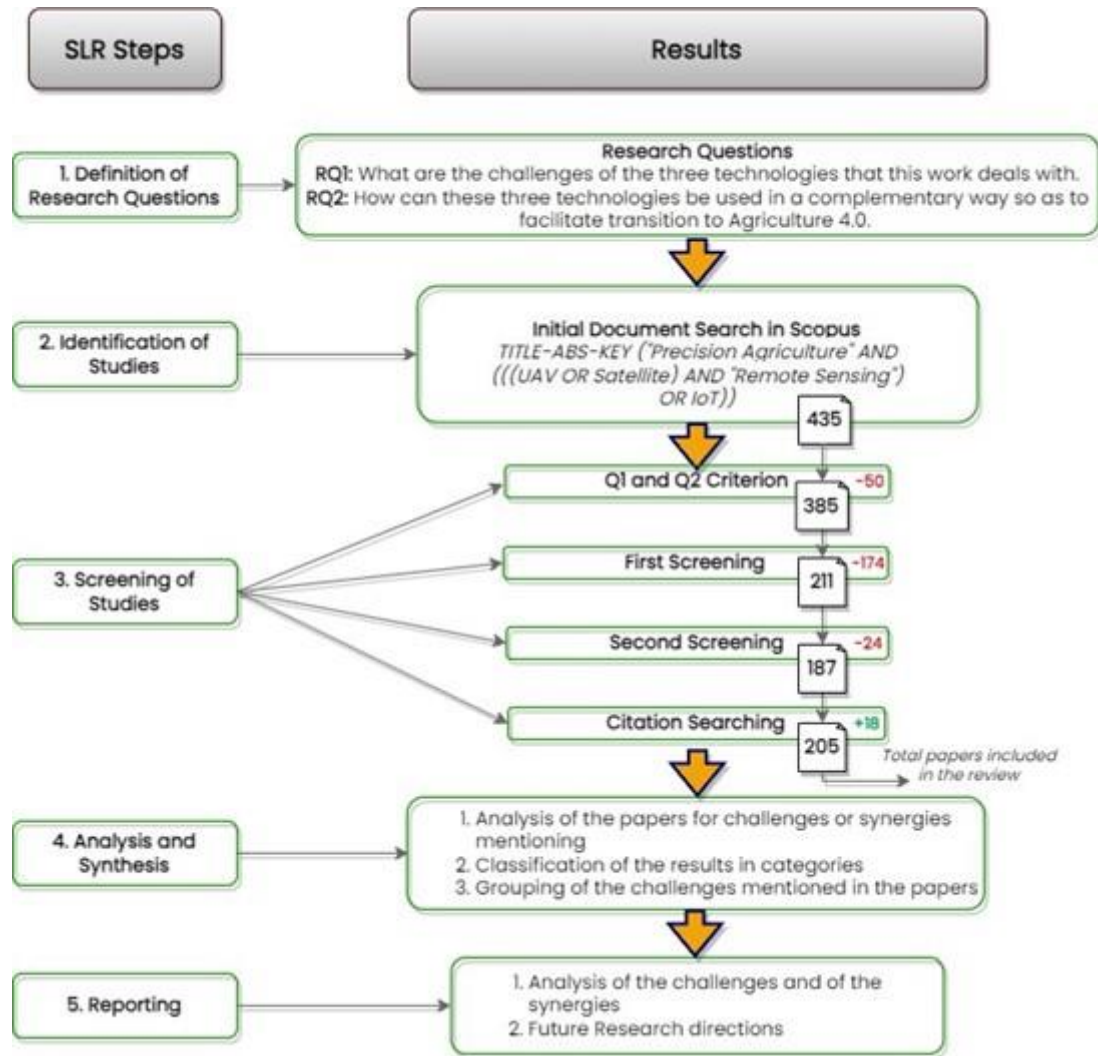


Figure 1. Systematic Literature Review Flowchart.

During the second screening phase, all challenges found by the authors were added to a spreadsheet. Subsequently, these challenges were grouped together. These groups can be found in Tables 1 and 2 for UAVs, Tables 3 and 4 for satellites, and Tables 5 and 6 for IoT. Papers that mentioned synergies were sparse among the body of results. These works are described in their own Section 4.4.

In order to give a sufficient definition of what a challenge is and what a synergy is, we refer to the following. A challenge is any type of impedance or problem that challenges the use of a particular technology in PA. For example, for UAVs, a challenge could be their short flight times, for satellites their lower resolution, and for ground sensors their inflexibility. Synergy is an idea that fuses together traits from two or more technologies to produce an effect that improves the use of both and augments each technology's value overall. The high-resolution images acquired by UAV, combined with the wide coverage and high spectral resolution of satellite images, constitutes a good example

of a synergy. Both challenges and synergies were sought in all examined papers, with the prerequisite that they were sufficiently analyzed in the review text. Therefore, it was much more probable to encounter UAV challenges in a UAV-centric paper than in an IoT-centric or a satellite-centric paper.

Table 1. Unmanned Aerial Vehicle (UAV) Technological Challenges for Applications in Agriculture.

Category	Challenge	References
<i>Sensors</i>		
Geometric and radiometric challenges of current lightweight sensors		[56-63]
	Hyperspectral (HS) imagery	[58,64,65]
	Passive remote sensing challenges	[59,62,66-70].
<i>Security Hardware</i>	Impact of weather effects on picture quality	[43,64,71-78]
	Standardization of remote sensor calibration	[59,72,79,80]
	Data privacy, security and governance	[64,72,81,82]
	Payload limitations	[64,71,76,81,83-85]
	UAV flight time limitations	[59,64,72,76,77,79,81,83,84,86-96]
	Short battery lifespan	[71,81,90,97]
	Impact of weather effects on UAV stability and path planning	[57,59,76,84,86,93,94,98-100]
	Waterproof inability	[87]
	Difficult flight control	[66,71,76,81,87,100-102]
<i>Data processing</i>		
	Computing complexity	[57,64,72,86,96,103-105]
	AI training and machine learning (ML) training	[72,87,89,106-109]
	Large data volumes	[57,81,110,111]
	UAV limited data-processing capabilities	[81,97,100,111]
	Accurate orthomosaics and georeferencing	[57,59,75,101,103,110,112,113]
	Crop disease profiling (general)	[82,84,103,114-117]
	Simplifying User Interfaces	[64,118]
	Interoperability	[81]
	3D point clouds issues	[119]
<i>Future research</i>		
	Autonomous UAVs and coordinated use of multiple UAVs	[71,79,82,97]

Table 2. UAV Peripheral Challenges for Applications in Agriculture.

Category	Challenge	References
<i>Economic</i>		
	High implementation costs	[43,56,57,62,64,71-73,83,86,87,94,118,127-132]
	High maintenance cost	[86]
	Unclear economic benefits	[86]
	Fieldwork expenses	[57]
<i>Social</i>		
	Need of skills and specific way of handling for proper operation and maintenance	[43,58,64,66,71,81,100,132]
	Lack of awareness	[43,81,118]
	Lack of research for this technology	[57,97,133]
<i>Governmental</i>		
	Limitations from governments and authorities	[43,57,59,64,71,72,81-88,92,93,134]
<i>Miscellaneous</i>		
	Demand of an assistant operator to perform a flight	[71]

To reduce bias, the two first authors double-checked the findings of each of the six authors during the second phase of deciding paper eligibility. Any paper that mentioned a well-analysed and evidence-supported phrase that met the challenge or synergy criteria was eligible for synthesis. During the second screening, a further 24 papers were excluded.

After this step, the number of records was reduced to 187. Out of those papers, six of them discussed a synergy of the technologies. Citation searching was performed to identify more records mentioning synergies, which added another 18 records, for a total of 205.

Synthesis of the results required that the phrases extracted from each paper described, in their core, the same basic challenge in order to be grouped with similar phrases from other papers. For example, papers mentioning UAV instability when carrying heavy equipment and UAV reduction in flight time due to heavy payloads were all grouped under the payload-limitation challenge because they describe the wider challenge that UAVs face when there is need to equip them with heavy payloads. As each challenge is further elaborated upon in the main text, the particular details of each phrase are not lost. The grouping helps to provide a summary of the challenge in a form that is quick and easy on the eye and captures how many works have mentioned it in the past.

Table 3. Satellite Technological Challenges for Applications in Agriculture.

Category	Challenge	References
<i>Sensors</i>		
	Lower spatial resolution compared to airborne images	[45,59,64,83,94,101,135-141]
	Passive remote sensing limitations	[64,67,142,143]
	Satellite-based active sensors bypass multiple satellite limitations but offer lower spatial resolution	[57,64]
	Lack of thermal bands	[144]
	High noise-to-signal ratio	[83,145-147]
<i>Security</i>		
	Data privacy	[72,142]
<i>Data processing</i>		
	Large data volumes	[144,148]
	Data processing complexity	[72,94,105]
	Standardization issues	[72]
	AI training and ML training	[72,107,121,149,150]
	Existence of practical prescription maps	[121]
<i>Platform</i>		
	Cloudy weather	[57,67,74,81,83,94,147,149,151-153]
	Low temporal resolution	[45,57,64,67,81,135,141,145,151,154-156]
	Inflexibility to various crop monitoring schedules	[64,83]
	Inflexibility of satellite sensors	[129,157]
	Weak disease-identification capability	[138,158,159]
	Distribution of plants in olive groves or vineyards	[142,159,160]
	Limitations due to the viewing angle	[57]
<i>Future research</i>		
	More research on transforming image classification maps into application maps	[121]
	Orthomosaic accuracy	[161]
	Connectivity	[142,148]
	Different device cooperation	[142,162]
	Need to make satellites more approachable for farmers	[155]

Table 5. Internet of Things (IoT) Technological Challenges for Applications in Agriculture.

Category	Challenge	References
<i>Sensors</i>		
	High energy consumption	[19,91,165–182]
	Uncertainty about the length of sensor life	[183]
	Sensor environmental waste	[167]
	Scalability issues	[35,168,172]
	Harsh environmental conditions	[166,175,181,184–187]
	Need for sensor specialization	[188–190]
	Short lifetime of underground sensors and soil interference	[67,191]
	Sensor field placement	[64,91,167,175,185,192]
	Effective sensing	[91,170,175,183,193–196]
<i>Security</i>		
	Data security and governance	[165,166,168,182,190,192,194,197–202]
	Hacking attacks	[199,200,202,203]
<i>Data processing</i>		
	Data analysis	[19,166,188,189],
	Data storage	[168,182,189,204,205]
	Computing efficiency	[91,206–209]
<i>Networking</i>		
	Sensor networking	[166,168,169,177,204]
	Non standardized data communications	[166,175,177,179,192,209,210]
	Internet coverage	[19,166,175,177,184,185,192,206]
	WiFi and cellular network weaknesses	[167,171]
	Effect of vegetation on signal transmission	[175,185,186]
	Latency and throughput	[19,166,168,184,211]
<i>Future research</i>		
	5G challenges	[167,171]
	Ground robot path planning and execution	[212]
	Overall system automation	[177]
	Public availability of use cases of IoT in agriculture	[213–216]
	Need for more IoT devices that are approachable to farmers	[166,172]
	Power management	[166,190,201,217]
	Real-time monitoring	[162,204]

Table 4. Satellite Peripheral Challenges for Applications in Agriculture.

Category	Challenge	References
<i>Economic</i>		
	High operation costs	[72,94,158,163]
	Cost of image acquisition	[57]
<i>Social</i>		
	Hindered access	[131,142]
	Need for knowledge and a specific way of handling	[163]
<i>Miscellaneous</i>		
	Influences of field heterogeneity	[164]

Table 6. IoT Peripheral Challenges for Applications in Agriculture.

Category	Challenge	References
<i>Economic</i>		
	High implementation costs	[64,145,165,166,179,181,182,187,188,218-223]
	High maintenance costs	[166]
	Unclear economic benefits	[167]
<i>Social</i>		
	Lack of knowledge and expertise	[166,219]
	Lack of awareness	[167,192]
	Lack of research on this technology	[167,224]
	Hindered access	[131,179,220,222,223]
	Hesitance to use IoT	[165]
<i>Governmental</i>		
	Data-ownership issues	[166,167]
	Lack of policies and regulations	[179,218]

4. Results

This section presents the results for the synthesis of the challenges for each technology in three subsections and the results for synergies in the fourth subsection.

4.1. UAV Challenges

This subsection provides the results of the categorization of challenges for UAV technology. Table 2 presents the types of challenges for implementing UAV technology in agriculture that are peripherally related to the use of UAVs. The categories that were observed in this case were economic, social, and governmental challenges, as well as one miscellaneous challenge. Table 1 presents the type of challenges for implementing UAV technology in agriculture that are native to the UAV technology, and hence, occur according to the UAV system itself. The categories that were observed in this case were challenges concerning the sensors, the system security, the data processing, and the system hardware. Moreover, future research challenges for implementing UAV technology in agriculture are also investigated and included. Figure 2 presents these groups of challenges found in the literature that was examined.



Figure 2. UAV Challenges Mentioned in the Literature.

Most commercially available UAVs come out of the box with cheap RGB sensors that lack the precision and spectral range for PA applications (for example, for calculating NVDI) [58]. It is necessary to equip UAVs with MS sensors, increasing the overall cost, and even then, cheaper MS sensors face saturation issues [59], especially since there are no standardized methods for their calibration [72]. The calibration of UAV sensors presents a challenge because camera position on a UAV might be slightly different for each flight [59], and differences in the orientation of the sensor result in different calibrations each time. This is especially true with HS sensors, as the slightest tilt has a negative impact in the sensor calibration [80]. With reference to HS sensors, although they have become more lightweight and cheaper, they are still a relatively expensive investment, and the processing of their output data remains extremely complex. Therefore, UAVs present a less cost-effective option for high spectral resolution when compared to satellites [129]. According to [71], another challenge for UAVs is their dependence on payload. Equipping the UAV with multiple sensors is not recommended, as it reduces flight time and affects its balance mid-flight ([81,86]). Therefore, careful choice must be made about which sensors to use and equip the platform with during each flight, resulting in the need for multiple flights when measurements from multiple sensors are required.

All data generated as an outcome of the UAV trips need to be processed to be useful. Some issues arise during this stage. As sensors become better and spatial resolution increases, the volume of acquired data increases, and UAV use in PA is faced with extreme data bloat [81,110,111]. Moreover, as mentioned earlier, data acquisition is not standardized, adding to the already considerable computing complexity of UAV images [57,86]. On top of that, the UAV itself can do little to share the burden of data processing as its computing capabilities are very limited [81,111]. When these ultra-high resolution data are used for machine learning (ML) training, it can take quite a while to complete [72,106], even though the final results are more trustworthy and useful than

training the ML algorithms with satellite acquired images. Higher resolution is not always a panacea when it is employed for disease classification. The currently developed plant disease classification methods have maximum resolution thresholds, which, when surpassed, result in their algorithm underperforming. Nevertheless, the highest resolutions can be capitalized on in object recognition algorithms that perform disease analysis at the individual plant level [117]. Another issue is that if these data are to be given to some company or organization for processing, issues of data governance arise, as well as security of sensitive data [64,72,82].

Furthermore, as the usage of UAVs in agriculture is still in an early stage [123], more research is needed to identify the costs and benefits of the implementation of this technology. For example, [125] recommended the actualization of more studies concerning the validation of low-cost sensors' results in different conditions. Moreover, according to [71,82], there is a need for the development of fully autonomous UAVs. Ref. [79] also discussed the implementation of multiple coordinated UAVs in an individual field. Finally, the path optimization of UAVs, in order to monitor a whole field with adequate accuracy, is mentioned in [71,75].

UAVs' application challenges exceed the purely technical aspects. Using a UAV for PA requires a large upfront investment from farmers [118,127], and even then, continuous use can be expensive as well [86]. This high initial cost is a considerable risk, as remote sensing is not a standardized procedure for every type of crop and in every environment, and its performance can wildly vary depending on these parameters [86]. The need for skills and a proper way of handling UAVs [58,66,132] are further impeding factors. Knowledge of repair and maintenance is also a requirement [64]. Moreover, most governments require special licences for UAV use, and they limit certain aspects of flying, such as flying height [71,93], and flying over inhabited areas and beyond visual lines [88].

4.2. Satellite Challenges

The present subsection provides the results of the categorization of challenges for satellites. Table 4 presents the type of challenges for using satellites in agriculture, which are not oriented to the technology itself. The categories that were observed in this case were economic and social. Table 3 presents the challenges native to satellite technology. Of this type of challenges, the main categories that were identified were related to sensors, security, data processing, and the platform. In addition, some future research challenges are also mentioned and analyzed. Figure 3 presents these groups of challenges found in the literature that was examined.




Figure 3. Satellite Challenges Mentioned in the Literature.

An important drawback of satellite imagery is its lower spatial resolution compared to airborne images ([101,135]). Satellite images of medium or low spatial resolution are freely available but do not provide adequate data for a handful of different PA uses, such as disease monitoring, soil spectral measurement, wild weed identification, or applications that require individual plant identification through ML [136–138]. Very-high-resolution (VHR) images from satellites are also available but incur a significant cost. Even then, VHR satellites have trouble in applications that require object identification in agricultural environments, as they provide less information than their airborne counterparts. Due to this lower spatial resolution, satellites are not optimal for heterogeneous environments, for example, for the size and distribution of most of the European olive grove systems or vineyards [142,159].

Similarly to UAVs, satellites generate big data images. Their processing is a time-consuming and computationally intensive endeavour [144]. Processing these data under time constraints may affect the quality of the final result [148]. Storing and managing the sheer volumes of imagery is a considerable challenge on its own. Furthermore, satellite data, because of their low spatial and temporal resolution, are not great candidates for AI calibration purposes or training of ML algorithms [149]. As with all big data applications, satellite imagery can also be leaked or be used by third parties for unknown purposes, so care must be taken [72,142].

Another drawback of satellites is their susceptibility to cloudy weather. Depending on cloud coverage, a satellite may not be able to acquire images at all [151]. The consensus in the literature is that cloud coverage reduces satellite temporal resolution [83,149]. Disease monitoring in particular is highly dependent on high temporal resolution; thus, satellite use for this particular application is inappropriate [158]. Satellites as a platform have inherently low temporal resolution, as they cannot be used for imaging at will but rather at their particular revisit time, but if at that moment the cloud coverage is dense, the chance for image acquisition may be lost. While satellites bearing active

sensors are a solution to cloud coverage, their spatial resolution is even lower, and hence they do not solve the disease- monitoring conundrum [57,64]. The low temporal resolution of satellites is a problem not only for disease monitoring but for monitoring in general. Satellites are inflexible platforms without the ability to interchange sensors at will, and waiting for a satellite with a suitable sensor for the required measurement is another cause of low temporal resolution. When the highest spatial resolution is needed from VHR satellites, they may not be there to provide it [64,83], but a very small number of satellites are equipped with both MS and HS sensors [129].

With reference to future research challenges, there is a need to sufficiently integrate and connect satellites with different technologies and devices, as well as enhance their level of cooperation between one another [142]. According to [121], there is also the need to perform more research for satellites on transforming image classification maps into application maps. Additionally, as the complexity of the usage of a satellite platform is a factor that hinders its adoption, the overall technology needs to become more approachable for farmers and be used as a DSS [155].

Concerning the satellite technology's peripheral challenges for applications in agriculture, the cost of acquiring useful information from satellite imagery incorporates the costs of taking the images and processing them. Specialized companies gather the imagery from specific satellites and process them themselves before finally delivering the final product to the customer. Satellite data for PA have been in use for many years, more than UAVs, and the whole process is more streamlined. Still, the cost of the man-hours involved is high, particularly when data processing must be undertaken quickly [57]. All in all, access to everyone is still hindered due to the scientific and technological knowledge required to deploy an effective method that brings true and valuable results to farmers [131].

4.3. IoT Challenges

The present subsection provides the outcomes of the categorization of challenges for IoT technology. Table 6 presents the type of challenges for implementing IoT in agriculture that are not native to the technology itself. The categories that were identified from this case were mainly economic, social, and governmental. Table 5 presents the IoT- technology-oriented challenges. From this group of challenges, the main categories that were observed were related to sensors, security, networking, data processing, and future research challenges. Figure 4 presents these groups of challenges found in the literature that was examined.




Figure 4. IoT Challenges Mentioned in the Literature.

Each sensor in an IoT context comprises four parts: a sensing part, a computing part, a transmitting part, and a battery. The batteries are usually not rechargeable or changeable. Therefore, there is a pressing need for saving energy [166,167,169,170]. Most of its energy is spent in transmitting sensed data back to the main station. Energy saving can be achieved by using operations with a low duty cycle, minimizing delays, or optimizing routing. Another challenge for IoT is the lack of reliable measurements for low-cost ground sensors [175]. For example, the measurement of soil moisture with ground sensors is challenging because the capacitive soil moisture sensors operate at low frequencies and are sensitive to the soil texture and salinity level [193]. The placement of sensors is another important challenge of incorporating IoT. Sensors have to be placed strategically to ensure maximum coverage and well-established communication between them [91,175,192]. The difficulty of this task is proportional to the size of the field. As size increases, the placement of sensors becomes more difficult, and the cost of implementing a critical mass of sensors increases as well. This is known as the scalability problem [168,172]. Harsh environmental conditions is another factor impeding ground sensors [166,184]. Meteorological variables such as snow, fog, and solar radiance have an impact on both the sensor network and the planting [185]. The electrodes of low-cost sensors suffer deterioration quite quickly, and it is important to somehow ensure protection from adverse conditions [175]. Underground sensors constitute a solution to this problem, as meteorological phenomena do not affect them, and they do not impact the above-ground activities of machinery or animals, but at the cost of limited range due to interference by soil elements [191]. Another challenge for IoT is the need for sensor specialization, for each crop or disease in need of monitoring. They should be tailored to the needs of wildly different sectors in agriculture such as fruits, arable crops, or trees [188–190]. Furthermore, all these sensors create electronic waste when they finally expire, and some of them contain harmful chemicals that are toxic to soils, crops, and stored grains [167].

Moving on, the architecture of the network is an important aspect of designing an IoT solution. Integrating data sources and distributed sensors is complicated [204]. IoT system design in PA is based on heterogeneous network topologies that lead to complex communications. IoT devices have to communicate and interact seamlessly through different platforms and infrastructures [168]. This is worsened by non-standardized data-communication protocols [166] and different IoT node synchronization [177], as communication protocols differ from crop to crop [175]. Another important aspect is the network layer itself. WiFi communications are not ideal for agricultural applications, which usually face extreme weather conditions and have insufficient power structure, particularly when devices are spread far over a field, and they work on non-rechargeable battery power [167]. On the other hand, cellular communication suffers in agriculture, as the operational area is far away from antennae of cellular networks, and thus the connectivity of 3G/4G is very low. Moreover, 4G cannot support ultra-low latency with high connectivity because it allows IP-based packet switching connectivity [171]. LoRaWAN has arisen as a replacement for WiFi/cellular networks in agricultural IoT. While it has low bandwidth, it boasts very low energy consumption and high connectivity across vast distances [175]. Its drawbacks are that its radio-based signals are affected by vegetation foliage [175,185,186]. Another defect is its high latency [166], but this is not always a problem in agricultural application, except if a real-time approach is taken to field monitoring.

From the point of view of the data processing challenge, reference is made to data bloat in [189]. Existing cloud-base storage does not provide useful solutions to the problem of manipulating the different data patterns produced by the IoT [168]. The analysis of these data is another challenge. According to [188], it has to be simplified so that it can be easily understood by most farmers. Moreover, computational efficiency needs to increase on the agricultural domain, and it remains a challenge to come up with efficient alternatives to provide sufficient resources to IoT in rural environments [206]. IoT networks that use WiFi—or cellular—for their network infrastructure are more vulnerable to hacking attacks [192,197]. A malicious party can infiltrate the network and cause a wide number of issues to the IoT network. Attacks can target various aspects such as the network itself, its nodes, the data it transmits, and the code by which nodes operate. The purpose of these attacks could be brute attempts to disrupt the network and cease its operation, or more subtle malicious attacks, such as data theft and faulty operation of sensors that lead to miscalculations and false measurements [199,200,203]. Authentication, encryption, and securely generated passwords are required to prevent security compromise [168]. LoRaWAN, as it does not use the Internet and has already authentication and encryption systems built-in, has a higher degree of security.

Furthermore, the data governance of IoT is another issue. Whoever processes the data extracted by the IoT has full access to sensitive information, and care must be taken about whom farmers entrust these data to [200].

Future research on agricultural IoT systems may focus on many different aspects. An important one is power management. Batteries of sensors that are self-rechargeable through solar power or other means would greatly enhance the capabilities of agricultural IoT [166,190,201]. Research on an IoT capability to monitor crops in real time is another important characteristic of sensor networks that is constrained by the limited power resources [204]. Ground robots bearing moving sensors need improvement in guidance systems to achieve smooth navigation through a farming environment [212]. The technology's approachability for farmers is another issue in need of improvement. The ergonomic design of sensors, so that they can be better integrated into the farming environment, and the facilitation of IoT device implementation in a "plug-and-play" manner are desirable improvements. Finally, there are numerous voices claiming that the 5G network could revolutionize the agricultural sector, but concerns have been raised regarding the absolute validity of those claims. To start with, there will be high infrastructure costs, because additional stations are needed due to 5G's shorter range. The end users' device cost would be higher, as would service tariffs [171]. Moreover, there are doubts that 5G is an environmentally friendly technology, as widespread deployment would translate to higher use of computing devices and an increase in energy demand to power the computing devices, which would exacerbate climate change. It is also worth noting that certain reports have raised concerns about 5G's high radiation [167].

When it comes to IoT peripheral challenges, the most commonly mentioned among the papers analysed was the high costs of implementation. According to [64], the measurement of ground-based parameters can be costly and time-consuming, as well as requiring large amounts of human resources. Furthermore, Ref. [166] described the business issue of implementing an IoT-based system with three categories, the setup cost, the running cost, and the upgrading cost. All of these categories can incur high costs for farmers, making the adoption of IoT in agriculture a dilemma. Besides economic challenges, there is also a lack of theoretical and practical knowledge about such systems [166], and there is always a problem with the farmers' lack of awareness for implementing new technologies in their farms [192], or even hesitance of the farmers to use them [165]. Finally, as these technologies are still at the infant stage of development, there is also a lack of policies and regulations [218], as well as ownership and processing issues related to the generated data [166].

4.4. Synergies Mentioned in the Literature

Works that present substantial synergies between technologies are sparse. This sub-section summarises the review findings. While data fusion between different sensors for agriculture has been explored in previous works [225,226], the particularities of fusing or combining sensory output originating from two or more sources as diverse as IoT, UAV, and satellites has not been touched upon adequately for agricultural purposes. Alvarez- Vanhard et al., 2021 [225] gives a thorough review of the literature from 2021 and before, which mentions the synergical use of satellites and UAVs for agriculture, but it does not mention combinations of IoT and any of the two aforementioned technologies. The current work attempts to take the reasoning of [225] one step further by focusing on the particularities of each paper reviewed and dissecting the exact reasons that make the use of a synergy desirable. These reasons can be traced back to the challenges mentioned in Sections 4.1–4.3, as the complementary use of two or more technologies attempts to mitigate the limitations and challenges each technology faces on its own. Tables 7 and 8 present the logic permeating each type of synergy encountered during the literature review by contrasting its complementary technological traits. Tables 9–11, describe the use cases of synergies performed in relevant works and characterize them according to the particular synergy types as defined in Tables 7 and 8.

Among UAV-Satellite papers, Type 3 and Type 5 synergies are the most common. Interestingly, only two papers have utilized the flexibility of the UAV, and only two papers have utilized its enhanced capacity to create 3D point clouds, while no work combining UAV and satellite requires the historical records of past satellite overpasses.

Among IoT-UAV/Satellite works, Type 8 was the most common, utilizing the proximity of IoT measurements to clear up uncertainties in UAV/satellite remote sensing. Type 10 and Type 12 are the next most commonly mentioned synergies. Most Type 10 synergies utilise meteorological data in ML models to complement remote sensing predictions, while Type 12's use of historical satellite data was quite common in contrast with UAV–Satellite papers. Type 9 and Type 11 are only encountered once, since real-time ground sensor monitoring is still in its infancy as a practice, and attempts to perform orthorectification through ground measurements are also scarce. Synergy Type 7 constitutes an exception, as it is commonly encountered across a very large number of scientific papers, which were not reviewed, as they were considered outside the scope of the current work.

Table 7. UAV and Satellite Synergy Types.

UAV Traits	Satellite Traits	Synergy Types
Can be deployed at will	Standard times	Synergy Type 1: UAV is deployed to circumvent satellites' inability to capture images at will
Each image-gathering excursion is expensive and time-consuming	Keeps a historical record of images	Synergy Type 2: Satellite temporal records help in monitoring diseases, yield etc. across time
UAV higher spatial resolution but low spectral resolution	MS Satellite imagery has low spatial resolution, high spectral resolution	Synergy Type 3: Data fusion gives higher spatial resolution and higher spectral resolution than each technology on its own
Narrow coverage	Wide coverage	Synergy Type 4: Satellites can ease the process of the mosaicking of images acquired by UAVs, as well as the process of georeferencing
High capacity for object recognition	Low object-recognition capacity	Synergy Type 5: UAV data calibrate models that satellites can then use repeatedly
Better capacity for 3D representation	Worse capacity for 3D representation	Synergy Type 6: UAV 3D representation capabilities complementing satellite images

Table 8. UAV/Satellite and IoT Synergy Types.

UAV/Satellite Traits	IoT Traits	Synergy Types
UAVs have high mobility	Low connectivity and energy shortage	Synergy Type 7: UAV as a mobile sink for sensor data
UAV/Satellite imagery limited to particular angles of acquisition (top-down), lower resolution than proximal sensors	Proximal imaging has higher resolution, more varied angles	Synergy Type 8: Remote and proximal data fusion eases phenotyping, canopy characterization, and digital terrain modeling
Wide coverage	Ground remote sensing coverage problems	Synergy Type 9: UAV/Satellite data fusion with ground pictures eases orthorectification
Can only employ remote sensors	A wide variety of sensors can be employed (meteorological, soil measurement sensors, etc.)	Synergy Type 10: Meteorological measurements, as well as soil measurements, can help build models that enrich and add to the value of the information provided by remote sensors
UAVs take only snapshots of a field	Capacity of constant field monitoring	Synergy Type 11: IoT sensors help models also extend their predictions in the temporal scale
Satellites keep a historical record of data	Not all ground sensors have the capacity of constant monitoring	Synergy Type 12: Satellite data archive can complement missing sensors or missing past information

Table 9. Synergies Part 1.

References	Technologies	Synergy Type	Synergy Description
Siok et al., 2020 [129]	UAV, Satellite	Type 3	This work proposes a fusion, based on pan-sharpening, of UAV RGB imagery with satellite MS imagery to achieve a result that combines the high spatial resolution of the UAV, with the high spectral resolution of the satellite.
Pereira et al., 2022 [60]	UAV, Satellite	Type 3	This study fused together data from a UAV RGB camera (simulated based on an MS camera), Planetscope, and Sentinel-2 for the prediction of nitrogen variability in pasture fields. The UAV data train the model with the R, G, and B bands while the other bands are provided by the satellites. The result shows that the predictions are more accurate when UAV RGB data are combined with satellite MS data, than when each dataset, either UAV or satellite, is used on its own.
Mazzia et al., 2020 [136]	UAV, Satellite	Type 5	The work suggests using high-resolution MS UAV data to train a deep neural network and then use it in tandem with moderate- or low-resolution satellite data to deal with heterogeneous crop environments such as olive orchards and vineyards. The neural network needs only one flight mission in order to classify the particularities of the field under examination, and after that, it refines all subsequent satellite images.
Riihimaki et al., 2019 [227]	UAV, Satellite	Type 5	This paper studies how UAVs can be used to bridge the gap between the integration of field and satellite data. The work first creates a binary vegetation classification using UAV and second uses the classification to calculate fractional cover from grids of different satellites.
Melville et al., 2019 [228]	UAV, Satellite	Type 3, Type 5	The authors of this paper apply three methods to data retrieved from satellite and UAV in a typical Australian range land environment. The first one uses downscaling between Landsat satellite maps and UAV images with a Random Forest regression model in order to predict different field parameters. The second used spectral unmixing based on endmembers identified in the multispectral imagery, while the third one used an object-based classification approach to label image segments.
Nhamo et al., 2018 [229]	UAV, Satellite	Type 3, Type 1	This paper combines and analyzes imageries from Landsat 8 satellite and imageries acquired from UAVs to give a clear picture of mapped irrigated fields.
Selvaraj et al., 2020 [230]	UAV, Satellite	Type 5	This work uses Random Forest and Support Vector Machine algorithms to train a model for the object recognition of banana trees and two types of diseases affecting them. The model is calibrated using high-resolution UAV and satellite data and is applied to both UAV and high-resolution satellite data with good results. Medium-resolution open-source satellite data (PlanetScope and Sentinel-2), on the other hand, is not adequate for the model to succeed in object recognition of banana canopies.

While synergical use can mitigate certain liabilities and provide solutions, there are some challenges that are shared by two of the technologies examined or even by all three. Therefore, such challenges continue to exist when a synergy is attempted. Data privacy is a prominent concern for all three technologies, which cannot be mitigated by combining them. Another shared challenge is the large data volumes, which become more cumbersome when we have data fused from different sources. This is coupled with the increase in processing time and costs. In fact, the fusion of data of different types (sensor data and images of different resolutions) creates further challenges to the goal of having them efficiently integrated. A further challenge of the complementary use of the aforementioned technologies is that farmers need to become acquainted with not just one but all the technologies that are being combined. Moreover, it should be mentioned that the lack of current research regarding actual synergies between the three technologies is both an important impeding factor towards a holistic paradigm involving all three and a challenge for future research and pilot projects. In fact, in our literature review, out of the 205 reviewed works, only 24 papers provided synergy use cases. Finally, the lack of standardization poses further challenges with reference to their complementary use. In fact, all use cases found by the authors miss any particular standardization procedure, which could be beneficial for the future of synergical use between technologies.

Table 9. Synergies Part 1.

References	Technologies	Synergy Type	Synergy Description
Siok et al., 2020 [129]	UAV, Satellite	Type 3	This work proposes a fusion, based on pan-sharpening, of UAV RGB imagery with satellite MS imagery to achieve a result that combines the high spatial resolution of the UAV, with the high spectral resolution of the satellite.
Pereira et al., 2022 [60]	UAV, Satellite	Type 3	This study fused together data from a UAV RGB camera (simulated based on an MS camera), Planetscope, and Sentinel-2 for the prediction of nitrogen variability in pasture fields. The UAV data train the model with the R, G, and B bands while the other bands are provided by the satellites. The result shows that the predictions are more accurate when UAV RGB data are combined with satellite MS data, than when each dataset, either UAV or satellite, is used on its own.
Mazzia et al., 2020 [136]	UAV, Satellite	Type 5	The work suggests using high-resolution MS UAV data to train a deep neural network and then use it in tandem with moderate- or low-resolution satellite data to deal with heterogeneous crop environments such as olive orchards and vineyards. The neural network needs only one flight mission in order to classify the particularities of the field under examination, and after that, it refines all subsequent satellite images.
Riihimaki et al., 2019 [227]	UAV, Satellite	Type 5	This paper studies how UAVs can be used to bridge the gap between the integration of field and satellite data. The work first creates a binary vegetation classification using UAV and second uses the classification to calculate fractional cover from grids of different satellites.
Melville et al., 2019 [228]	UAV, Satellite	Type 3, Type 5	The authors of this paper apply three methods to data retrieved from satellite and UAV in a typical Australian range land environment. The first one uses downscaling between Landsat satellite maps and UAV images with a Random Forest regression model in order to predict different field parameters. The second used spectral unmixing based on endmembers identified in the multispectral imagery, while the third one used an object-based classification approach to label image segments.
Nhamo et al., 2018 [229]	UAV, Satellite	Type 3, Type 1	This paper combines and analyzes imageries from Landsat 8 satellite and imageries acquired from UAVs to give a clear picture of mapped irrigated fields.
Selvaraj et al., 2020 [230]	UAV, Satellite	Type 5	This work uses Random Forest and Support Vector Machine algorithms to train a model for the object recognition of banana trees and two types of diseases affecting them. The model is calibrated using high-resolution UAV and satellite data and is applied to both UAV and high-resolution satellite data with good results. Medium-resolution open-source satellite data (PlanetScope and Sentinel-2), on the other hand, is not adequate for the model to succeed in object recognition of banana canopies.

Table 10. Synergies Part 2.

References	Technologies	Synergy Type	Synergy Description
Zhou, X. et al., 2021 [231]	UAV, Satellite	Type 6, Type 1	This paper utilizes vine canopy structure information (canopy height, vegetation fraction cover) gathered from UAVs and temporal spectral information gathered from Sentinel-2 to train the following ML models: partial least squares regression, support vector regression, random forest regression, and extreme learning regression, for the prediction of disease severity and disease incidence. The results show that UAV and satellite data combined as training inputs have the best results, especially when coupled with the support vector regression algorithm.
Mokhtari, A. et al., 2021 [232]	UAV, Satellite	Type 3	This work describes a method to estimate ETA through the fusion of MS UAV data and Landsat-8 data by using the TsHARP algorithm, nullifying the need for a thermal sensor onboard the UAV or on the field.
Maimaitijiang, M. et al., 2020 [233]	UAV, Satellite	Type 6	This work uses MS data from VHR satellite WorldView-2 and combines them with canopy structure data derived from a cheap RGB camera mounted on a cheap UAV. Four different ML models are used to make estimations on Leaf Area Index (LAI), Aboveground Biomass (AGB), and Leaf Nitrogen Concentration (N). All ML models were trained with multispectral satellite data and structural UAV data. Then, each technology's data were applied independently of the other, and then they were applied together. The results showed that LAI, AGB, and N estimates were worse when each technology dataset was applied independently, and they were better when the datasets were applied together.
Zhao, Y. et al., 2020 [234]	IoT, Remote Sensing	Type 10	Training of a feed-forward neural network with image data gathered from cameras and meteorological data gathered from ground sources, for better disease identification. The image data pass through a convolutional neural network, while the meteorological data pass through a normal feed-forward neural network, and the results of those networks are combined as inputs to a final feedforward neural network. The whole arrangement of neural networks is termed Multi-Context Fusion Network (MCFN).
Popescu et al., 2020 [96]	IoT, UAV	Type 7	A UAV is used as a receiver and carrier of data from IoT sensors on the field to a central processing station. The authors improved the algorithms that permeate the UAV-WSN-IoT setup and performed a real experiment on a field to prove their findings.
Lin et al., 2021 [235]	IoT, UAV	Type 9	This work utilized point cloud data gathered by a UAV LiDAR sensor to ease the orthophoto generation process of images gathered by an RGB camera mounted on a ground vehicle.
Cucchiario et al., 2020 [236]	IoT, UAV	Type 8	This work fused data collected with terrestrial laser-scanning (TLS) and structure-from-motion (SfM) data collected aurally to create a digital terrain model of an agricultural terrace field with multiple steep slopes covered by vegetation. The fusion was needed in order to cover areas that each technology on its own could not.
Liu et al., 2019 [237]	UAV, Satellite, IoT	Type 2, Type 3, Type 8, Type 10	The authors of this paper present a developed optimized method in order to map high-resolution forage production using multispectral remote sensing imagery. For this purpose, flights of UAVs were conducted, as were 3 m Planet Scope satellite observations.

Table 11. Synergies Part 3.

References	Technologies	Synergy Type	Synergy Description
Lu et al., 2022 [238]	IoT, UAV	Type 8	This study combined UAV-based MS, thermal imagery, and ground-based thermal imagery to provide a comprehensive assessment of shadow pixels for ETO estimation. The authors determined if the shadow pixels contained either soil or vegetation, by differentiating them based on their temperature, which was measured using ground thermal sensors. Then, by applying MS correction to the shaded vegetation pixels and incorporating them into the 3T model, they managed to improve their ETO estimates.
Üstundag, B. et al., 2021 [239]	IoT, Remote Sensing	Type 10, Type 12	The authors estimated yield efficiency mapping depending on agrometeorological indices and remote sensing data as one of the data fusion examples, as well as how time delay neural networks can be used to estimate the root zone's soil moisture.
Pantazi, X. et al., 2016 [240]	IoT, Satellite	Type 8	This work used models (Cp-ANN, XY-F. SKN) based on three self-organized maps (SOMs) to associate high-resolution data on soil with isofrequency classes of wheat-yield productivity. The goal was to predict the field variation in wheat yield, based on an on-line multi-layer soil data and satellite imagery. The best result was obtained with SKN.
Hu, S. et al., 2021 [92]	IoT, Satellite	Type 10, Type 12	This work used meteorological, agricultural, and remote sensing data to calculate the intrinsic quantum efficiency of spring maize according to the Vegetation Interface Processes (VIP) model. The goal was to finally make accurate predictions of yield in order to better manage the amount of water resources used for irrigation. Meteorological data are correlated with yield data and NVDI of past years to make the predictions.
Moeckel, T. et al., 2017 [241]	IoT, Satellite	Type 8	The objective of this work was to discriminate crop types using ground-based hyperspectral data, airborne multi-spectral imagery, and fused data from the ground-based and airborne spectral measurements.
Nidamanuri et al., 2022 [137]	IoT, Satellite	Type 8	This work described a method of fusing MS satellite imagery at the feature level with LiDAR sensors mounted on the ground to better achieve object recognition in remote sensing imagery. Three-dimensional clouds, when fused with MS data at the feature level, can provide more information on the physiology of the crops, thus helping in recognizing canopies of plants, as well as plantation rows.
De Bernardis, C. et al., 2016 [242]	IoT, Satellite	Type 8, Type 11	This work analyzed the use of a particle filter (PE) as a dynamical framework to incorporate different information sources (satellites and IoT), in order to improve the estimation of the phenological state of the crops.
Guerrero, A et al., 2021 [243]	IoT, Remote Sensing	Type 12	This particular work considered which strategy of Variable rate N fertilization is more sound by examining a use case of two fields, one with barley and another with wheat. By fusing ground measurements using a vis-NIR sensor, with satellite NDVI measurements, and historical yield measurements, they rasterized the fields into management zones with different fertility classes. Then, they considered if they should apply more N to less fertile areas, apply more N to more fertile areas, or just apply N uniformly. Their results show that the first strategy is the strongest.

5. Discussion

The value of satellite imagery in PA greatly depends on the application it is required for, as well as the particularities of the crops and the field. Even VHR satellites such as World View-3 are not suitable for individual plant analysis. While they provide a 30 cm per pixel spatial resolution on RGB imagery, on MS imagery, their spatial resolution is about 1.24 m per pixel. Thus, while their RGB imagery resolution is good enough for distinguishing canopies, the same satellite MS spatial resolution is not enough to provide adequate data for further analysis of these canopies. Evidently, satellite use is limited in heterogeneous farms, meaning farms that provide imagery that combines

many different textures, such as soil, plants, wild weeds, or farming structures. In contrast, satellites are more useful for crops that cover an area homogeneously, such as cereal crops. But even in these types of plantations, applications such as wild-weed identification and soil spectral analysis benefit the most from the highest possible spatial resolution. Therefore, UAVs have an edge in applications of this type or heterogeneous farms. Very-high-definition images from UAVs, on the other hand, may introduce data redundancy, which lowers the performance of the algorithms used to process the images [117]. Upscaling may be necessary to a resolution scale, which ensures optimal performance of the algorithm used, which is another impediment to the UAV standardization of procedures regarding PA. It is therefore necessary to know the optimal resolution scale for each use case, as different combinations of algorithms and crops require different optimal resolutions. An added benefit is that lower resolution requirements allow the UAVs to fly to a higher altitude, thus also reducing battery expenditure and the time needed for the image-gathering excursion [116].

It is less probable to obtain usable imagery during rainy weather with a satellite than it is with a UAV system [57,74], as cloud coverage greatly affects satellite image quality. It might even render satellite images unusable if the coverage is too dense. Diseases can evolve rapidly, requiring precise and strict monitoring to ensure results, and skipping a measurement because of cloud coverage might throw off the project completely. On the opposite end, UAVs, being able to fly at will and being unaffected by cloud coverage, have a much higher capability for frequent imaging. A satellite's lower resolution does come with certain benefits. Wide coverage is a satellite's inherent advantage, and, as there is no piloting involved, the homogeneity of data is guaranteed. In contrast, UAVs have to be piloted carefully, they have to be stable enough to follow their required trajectory, and they have to maintain the same height over crops. Covering the same area as a satellite requires more images, more time, an expert pilot, and more processing of the images to create the final mosaics. It is therefore evident that UAVs are optimal for small to medium farms, where they are not required to cover vast areas for image acquisition. Large farms are better served by satellite imagery, supposing that they are not very heterogeneous.

UAVs, being highly modular platforms that come in all shapes and sizes while also being able to carry many different sensors, have abundant flexibility but at the cost of standardization. Sensor calibration is a process that is dependent on the equipment; therefore, each combination of UAV model and sensor requires its own calibration procedure. In contrast, satellites do not face such issues, as their calibration is a standardized procedure that has been taken care of by the platform operators. Therefore, the risk of obtaining unusable data due to calibration faults is higher in UAVs. Moreover, due to this lack of standardization, UAV images have a slightly higher processing

complexity than satellite imagery. Still, by having a much higher temporal resolution and by being devices that can become part of a wider IoT network, UAVs can provide their data faster for processing and can even utilize edge computing if there is available on-field infrastructure.

Nevertheless, UAVs require a large upfront investment, that includes the cost of buying the vehicle, as well as the cost of buying its sensory equipment. Following this considerable investment, the cost of using and maintaining the platform includes recharging costs, the cost of man hours for processing the images, the cost of man hours for piloting the platform, and any costs for repairs and spare parts. Satellites, on the other hand, do not require the large upfront investment, but high spatial resolution satellite images can only be acquired by paying a hefty price. A further cost is added due to the man hours and skills required to process the satellite data. Adding to the challenge of buying and setting up a UAV platform for remote sensing are the bureaucratic difficulties of acquiring a licence to fly it. In contrast, satellite data require almost no bureaucratic hurdle for their acquisition.

The third PA technology analysed in this review is IoT. This may incorporate any type of sensor, from soil sensors that measure soil parameters, such as moisture, temperature, and the concentration of elements such as carbon and nitrogen, to sensors that measure water levels in crops for irrigation purposes, to MS sensors that measure vegetation indices. An IoT device can have any combination of sensors and can be adapted to the particularities of the farm under examination. IoT tends to be more expensive than UAVs or satellite data, but provides the most noise-free data out of the three technologies. Moreover, their capacity to capitalize on edge-computing puts them at the forefront of scientific research, as this allows real-time monitoring, which is an important future prospect for PA. Out of the three technologies analyzed, IoT is the only technology that has the capacity for continuous monitoring. Measurements from ground sensors are used as training and evaluation sets for ML algorithms for application in remote sensing, because their data are the most trustworthy source of measurement regarding soil moisture, concentrations of various elements in the soil, water plant status, and similar quantities that can be measured through physical contact or proximal sensing. The calculation of vegetation indices through ground remote sensors, on the other hand, is a more challenging endeavor. Ground remote sensing requires many sensors to be placed strategically across the field for maximum coverage, and even then, only homogeneous crop types can be measured safely. Image recognition of canopies or rows of vines in heterogeneous environments is very difficult or even impossible to achieve when using ground remote sensors because of the angle the images are taken from.

IoT systems are susceptible to attacks by malicious third parties, as they always require a network infrastructure to operate. On the other hand, UAVs usually operate without becoming a part of a network. Thus, they are less susceptible to hacking. Satellites, as they are not operated by the farmer, cannot become victims of hacking attacks. Nevertheless, satellite data from a farmer's field can still be used for nefarious purposes, similar to data extracted from IoT and UAVs.

Satellites and UAVs are reusable assets, in contrast to cheap ground sensors. The environmental waste from an IoT system can be an important cause for concern. In particular, as the dimensions of the under-measurement field become larger, so does the number of sensors required to cover it. It can be safely assumed that, cost-wise and environmentally, IoT for large fields is not an optimal choice.

Complementary use relies on capitalizing on the strengths of one technology while complementing its weaknesses with another technology. UAVs can be used to enhance the spatial resolution of satellite MS data on certain parts of a field in order to examine that part more carefully. UAVs are also sources of excellent training data for ML algorithms that will then be applied to satellite imagery. Similarly, IoT systems are great producers of training data, especially for the purposes of irrigation and the measurement of soil parameters. LiDAR and thermal sensors on the ground can be used to enhance remotely sensed imagery. UAVs and IoT can therefore provide precision when satellite information is not precise enough for the needed application.

IoT and UAVs can act in synergy in a multitude of ways. The UAV can provide its remotely sensed data to complement data gathered by the ground nodes. A UAV can itself become another node in an IoT system so that its information can be processed in tandem with the information of the other nodes. UAVs can even help mitigate power expenditure in an IoT system, which is an important limitation, by serving as a carrier of data from sensors to the main station.

6. Conclusions

This systematic review summarized the limitations of ground-based, space-borne, and airborne technologies for PA, as they are presented in recent literature. It also pinpointed and summarized works that provide useful synergies between these technologies. These studies, when paralleled with the limitations of each technology, enable certain conclusions to be drawn, which can be summed up in the following points:

- Satellite is the broadest of the three technologies, providing ample farm coverage and good image detail. Cost-wise, it is the least risky source of PA data out of the three technologies, but it is also the slowest to provide usable results.

- UAVs have great flexibility and the capability to provide very specific information, but they are costly when applied to large farms, while also requiring a risky upfront investment from farmers. Their ability to analyze crops in very fine detail allows them to deal with specialized problems such as diseases or wild weeds. Still, using them is far from a standardized procedure, and more research is needed to establish the UAVs as a definitive solution.
- IoT provides the most specific information, as it can be tailored to the particular crop and farm. Moreover, it takes the smallest amount of time for data processing and has the unique potential of constant field monitoring. Its high specialization comes at the cost of reduced flexibility and area coverage.
- The review process included reviewing 24 use cases of synergies in the domain of agriculture between the technologies in question. Open challenges setting the ground for future research include data privacy issues, large data volumes, data fusion, farmers' acquaintance with the technology, and lack of standardization. Taking steps toward addressing such challenges could facilitate further synergies and help the agricultural domain advance toward the Agriculture 4.0 paradigm.

As things stand, complementary use of the three technologies requires further research. The number of works that make an effort to combine them is far too small when compared with the number of works that have come out in PA recently. The future of agriculture relies on optimally using all the technological tools currently at our disposal.

Author Contributions: A.K., S.P., A.C., S.B.A., K.K. and A.A. contributed in the conception of the study; A.K., A.A. and K.K. contributed in the design of the study and the choice of the search query; All authors read an equal subdivision of the results of the query; A.A. and K.K. wrote the first draft of the manuscript. A.K., S.P., A.C., S.B.A. and R.O. wrote parts of the manuscript. All authors have read and agreed to the published version of the manuscript.

Funding: The present review paper has been developed as part of the SUSTAINABLE project, funded by the European Union's Horizon 2020 research and innovation program under the Marie Skłodowska-Curie-RISE Grant Agreement No. 101007702, accessed on 25 May 2021 <https://www.projectsustainable.eu>.

Data Availability Statement: Data sharing not applicable No new data were created or analyzed in this study. Data sharing is not applicable to this article.

Conflicts of Interest: The authors declare no conflict of interest.

Abbreviations

The following abbreviations are used in this manuscript:

UAV Unmanned Aerial Vehicle

IoT Internet of Things

WSN	Wireless Sensor Network
PA	Precision Agriculture
IIoT	Industrial Internet of Things
ETO	Evapotranspiration
UN	United Nations
FAO	Food and Agriculture Organization
LVDT	Linear Variable Differential Transformer
LiDAR	Light Detection and Ranging
DSS	Decision Support System
LoRAWAN	Long Range Wide Area Network
NB-IoT	Narrow Band IoT
RGB	Red-Green-Blue
NIR	Near Infrared
IR	Infrared
MS	Multispectral
HS	Hyperspectral
LAI	Leaf Area Index
NDVI	Normalized Difference Vegetation Index
ML	Machine Learning
VHR	Very High Resolution
SfM	Structure from Motion
PRISMA	Preferred Reporting Items for Systematic Reviews and Meta-Analyses

References

1. De Clercq, M.; Vats, A.; Biel, A. Agriculture 4.0: The future of farming technology. In Proceedings of the World Government Summit, Dubai, United Arab Emirates, 17 January 2018; pp. 11–13.
2. Leakey, R.R. Addressing the causes of land degradation, food/nutritional insecurity and poverty: A new approach to agricultural intensification in the tropics and sub-tropics. In *Trade and Environment Review 2013: Wake Up Before it is too Late: Make Agriculture Truly Sustainable Now for Food Security in a Changing Climate*; UN Publication: Geneva, Switzerland, 2013.
3. Ray, D.K.; West, P.C.; Clark, M.; Gerber, J.S.; Prishchepov, A.V.; Chatterjee, S. Climate change has likely already affected global food production. *PLoS ONE* **2019**, *14*, e0217148. [[CrossRef](#)] [[PubMed](#)]
4. Caldeira, C.; De Laurentiis, V.; Corrado, S.; van Holsteijn, F.; Sala, S. Quantification of food waste per product group along the food supply chain in the European Union: A mass flow analysis. *Resour. Conserv. Recycl.* **2019**, *149*, 479–488. [[CrossRef](#)]
5. Rose, D.C.; Chilvers, J. Agriculture 4.0: Broadening responsible innovation in an era of smart farming. *Front. Sustain. Food Syst.* **2018**, *2*, 87. [[CrossRef](#)]
6. Liu, Y.; Ma, X.; Shu, L.; Hancke, G.P.; Abu-Mahfouz, A.M. From Industry 4.0 to Agriculture 4.0: Current status, enabling technologies, and research challenges. *IEEE Trans. Ind. Inform.* **2020**, *17*, 4322–4334. [[CrossRef](#)]
7. Mylonas, G.; Kalogeras, A.; Kalogeras, G.; Anagnostopoulos, C.; Alexakos, C.; Muñoz, L. Digital twins from smart manufacturing to smart cities: A survey. *IEEE Access* **2021**, *9*, 143222–143249. [[CrossRef](#)]
8. Kalogeras, A.P.; Rivano, H.; Ferrarini, L.; Alexakos, C.; Iova, O.; Rastegarpour, S.; Mbacké, A.A. Cyber physical systems and Internet of Things: Emerging paradigms on smart cities. In Proceedings of the 2019 First International Conference on Societal Automation (SA), Krakow, Poland, 4–6 September 2019; pp. 1–13.
9. Koulamas, C.; Kalogeras, A. Cyber-physical systems and digital twins in the industrial internet of things [cyber-physical systems]. *Computer* **2018**, *51*, 95–98. [[CrossRef](#)]
10. Kalogeras, G.; Anagnostopoulos, C.; Alexakos, C.; Kalogeras, A.; Mylonas, G. Cyber Physical Systems for Smarter Society: A use case in the manufacturing sector. In Proceedings of the 2021 IEEE International Conference on Smart Internet of Things (SmartIoT), Jeju, Republic of Korea, 13–15 August 2021; pp. 371–376.
11. Fountas, S.; Aggelopoulou, K.; Gemtos, T.A. Precision agriculture: Crop management for improved productivity and reduced environmental impact or improved sustainability. In *Supply Chain Management for Sustainable Food Networks*; John Wiley & Sons: Hoboken, NJ, USA, 2015; pp. 41–65.
12. Roma, E.; Catania, P. Precision Oliviculture: Research Topics, Challenges, and Opportunities—A Review. *Remote*

- Sens.* **2022**, *14*, 1668. [[CrossRef](#)]
13. Alexakos, C.; Kalogeras, A.P. Internet of Things integration to a multi agent system based manufacturing environment. In Proceedings of the 2015 IEEE 20th Conference on Emerging Technologies & Factory Automation (ETFAs), Luxembourg, 8–11 September 2015; pp. 1–8.
 14. Alexakos, C.; Anagnostopoulos, C.; Kalogeras, A.P. Integrating IoT to manufacturing processes utilizing semantics. In Proceedings of the 2016 IEEE 14th International Conference on Industrial Informatics (INDIN), Poitiers, France, 19–21 July 2016; pp. 154–159.
 15. Lalos, A.S.; Kalogeras, A.P.; Koulamas, C.; Tselios, C.; Alexakos, C.; Serpanos, D. Secure and safe iiot systems via machine and deep learning approaches. In *Security and Quality in Cyber-Physical Systems Engineering*; Springer: Cham, Switzerland, 2019; pp. 443–470.
 16. Kandris, D.; Nakas, C.; Vomvas, D.; Koulouras, G. Applications of wireless sensor networks: An up-to-date survey. *Appl. Syst. Innov.* **2020**, *3*, 14. [[CrossRef](#)]
 17. Rossel, R.V.; Behrens, T. Using data mining to model and interpret soil diffuse reflectance spectra. *Geoderma* **2010**, *158*, 46–54. [[CrossRef](#)]
 18. Pallottino, F.; Antonucci, F.; Costa, C.; Bisaglia, C.; Figorilli, S.; Menesatti, P. Optoelectronic proximal sensing vehicle-mounted technologies in precision agriculture: A review. *Comput. Electron. Agric.* **2019**, *162*, 859–873. [[CrossRef](#)]
 19. Shafi, U.; Mumtaz, R.; García-Nieto, J.; Hassan, S.A.; Zaidi, S.A.R.; Iqbal, N. Precision agriculture techniques and practices: From considerations to applications. *Sensors* **2019**, *19*, 3796. [[CrossRef](#)]
 20. Babaeian, E.; Sadeghi, M.; Jones, S.B.; Montzka, C.; Vereecken, H.; Tuller, M. Ground, proximal, and satellite remote sensing of soil moisture. *Rev. Geophys.* **2019**, *57*, 530–616. [[CrossRef](#)]
 21. Adams, R.M.; Hurd, B.H.; Lenhart, S.; Leary, N. Effects of global climate change on agriculture: An interpretative review. *Clim. Res.* **1998**, *11*, 19–30. [[CrossRef](#)]
 22. Decoteau, D. *Plant Physiology: Environmental Factors and Photosynthesis*; Department of Horticulture, Pennsylvania State University: State College, PA, USA, 1998.
 23. Allen, R.G.; Pereira, L.S.; Raes, D.; Smith, M. *Crop Evapotranspiration-Guidelines for Computing Crop Water Requirements-FAO Irrigation and Drainage Paper 56*; FAO: Rome, Italy, 1998; Volume 300, p. D05109.
 24. Strand, J.F. Some agrometeorological aspects of pest and disease management for the 21st century. *Agric. For. Meteorol.* **2000**, *103*, 73–82. [[CrossRef](#)]
 25. Scalisi, A.; Bresilla, K.; Simões Grilo, F. Continuous determination of fruit tree water-status by plant-based sensors. *Italus Hortus*, **2017**, *24*, 39–50. [[CrossRef](#)]
 26. Morandi, B.; Manfrini, L.; Zibordi, M.; Noferini, M.; Fiori, G.; Grappadelli, L.C. A low-cost device for accurate and continuous measurements of fruit diameter. *HortScience* **2007**, *42*, 1380–1382. [[CrossRef](#)]
 27. Carella, A.; Gianguzzi, G.; Scalisi, A.; Farina, V.; Inglese, P.; Bianco, R.L. Fruit Growth Stage Transitions in Two Mango Cultivars Grown in a Mediterranean Environment. *Plants* **2021**, *10*, 1332. [[CrossRef](#)] [[PubMed](#)]
 28. Hornero, G.; Gaitán-Pitre, J.E.; Serrano-Finetti, E.; Casas, O.; Pallas-Areny, R. A novel low-cost smart leaf wetness sensor. *Comput. Electron. Agric.* **2017**, *143*, 286–292. [[CrossRef](#)]
 29. Karpyshev, P.; Ilin, V.; Kalinov, I.; Petrovsky, A.; Tsetserukou, D. Autonomous mobile robot for apple plant disease detection based on cnn and multi-spectral vision system. In Proceedings of the 2021 IEEE/SICE international symposium on system integration (SII), Virtual, 11–14 January 2021; pp. 157–162.
 30. Cardim Ferreira Lima, M.; Krus, A.; Valero, C.; Barrientos, A.; Del Cerro, J.; Roldán-Gómez, J.J. Monitoring plant status and fertilization strategy through multispectral images. *Sensors* **2020**, *20*, 435. [[CrossRef](#)]
 31. Vidoni, R.; Gallo, R.; Ristorto, G.; Carabin, G.; Mazzetto, F.; Scalera, L.; Gasparetto, A. ByeLab: An agricultural mobile robot prototype for proximal sensing and precision farming. In *Proceedings of the ASME International Mechanical Engineering Congress and Exposition*; American Society of Mechanical Engineers: New York, NY, USA, 2017; Volume 58370, p. V04AT05A057.
 32. Anderson, V.; Leung, A.C.; Mehdipoor, H.; Jänicke, B.; Milošević, D.; Oliveira, A.; Manavvi, S.; Kabano, P.; Dzyuban, Y.; Aguilar, R.; et al. Technological opportunities for sensing of the health effects of weather and climate change: A state-of-the-art-review. *Int. J. Biometeorol.* **2021**, *65*, 779–803. [[CrossRef](#)]
 33. Ji, W.; Li, L.; Zhou, W. Design and implementation of a RFID reader/router in RFID-WSN hybrid system. *Future Internet* **2018**, *10*, 106. [[CrossRef](#)]
 34. Kocakulak, M.; Butun, I. An overview of Wireless Sensor Networks towards internet of things. In Proceedings of the 2017 IEEE 7th annual computing and communication workshop and conference (CCWC), Las Vegas, NV, USA, 9–11 January 2017; pp. 1–6.
 35. Mekonnen, Y.; Namuduri, S.; Burton, L.; Sarwat, A.; Bhansali, S. Machine learning techniques in wireless sensor network based precision agriculture. *J. Electrochem. Soc.* **2019**, *167*, 037522. [[CrossRef](#)]
 36. Haxhibeqiri, J.; De Poorter, E.; Moerman, I.; Hoebeker, J. A survey of LoRaWAN for IoT: From technology to application. *Sensors* **2018**, *18*, 3995. [[CrossRef](#)] [[PubMed](#)]
 37. Martinez, B.; Adelantado, F.; Bartoli, A.; Vilajosana, X. Exploring the performance boundaries of NB-IoT. *IEEE Internet Things J.* **2019**, *6*, 5702–5712. [[CrossRef](#)]
 38. Lavric, A.; Petrariu, A.I.; Popa, V. SigFox communication protocol: The new era of IoT? In Proceedings of the 2019 international conference on sensing and instrumentation in IoT Era (ISSI), Lisbon, Portugal, 29–30 August 2019; pp. 1–4.
 39. Borkar, S.R. Long-term evolution for machines (LTE-M). In *LPWAN Technologies for IoT and M2M Applications*; Elsevier:

- Amsterdam, The Netherlands, 2020; pp. 145–166.
40. Aldahdouh, K.A.; Darabkh, K.A.; Al-Sit, W. A survey of 5G emerging wireless technologies featuring LoRaWAN, Sigfox, NB-IoT and LTE-M. In Proceedings of the 2019 International Conference on Wireless Communications Signal Processing and Networking (WiSPNET), Chennai, India, 21–23 March 2019; pp. 561–566.
 41. Milics, G. Application of uavs in precision agriculture. In *International Climate Protection*; Springer: Berlin/Heidelberg, Germany, 2019; pp. 93–97.
 42. Maltamo, M.; Næsset, E.; Vauhkonen, J. Forestry applications of airborne laser scanning. *Concepts Case Stud. Manag. Ecosys* **2014**, *27*, 460.
 43. Tsouros, D.C.; Bibi, S.; Sarigiannidis, P.G. A review on UAV-based applications for precision agriculture. *Information* **2019**, *10*, 349. [[CrossRef](#)]
 44. dos Santos Ferreira, A.; Freitas, D.M.; da Silva, G.G.; Pistori, H.; Folhes, M.T. Weed detection in soybean crops using ConvNets. *Comput. Electron. Agric.* **2017**, *143*, 314–324. [[CrossRef](#)]
 45. Quebrajo, L.; Perez-Ruiz, M.; Pérez-Urrestarazu, L.; Martínez, G.; Egea, G. Linking thermal imaging and soil remote sensing to enhance irrigation management of sugar beet. *Biosyst. Eng.* **2018**, *165*, 77–87. [[CrossRef](#)]
 46. Garre, P.; Harish, A. Autonomous agricultural pesticide spraying uav. In *Proceedings of the IOP Conference Series: Materials Science and Engineering*; IOP Publishing: Bristol, UK, 2018; Volume 455, p. 012030.
 47. Kerkech, M.; Hafiane, A.; Canals, R. Deep leaning approach with colorimetric spaces and vegetation indices for vine diseases detection in UAV images. *Comput. Electron. Agric.* **2018**, *155*, 237–243. [[CrossRef](#)]
 48. del Cerro, J.; Cruz Ulloa, C.; Barrientos, A.; de León Rivas, J. Unmanned aerial vehicles in agriculture: A survey. *Agronomy* **2021**, *11*, 203. [[CrossRef](#)]
 49. Lal, R. 16 Challenges and Opportunities in Precision Agriculture. *Soil-Specif. Farming Precis. Agric.* **2015**, *22*, 391.
 50. Teke, M.; Deveci, H.S.; Haliloglu, O.; Gürbüz, S.Z.; Sakarya, U. A short survey of hyperspectral remote sensing applications in agriculture. In Proceedings of the 2013 6th international conference on recent advances in space technologies (RAST), Istanbul, Turkey, 12–14 June 2013; pp. 171–176.
 51. Sishodia, R.P.; Ray, R.L.; Singh, S.K. Applications of remote sensing in precision agriculture: A review. *Remote Sens.* **2020**, *12*, 3136. [[CrossRef](#)]
 52. López-Granados, F.; Jurado-Expósito, M.; Alamo, S.; Garcia-Torres, L. Leaf nutrient spatial variability and site-specific fertilization maps within olive (*Olea europaea* L.) orchards. *Eur. J. Agron.* **2004**, *21*, 209–222. [[CrossRef](#)]
 53. Noori, O.; Panda, S.S. Site-specific management of common olive: Remote sensing, geospatial, and advanced image processing applications. *Comput. Electron. Agric.* **2016**, *127*, 680–689. [[CrossRef](#)]
 54. Van Evert, F.K.; Gaitán-Cremaschi, D.; Fountas, S.; Kempenaar, C. Can precision agriculture increase the profitability and sustainability of the production of potatoes and olives? *Sustainability* **2017**, *9*, 1863. [[CrossRef](#)]
 55. Page, M.J.; McKenzie, J.E.; Bossuyt, P.M.; Boutron, I.; Hoffmann, T.C.; Mulrow, C.D.; Shamseer, L.; Tetzlaff, J.M.; Akl, E.A.; Brennan, S.E.; et al. The PRISMA 2020 statement: An updated guideline for reporting systematic reviews. *Int. J. Surg.* **2021**, *88*, 105906. [[CrossRef](#)]
 56. Wang, T.; Liu, Y.; Wang, M.; Fan, Q.; Tian, H.; Qiao, X.; Li, Y. Applications of UAS in crop biomass monitoring: A review. *Front. Plant Sci.* **2021**, *12*, 616689. [[CrossRef](#)]
 57. Manfreda, S.; McCabe, M.F.; Miller, P.E.; Lucas, R.; Pajuelo Madrigal, V.; Mallinis, G.; Ben Dor, E.; Helman, D.; Estes, L.; Ciralo, G.; et al. On the use of unmanned aerial systems for environmental monitoring. *Remote Sens.* **2018**, *10*, 641. [[CrossRef](#)]
 58. Ezenne, G.; Jupp, L.; Mantel, S.; Tanner, J. Current and potential capabilities of UAS for crop water productivity in precision agriculture. *Agric. Water Manag.* **2019**, *218*, 158–164. [[CrossRef](#)]
 59. Niu, H.; Hollenbeck, D.; Zhao, T.; Wang, D.; Chen, Y. Evapotranspiration estimation with small UAVs in precision agriculture. *Sensors* **2020**, *20*, 6427. [[CrossRef](#)]
 60. Pereira, F.d.S.; de Lima, J.; Freitas, R.; Dos Reis, A.A.; do Amaral, L.R.; Figueiredo, G.K.D.A.; Lamparelli, R.A.; Magalhães, P.S.G. Nitrogen variability assessment of pasture fields under an integrated crop-livestock system using UAV, PlanetScope, and Sentinel-2 data. *Comput. Electron. Agric.* **2022**, *193*, 106645. [[CrossRef](#)]
 61. Veysi, S.; Naseri, A.A.; Hamzeh, S. Relationship between field measurement of soil moisture in the effective depth of sugarcane root zone and extracted indices from spectral reflectance of optical/thermal bands of multispectral satellite images. *J. Indian Soc. Remote Sens.* **2020**, *48*, 1035–1044. [[CrossRef](#)]
 62. Sun, C.; Zhou, J.; Ma, Y.; Xu, Y.; Pan, B.; Zhang, Z. A review of remote sensing for potato traits characterization in precision agriculture. *Front. Plant Sci.* **2022**, *13*, 871859. [[CrossRef](#)] [[PubMed](#)]
 63. Günder, M.; Ispizua Yamati, F.R.; Kierdorf, J.; Roscher, R.; Mahlein, A.K.; Bauckhage, C. Agricultural plant cataloging and establishment of a data framework from UAV-based crop images by computer vision. *GigaScience* **2022**, *11*, giac054. [[CrossRef](#)]
 64. Panday, U.S.; Pratihast, A.K.; Aryal, J.; Kayastha, R.B. A review on drone-based data solutions for cereal crops. *Drones* **2020**, *4*, 41. [[CrossRef](#)]
 65. Vlachopoulos, O.; Leblon, B.; Wang, J.; Haddadi, A.; LaRocque, A.; Patterson, G. Evaluation of Crop Health Status With UAS Multispectral Imagery. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* **2021**, *15*, 297–308. [[CrossRef](#)]
 66. Bahuguna, S.; Anchal, S.; Guleria, D.; Devi, M.; Meenakshi; Kumar, D.; Kumar, R.; Murthy, P.; Kumar, A. Unmanned aerial vehicle-based multispectral remote sensing for commercially important aromatic crops in India for its efficient monitoring and management. *J. Indian Soc. Remote Sens.* **2022**, *50*, 397–407. [[CrossRef](#)]

67. Thilakarathna, M.S.; Raizada, M.N. Challenges in using precision agriculture to optimize symbiotic nitrogen fixation in legumes: Progress, limitations, and future improvements needed in diagnostic testing. *Agronomy* **2018**, *8*, 78. [[CrossRef](#)]
68. Luo, S.; Jiang, X.; Yang, K.; Li, Y.; Fang, S. Multispectral remote sensing for accurate acquisition of rice phenotypes: Impacts of radiometric calibration and unmanned aerial vehicle flying altitudes. *Front. Plant Sci.* **2022**, *13*, 958106. [[CrossRef](#)]
69. Hunt, E.R.; Horneck, D.A.; Spinelli, C.B.; Turner, R.W.; Bruce, A.E.; Gadler, D.J.; Brungardt, J.J.; Hamm, P.B. Monitoring nitrogen status of potatoes using small unmanned aerial vehicles. *Precis. Agric.* **2018**, *19*, 314–333. [[CrossRef](#)]
70. Di Gennaro, S.F.; Toscano, P.; Gatti, M.; Poni, S.; Berton, A.; Matese, A. Spectral Comparison of UAV-Based Hyper and Multispectral Cameras for Precision Viticulture. *Remote Sens.* **2022**, *14*, 449. [[CrossRef](#)]
71. Barbosa Júnior, M.R.; Moreira, B.R.d.A.; Brito Filho, A.L.d.; Tedesco, D.; Shiratsuchi, L.S.; Silva, R.P.d. UAVs to Monitor and Manage Sugarcane: Integrative Review. *Agronomy* **2022**, *12*, 661. [[CrossRef](#)]
72. Martos, V.; Ahmad, A.; Cartujo, P.; Ordoñez, J. Ensuring agricultural sustainability through remote sensing in the era of agriculture 5.0. *Appl. Sci.* **2021**, *11*, 5911. [[CrossRef](#)]
73. Velusamy, P.; Rajendran, S.; Mahendran, R.K.; Naseer, S.; Shafiq, M.; Choi, J.G. Unmanned Aerial Vehicles (UAV) in precision agriculture: Applications and challenges. *Energies* **2021**, *15*, 217. [[CrossRef](#)]
74. Rasmussen, J.; Azim, S.; Boldsen, S.K.; Nitschke, T.; Jensen, S.M.; Nielsen, J.; Christensen, S. The challenge of reproducing remote sensing data from satellites and unmanned aerial vehicles (UAVs) in the context of management zones and precision agriculture. *Precis. Agric.* **2021**, *22*, 834–851. [[CrossRef](#)]
75. Aliane, N.; Muñoz, C.Q.G.; Sánchez-Soriano, J. Web and MATLAB-Based Platform for UAV Flight Management and Multispectral Image Processing. *Sensors* **2022**, *22*, 4243. [[CrossRef](#)]
76. Mateo-Aroca, A.; García-Mateos, G.; Ruiz-Canales, A.; Molina-García-Pardo, J.M.; Molina-Martínez, J.M. Remote image capture system to improve aerial supervision for precision irrigation in agriculture. *Water* **2019**, *11*, 255. [[CrossRef](#)]
77. Donmez, C.; Villi, O.; Berberoglu, S.; Cilek, A. Computer vision-based citrus tree detection in a cultivated environment using UAV imagery. *Comput. Electron. Agric.* **2021**, *187*, 106273. [[CrossRef](#)]
78. Pephrah, C.O.; Yamashita, M.; Yamaguchi, T.; Sekino, R.; Takano, K.; Katsura, K. Spatio-temporal estimation of biomass growth in rice using canopy surface model from unmanned aerial vehicle images. *Remote Sens.* **2021**, *13*, 2388. [[CrossRef](#)]
79. Radoglou-Grammatikis, P.; Sarigiannidis, P.; Lagkas, T.; Moscholios, I. A compilation of UAV applications for precision agriculture. *Comput. Netw.* **2020**, *172*, 107148. [[CrossRef](#)]
80. Köppl, C.J.; Malureanu, R.; Dam-Hansen, C.; Wang, S.; Jin, H.; Barchiesi, S.; Sandi, J.M.S.; Munoz-Carpena, R.; Johnson, M.; Durán-Quesada, A.M.; et al. Hyperspectral reflectance measurements from UAS under intermittent clouds: Correcting irradiance measurements for sensor tilt. *Remote Sens. Environ.* **2021**, *267*, 112719. [[CrossRef](#)]
81. Rejeb, A.; Abdollahi, A.; Rejeb, K.; Treiblmaier, H. Drones in agriculture: A review and bibliometric analysis. *Comput. Electron. Agric.* **2022**, *198*, 107017. [[CrossRef](#)]
82. Yang, S.; Yang, X.; Mo, J. The application of unmanned aircraft systems to plant protection in China. *Precis. Agric.* **2018**, *19*, 278–292. [[CrossRef](#)]
83. Jafarbiglu, H.; Pourreza, A. A comprehensive review of remote sensing platforms, sensors, and applications in nut crops. *Comput. Electron. Agric.* **2022**, *197*, 106844. [[CrossRef](#)]
84. Yang, C. High resolution satellite imaging sensors for precision agriculture. *Front. Agric. Sci. Eng.* **2018**, *5*, 393–405. [[CrossRef](#)]
85. Crucil, G.; Castaldi, F.; Aldana-Jague, E.; van Wesemael, B.; Macdonald, A.; Van Oost, K. Assessing the performance of UAS-compatible multispectral and hyperspectral sensors for soil organic carbon prediction. *Sustainability* **2019**, *11*, 1889. [[CrossRef](#)]
86. Hassler, S.C.; Baysal-Gurel, F. Unmanned aircraft system (UAS) technology and applications in agriculture. *Agronomy* **2019**, *9*, 618. [[CrossRef](#)]
87. Srivastava, K.; Bhutoria, A.J.; Sharma, J.K.; Sinha, A.; Pandey, P.C. UAVs technology for the development of GUI based application for precision agriculture and environmental research. *Remote Sens. Appl. Soc. Environ.* **2019**, *16*, 100258. [[CrossRef](#)]
88. Wang, T.; Mei, X.; Thomasson, J.A.; Yang, C.; Han, X.; Yadav, P.K.; Shi, Y. GIS-based volunteer cotton habitat prediction and plant-level detection with UAV remote sensing. *Comput. Electron. Agric.* **2022**, *193*, 106629. [[CrossRef](#)]
89. El Hoummaid, L.; Larabi, A.; Alam, K. Using unmanned aerial systems and deep learning for agriculture mapping in Dubai. *Heliyon* **2021**, *7*, e08154. [[CrossRef](#)] [[PubMed](#)]
90. Isorna Llerena, F.; Fernandez Barranco, A.; Bogeat, J.A.; Segura, F.; Andújar, J.M. Converting a Fixed-Wing Internal Combustion Engine RPAS into an Electric Lithium-Ion Battery-Driven RPAS. *Appl. Sci.* **2020**, *10*, 1573. [[CrossRef](#)]
91. Singh, P.K.; Sharma, A. An intelligent WSN-UAV-based IoT framework for precision agriculture application. *Comput. Electr. Eng.* **2022**, *100*, 107912. [[CrossRef](#)]
92. Hu, P.; Chapman, S.C.; Zheng, B. Coupling of machine learning methods to improve estimation of ground coverage from unmanned aerial vehicle (UAV) imagery for high-throughput phenotyping of crops. *Funct. Plant Biol.* **2021**, *48*, 766–779. [[CrossRef](#)] [[PubMed](#)]

93. Hunt, E.R., Jr.; Stern, A.J. Evaluation of incident light sensors on unmanned aircraft for calculation of spectral reflectance. *Remote Sens.* **2019**, *11*, 2622. [[CrossRef](#)]
94. Potgieter, A.B.; Zhao, Y.; Zarco-Tejada, P.J.; Chenu, K.; Zhang, Y.; Porker, K.; Biddulph, B.; Dang, Y.P.; Neale, T.; Roosta, F.; et al. Evolution and application of digital technologies to predict crop type and crop phenology in agriculture. *Silico Plants* **2021**, *3*, diab017. [[CrossRef](#)]
95. Vélez, S.; Poblete-Echeverría, C.; Rubio, J.A.; Barajas, E. Estimation of Leaf Area Index in vineyards by analysing projected shadows using UAV imagery. *OENO One* **2021**, *55*, 159–180. [[CrossRef](#)]
96. Popescu, D.; Stoican, F.; Stamatescu, G.; Ichim, L.; Dragana, C. Advanced UAV–WSN system for intelligent monitoring in precision agriculture. *Sensors* **2020**, *20*, 817. [[CrossRef](#)]
97. Zhang, C.; Valente, J.; Kooistra, L.; Guo, L.; Wang, W. Orchard management with small unmanned aerial vehicles: A survey of sensing and analysis approaches. *Precis. Agric.* **2021**, *22*, 2007–2052. [[CrossRef](#)]
98. Li, L.; Zheng, X.; Zhao, K.; Li, X.; Meng, Z.; Su, C. Potential Evaluation of High Spatial Resolution Multi-Spectral Images Based on Unmanned Aerial Vehicle in Accurate Recognition of Crop Types. *J. Indian Soc. Remote Sens.* **2020**, *48*, 1471–1478. [[CrossRef](#)]
99. Tetila, E.C.; Machado, B.B.; Astolfi, G.; de Souza Belete, N.A.; Amorim, W.P.; Roel, A.R.; Pistori, H. Detection and classification of soybean pests using deep learning with UAV images. *Comput. Electron. Agric.* **2020**, *179*, 105836. [[CrossRef](#)]
100. Bagha, H.; Yavari, A.; Georgakopoulos, D. Hybrid Sensing Platform for IoT-Based Precision Agriculture. *Future Internet* **2022**, *14*, 233. [[CrossRef](#)]
101. Mohidem, N.A.; Che'Ya, N.N.; Juraimi, A.S.; Fazlil Ilahi, W.F.; Mohd Roslim, M.H.; Sulaiman, N.; Saberioon, M.; Mohd Noor, N. How can unmanned aerial vehicles be used for detecting weeds in agricultural fields? *Agriculture* **2021**, *11*, 1004. [[CrossRef](#)]
102. Kerkech, M.; Hafiane, A.; Canals, R. VddNet: Vine disease detection network based on multispectral images and depth map. *Remote Sens.* **2020**, *12*, 3305. [[CrossRef](#)]
103. Hunt, E.R., Jr.; Daughtry, C.S. What good are unmanned aircraft systems for agricultural remote sensing and precision agriculture? *Int. J. Remote Sens.* **2018**, *39*, 5345–5376. [[CrossRef](#)]
104. Osco, L.P.; de Arruda, M.d.S.; Gonçalves, D.N.; Dias, A.; Batistoti, J.; de Souza, M.; Gomes, F.D.G.; Ramos, A.P.M.; de Castro Jorge, L.A.; Liesenberg, V.; et al. A CNN approach to simultaneously count plants and detect plantation-rows from UAV imagery. *ISPRS J. Photogramm. Remote Sens.* **2021**, *174*, 1–17. [[CrossRef](#)]
105. Huang, Y.; Chen, Z.X.; Tao, Y.; Huang, X.Z.; Gu, X.F. Agricultural remote sensing big data: Management and applications. *J. Integr. Agric.* **2018**, *17*, 1915–1931. [[CrossRef](#)]
106. Tetila, E.C.; Machado, B.B.; Menezes, G.K.; Oliveira, A.d.S.; Alvarez, M.; Amorim, W.P.; Belete, N.A.D.S.; Da Silva, G.G.; Pistori, H. Automatic recognition of soybean leaf diseases using UAV images and deep convolutional neural networks. *IEEE Geosci. Remote Sens. Lett.* **2019**, *17*, 903–907. [[CrossRef](#)]
107. Illana Rico, S.; Martinez Gila, D.M.; Cano Marchal, P.; Gómez Ortega, J. Automatic Detection of Olive Tree Canopies for Groves with Thick Plant Cover on the Ground. *Sensors* **2022**, *22*, 6219. [[CrossRef](#)]
108. Kutugata, M.; Hu, C.; Sapkota, B.; Bagavathiannan, M. Seed rain potential in late-season weed escapes can be estimated using remote sensing. *Weed Sci.* **2021**, *69*, 653–659. [[CrossRef](#)]
109. Ampatzidis, Y.; Partel, V. UAV-based high throughput phenotyping in citrus utilizing multispectral imaging and artificial intelligence. *Remote Sens.* **2019**, *11*, 410. [[CrossRef](#)]
110. Csillik, O.; Cherbini, J.; Johnson, R.; Lyons, A.; Kelly, M. Identification of citrus trees from unmanned aerial vehicle imagery using convolutional neural networks. *Drones* **2018**, *2*, 39. [[CrossRef](#)]
111. Donati, C.; Mammarella, M.; Comba, L.; Biglia, A.; Gay, P.; Dabbene, F. 3D Distance Filter for the Autonomous Navigation of UAVs in Agricultural Scenarios. *Remote Sens.* **2022**, *14*, 1374. [[CrossRef](#)]
112. González-García, J.; Swenson, R.L.; Gómez-Espinosa, A. Real-time kinematics applied at unmanned aerial vehicles positioning for orthophotography in precision agriculture. *Comput. Electron. Agric.* **2020**, *177*, 105695. [[CrossRef](#)]
113. Khun, K.; Tremblay, N.; Panneton, B.; Vigneault, P.; Lord, E.; Cavayas, F.; Codjia, C. Use of oblique RGB imagery and apparent surface area of plants for early estimation of above-ground corn biomass. *Remote Sens.* **2021**, *13*, 4032. [[CrossRef](#)]
114. Simic Milas, A.; Romanko, M.; Reil, P.; Abeysinghe, T.; Marambe, A. The importance of leaf area index in mapping chlorophyll content of corn under different agricultural treatments using UAV images. *Int. J. Remote Sens.* **2018**, *39*, 5415–5431. [[CrossRef](#)]
115. Zhang, T.; Yang, Z.; Xu, Z.; Li, J. Wheat Yellow Rust Severity Detection by Efficient DF-UNet and UAV Multispectral Imagery. *IEEE Sens. J.* **2022**, *22*, 9057–9068. [[CrossRef](#)]
116. Zhang, J.; Wang, C.; Yang, C.; Xie, T.; Jiang, Z.; Hu, T.; Luo, Z.; Zhou, G.; Xie, J. Assessing the Effect of Real Spatial Resolution of In Situ UAV Multispectral Images on Seedling Rapeseed Growth Monitoring. *Remote Sens.* **2020**, *12*, 1207. [[CrossRef](#)]
117. Zhao, H.; Yang, Y.; Yang, C.; Song, R.; Guo, W. Evaluation of spatial resolution on crop disease detection based on multiscale images and category variance ratio. *Comput. Electron. Agric.* **2023**, *207*, 107743. [[CrossRef](#)]
118. Ahmad, A.; Ordoñez, J.; Cartujo, P.; Martos, V. Remotely piloted aircraft (RPA) in agriculture: A pursuit of sustainability. *Agronomy* **2020**, *11*, 7. [[CrossRef](#)]
119. Comba, L.; Biglia, A.; Aimonino, D.R.; Gay, P. Unsupervised detection of vineyards by 3D point-cloud UAV photogrammetry for precision agriculture. *Comput. Electron. Agric.* **2018**, *155*, 84–95. [[CrossRef](#)]
120. Zhang, F.; Hassanzadeh, A.; Kikkert, J.; Pethybridge, S.J.; van Aardt, J. Comparison of UAS-based structure-from-motion and LiDAR for structural characterization of short broadacre crops. *Remote Sens.* **2021**, *13*, 3975. [[CrossRef](#)]

121. Yang, C. Remote sensing and precision agriculture technologies for crop disease detection and management with a practical application example. *Engineering* **2020**, *6*, 528–532. [[CrossRef](#)]
122. Zhu, W.; Rezaei, E.E.; Nouri, H.; Sun, Z.; Li, J.; Yu, D.; Siebert, S. UAV-based indicators of crop growth are robust for distinct water and nutrient management but vary between crop development phases. *Field Crops Res.* **2022**, *284*, 108582. [[CrossRef](#)]
123. Liu, J.; Xiang, J.; Jin, Y.; Liu, R.; Yan, J.; Wang, L. Boost Precision Agriculture with Unmanned Aerial Vehicle Remote Sensing and Edge Intelligence: A Survey. *Remote Sens.* **2021**, *13*, 4387. [[CrossRef](#)]
124. Latif, M.A.; Cheema, M.J.M.; Saleem, M.F.; Maqsood, M. Mapping wheat response to variations in N, P, Zn, and irrigation using an unmanned aerial vehicle. *Int. J. Remote Sens.* **2018**, *39*, 7172–7188. [[CrossRef](#)]
125. Näsi, R.; Viljanen, N.; Kaivosoja, J.; Alhonoja, K.; Hakala, T.; Markelin, L.; Honkavaara, E. Estimating biomass and nitrogen amount of barley and grass using UAV and aircraft based spectral and photogrammetric 3D features. *Remote Sens.* **2018**, *10*, 1082. [[CrossRef](#)]
126. Yu, J.; Wang, J.; Leblon, B. Evaluation of Soil Properties, Topographic Metrics, Plant Height, and Unmanned Aerial Vehicle Multispectral Imagery Using Machine Learning Methods to Estimate Canopy Nitrogen Weight in Corn. *Remote Sens.* **2021**, *13*, 3105. [[CrossRef](#)]
127. Shaikh, T.A.; Rasool, T.; Lone, F.R. Towards leveraging the role of machine learning and artificial intelligence in precision agriculture and smart farming. *Comput. Electron. Agric.* **2022**, *198*, 107119. [[CrossRef](#)]
128. Bellis, E.S.; Hashem, A.A.; Causey, J.L.; Runkle, B.R.; Moreno-García, B.; Burns, B.W.; Green, V.S.; Burcham, T.N.; Reba, M.L.; Huang, X. Detecting Intra-Field Variation in Rice Yield with Unmanned Aerial Vehicle Imagery and Deep Learning. *Front. Plant Sci.* **2022**, *13*, 716506. [[CrossRef](#)]
129. Siok, K.; Jenerowicz, A.; Ewiak, I. A simulation approach to the spectral quality of multispectral images enhancement. *Comput. Electron. Agric.* **2020**, *174*, 105432. [[CrossRef](#)]
130. Peter, B.G.; Messina, J.P.; Carroll, J.W.; Zhi, J.; Chimonyo, V.; Lin, S.; Snapp, S.S. Multi-spatial resolution satellite and sUAS imagery for precision agriculture on smallholder farms in Malawi. *Photogramm. Eng. Remote Sens.* **2020**, *86*, 107–119. [[CrossRef](#)]
131. Morais, R.; Silva, N.; Mendes, J.; Adão, T.; Pádua, L.; López-Riquelme, J.A.; Pavón-Pulido, N.; Sousa, J.J.; Peres, E. Mysense: A comprehensive data management environment to improve precision agriculture practices. *Comput. Electron. Agric.* **2019**, *162*, 882–894. [[CrossRef](#)]
132. Li, M.; Shamshiri, R.R.; Weltzien, C.; Schirrmann, M. Crop Monitoring Using Sentinel-2 and UAV Multispectral Imagery: A Comparison Case Study in Northeastern Germany. *Remote Sens.* **2022**, *14*, 4426. [[CrossRef](#)]
133. Singh, A.P.; Yerudkar, A.; Mariani, V.; Iannelli, L.; Glielmo, L. A Bibliometric Review of the Use of Unmanned Aerial Vehicles in Precision Agriculture and Precision Viticulture for Sensing Applications. *Remote Sens.* **2022**, *14*, 1604. [[CrossRef](#)]
134. Gilliot, J.M.; Hadjar, D.; Michelin, J. Potential of Ultra-High-Resolution UAV Images with Centimeter GNSS Positioning for Plant Scale Crop Monitoring. *Remote Sens.* **2022**, *14*, 2391. [[CrossRef](#)]
135. Chen, A.; Orlov-Levin, V.; Meron, M. Applying high-resolution visible-channel aerial imaging of crop canopy to precision irrigation management. *Agric. Water Manag.* **2019**, *216*, 196–205. [[CrossRef](#)]
136. Mazzia, V.; Comba, L.; Khaliq, A.; Chiaberge, M.; Gay, P. UAV and machine learning based refinement of a satellite-driven vegetation index for precision agriculture. *Sensors* **2020**, *20*, 2530. [[CrossRef](#)]
137. Nidamanuri, R.R.; Jayakumari, R.; Ramiya, A.M.; Astor, T.; Wachendorf, M.; Buerkert, A. High-resolution multispectral imagery and LiDAR point cloud fusion for the discrimination and biophysical characterisation of vegetable crops at different levels of nitrogen. *Biosyst. Eng.* **2022**, *222*, 177–195. [[CrossRef](#)]
138. Heim, R.H.; Wright, I.J.; Scarth, P.; Carnegie, A.J.; Taylor, D.; Oldeland, J. Multispectral, aerial disease detection for myrtle rust (*Austropuccinia psidii*) on a lemon myrtle plantation. *Drones* **2019**, *3*, 25. [[CrossRef](#)]
139. Guan, Z.; Abd-Elrahman, A.; Fan, Z.; Whitaker, V.M.; Wilkinson, B. Modeling strawberry biomass and leaf area using object-based analysis of high-resolution images. *ISPRS J. Photogramm. Remote Sens.* **2020**, *163*, 171–186. [[CrossRef](#)]
140. Nguyen, L.H.; Robinson, S.; Galpern, P. Medium-resolution multispectral satellite imagery in precision agriculture: Mapping precision canola (*Brassica napus* L.) yield using Sentinel-2 time series. *Precis. Agric.* **2022**, *23*, 1051–1071. [[CrossRef](#)]
141. Řezník, T.; Pavelka, T.; Herman, L.; Lukas, V.; Širuček, P.; Leitgeb, Š.; Leitner, F. Prediction of yield productivity zones from Landsat 8 and Sentinel-2A/B and their evaluation using farm machinery measurements. *Remote Sens.* **2020**, *12*, 1917. [[CrossRef](#)]
142. Marshall, A.; Turner, K.; Richards, C.; Foth, M.; Dezuanni, M. Critical factors of digital AgTech adoption on Australian farms: From digital to data divide. *Inf. Commun. Soc.* **2022**, *25*, 868–886. [[CrossRef](#)]
143. Chemura, A.; Mutanga, O.; Odindi, J.; Kutwayo, D. Mapping spatial variability of foliar nitrogen in coffee (*Coffea arabica* L.) plantations with multispectral Sentinel-2 MSI data. *ISPRS J. Photogramm. Remote Sens.* **2018**, *138*, 1–11. [[CrossRef](#)]
144. Segarra, J.; Buchaillet, M.L.; Araus, J.L.; Kefauver, S.C. Remote sensing for precision agriculture: Sentinel-2 improved features and applications. *Agronomy* **2020**, *10*, 641. [[CrossRef](#)]
145. Cavaliere, D.; Senatore, S. Incremental Knowledge Extraction from IoT-Based System for Anomaly Detection in Vegetation Crops. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* **2021**, *15*, 876–888. [[CrossRef](#)]
146. Anderson, N.; Underwood, J.; Rahman, M.; Robson, A.; Walsh, K. Estimation of fruit load in mango orchards: Tree sampling considerations and use of machine vision and satellite imagery. *Precis. Agric.* **2019**, *20*, 823–839. [[CrossRef](#)]
147. Georgi, C.; Spengler, D.; Itzerott, S.; Kleinschmit, B. Automatic delineation algorithm for site-specific management zones based on satellite remote sensing data. *Precis. Agric.* **2018**, *19*, 684–707. [[CrossRef](#)]
148. Solano-Correa, Y.T.; Meshkini, K.; Bovolo, F.; Bruzzone, L. Automatic Large-Scale Precise Mapping and Monitoring of

- Agricultural Fields at Country Level With Sentinel-2 SITS. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* **2022**, *15*, 3131–3145. [[CrossRef](#)]
149. Bukowiecki, J.; Rose, T.; Kage, H. Sentinel-2 Data for Precision Agriculture?—A UAV-Based Assessment. *Sensors* **2021**, *21*, 2861. [[CrossRef](#)]
150. Breunig, F.M.; Galvão, L.S.; Dalagnol, R.; Dauve, C.E.; Parraga, A.; Santi, A.L.; Della Flora, D.P.; Chen, S. Delineation of management zones in agricultural fields using cover–crop biomass estimates from PlanetScope data. *Int. J. Appl. Earth Obs. Geoinf.* **2020**, *85*, 102004. [[CrossRef](#)]
151. Iwasaki, K.; Torita, H.; Abe, T.; Uraike, T.; Touze, M.; Fukuchi, M.; Sato, H.; Iijima, T.; Imaoka, K.; Igawa, H. Spatial pattern of windbreak effects on maize growth evaluated by an unmanned aerial vehicle in Hokkaido, northern Japan. *Agrofor. Syst.* **2019**, *93*, 1133–1145. [[CrossRef](#)]
152. Silvero, N.E.Q.; Demattê, J.A.M.; Amorim, M.T.A.; dos Santos, N.V.; Rizzo, R.; Safanelli, J.L.; Poppiel, R.R.; de Sousa Mendes, W.; Bonfatti, B.R. Soil variability and quantification based on Sentinel-2 and Landsat-8 bare soil images: A comparison. *Remote Sens. Environ.* **2021**, *252*, 112117. [[CrossRef](#)]
153. Gómez, D.; Salvador, P.; Sanz, J.; Casanova, J.L. Potato yield prediction using machine learning techniques and sentinel 2 data. *Remote Sens.* **2019**, *11*, 1745. [[CrossRef](#)]
154. De la Casa, A.; Ovando, G.; Bressanini, L.; Martínez, J.; Díaz, G.; Miranda, C. Soybean crop coverage estimation from NDVI images with different spatial resolution to evaluate yield variability in a plot. *ISPRS J. Photogramm. Remote Sens.* **2018**, *146*, 531–547. [[CrossRef](#)]
155. Barbanti, L.; Adroher, J.; Damian, J.M.; Di Virgilio, N.; Falsone, G.; Zucchelli, M.; Martelli, R. Assessing wheat spatial variation based on proximal and remote spectral vegetation indices and soil properties. *Ital. J. Agron.* **2018**, *13*, 21–30. [[CrossRef](#)]
156. Mukherjee, A.; Misra, S.; Raghuvanshi, N.S. A survey of unmanned aerial sensing solutions in precision agriculture. *J. Netw. Comput. Appl.* **2019**, *148*, 102461. [[CrossRef](#)]
157. Prey, L.; Schmidhalter, U. Simulation of satellite reflectance data using high-frequency ground based hyperspectral canopy measurements for in-season estimation of grain yield and grain nitrogen status in winter wheat. *ISPRS J. Photogramm. Remote Sens.* **2019**, *149*, 176–187. [[CrossRef](#)]
158. Marin, D.B.; Ferraz, G.A.e.S.; Santana, L.S.; Barbosa, B.D.S.; Barata, R.A.P.; Osco, L.P.; Ramos, A.P.M.; Guimarães, P.H.S. Detecting coffee leaf rust with UAV-based vegetation indices and decision tree machine learning models. *Comput. Electron. Agric.* **2021**, *190*, 106476. [[CrossRef](#)]
159. Fahey, T.; Pham, H.; Gardi, A.; Sabatini, R.; Stefanelli, D.; Goodwin, I.; Lamb, D.W. Active and passive electro-optical sensors for health assessment in food crops. *Sensors* **2020**, *21*, 171. [[CrossRef](#)]
160. Hernández-López, D.; Piedelobo, L.; Moreno, M.A.; Chakhar, A.; Ortega-Terol, D.; González-Aguilera, D. Design of a Local Nested Grid for the Optimal Combined Use of Landsat 8 and Sentinel 2 Data. *Remote Sens.* **2021**, *13*, 1546. [[CrossRef](#)]
161. Rasmussen, J.; Azim, S.; Nielsen, J. Pre-harvest weed mapping of *Cirsium arvense* L. based on free satellite imagery—The importance of weed aggregation and image resolution. *Eur. J. Agron.* **2021**, *130*, 126373. [[CrossRef](#)]
162. Hänel, T.; Jarmer, T.; Aschenbruck, N. Learning a Transform Base for the Multi-to Hyperspectral Sensor Network with K-SVD. *Sensors* **2021**, *21*, 7296. [[CrossRef](#)]
163. Altobelli, F.; Lall, U.; Dalla Marta, A.; Caracciolo, F.; Cicia, G.; D’Urso, G.; Del Giudice, T. Willingness of farmers to pay for satellite-based irrigation advisory services: A southern Italy experience. *J. Agric. Sci.* **2018**, *156*, 723–730. [[CrossRef](#)]
164. Vallentin, C.; Harfenmeister, K.; Itzerott, S.; Kleinschmit, B.; Conrad, C.; Spengler, D. Suitability of satellite remote sensing data for yield estimation in northeast Germany. *Precisi. Agric.* **2022**, *23*, 52–82. [[CrossRef](#)]
165. Ruan, J.; Jiang, H.; Zhu, C.; Hu, X.; Shi, Y.; Liu, T.; Rao, W.; Chan, F.T.S. Agriculture IoT: Emerging trends, cooperation networks, and outlook. *IEEE Wirel. Commun.* **2019**, *26*, 56–63. [[CrossRef](#)]
166. Chamara, N.; Islam, M.D.; Bai, G.F.; Shi, Y.; Ge, Y. Ag-IoT for crop and environment monitoring: Past, present, and future. *Agric. Syst.* **2022**, *203*, 103497. [[CrossRef](#)]
167. Maraveas, C.; Piromalis, D.; Arvanitis, K.; Bartzanas, T.; Loukatos, D. Applications of IoT for optimized greenhouse environment and resources management. *Comput. Electron. Agric.* **2022**, *198*, 106993. [[CrossRef](#)]
168. Torky, M.; Hassanein, A.E. Integrating blockchain and the internet of things in precision agriculture: Analysis, opportunities, and challenges. *Comput. Electron. Agric.* **2020**, *178*, 105476. [[CrossRef](#)]
169. Li, W.; Awais, M.; Ru, W.; Shi, W.; Ajmal, M.; Uddin, S.; Liu, C. Review of sensor network-based irrigation systems using IoT and remote sensing. *Adv. Meteorol.* **2020**, *2020*, 8396164. [[CrossRef](#)]
170. Dasgupta, I.; Saha, J.; Venkatasubbu, P.; Ramasubramanian, P. AI Crop predictor and weed detector using wireless technologies: A smart application for farmers. *Arab. J. Sci. Eng.* **2020**, *45*, 11115–11127. [[CrossRef](#)]
171. Tang, Y.; Dananjayan, S.; Hou, C.; Guo, Q.; Luo, S.; He, Y. A survey on the 5G network and its impact on agriculture: Challenges and opportunities. *Comput. Electron. Agric.* **2021**, *180*, 105895. [[CrossRef](#)]
172. Guillén-Navarro, M.A.; Martínez-España, R.; Bueno-Crespo, A.; Morales-García, J.; Ayuso, B.; Cecilia, J.M. A decision support system for water optimization in anti-frost techniques by sprinklers. *Sensors* **2020**, *20*, 7129. [[CrossRef](#)] [[PubMed](#)]
173. Ahmed, N.; De, D.; Hussain, I. Internet of Things (IoT) for smart precision agriculture and farming in rural areas. *IEEE Internet Things J.* **2018**, *5*, 4890–4899. [[CrossRef](#)]
174. Sophocleous, M.; Karkotis, A.; Georgiou, J. A versatile, stand-alone, in-field sensor node for implementation in precision agriculture. *IEEE J. Emerg. Sel. Top. Circuits Syst.* **2021**, *11*, 449–457. [[CrossRef](#)]

175. Lloret, J.; Sendra, S.; Garcia, L.; Jimenez, J.M. A Wireless Sensor Network Deployment for Soil Moisture Monitoring in Precision Agriculture. *Sensors* **2021**, *21*, 7243. [[CrossRef](#)]
176. Phupattanasilp, P.; Tong, S.R. Augmented reality in the integrative internet of things (AR-IoT): Application for precision farming. *Sustainability* **2019**, *11*, 2658. [[CrossRef](#)]
177. Tsipis, A.; Papamichail, A.; Koufoudakis, G.; Tsoumanis, G.; Polykalas, S.E.; Oikonomou, K. Latency-adjustable cloud/fog computing architecture for time-sensitive environmental monitoring in olive groves. *AgriEngineering* **2020**, *2*, 175–205. [[CrossRef](#)]
178. Agrawal, H.; Dhall, R.; Iyer, K.; Chetlapalli, V. An improved energy efficient system for IoT enabled precision agriculture. *J. Ambient Intell. Humaniz. Comput.* **2020**, *11*, 2337–2348. [[CrossRef](#)]
179. Kour, V.P.; Arora, S. Recent developments of the internet of things in agriculture: A survey. *IEEE Access* **2020**, *8*, 129924–129957. [[CrossRef](#)]
180. Castellanos, G.; Deruyck, M.; Martens, L.; Joseph, W. System assessment of WUSN using NB-IoT UAV-aided networks in potato crops. *IEEE Access* **2020**, *8*, 56823–56836. [[CrossRef](#)]
181. Triantafyllou, A.; Sarigiannidis, P.; Bibi, S. Precision agriculture: A remote sensing monitoring system architecture. *Information* **2019**, *10*, 348. [[CrossRef](#)]
182. Singh, R.K.; Berkvens, R.; Weyn, M. AgriFusion: An architecture for IoT and emerging technologies based on a precision agriculture survey. *IEEE Access* **2021**, *9*, 136253–136283. [[CrossRef](#)]
183. Roy, S.K.; Misra, S.; Raghuwanshi, N.S.; Das, S.K. AgriSens: IoT-based dynamic irrigation scheduling system for water management of irrigated crops. *IEEE Internet Things J.* **2020**, *8*, 5023–5030. [[CrossRef](#)]
184. Tsipis, A.; Papamichail, A.; Angelis, I.; Koufoudakis, G.; Tsoumanis, G.; Oikonomou, K. An alertness-adjustable cloud/fog IoT solution for timely environmental monitoring based on wildfire risk forecasting. *Energies* **2020**, *13*, 3693. [[CrossRef](#)]
185. Abu, N.; Bukhari, W.; Ong, C.; Kassim, A.; Izzuddin, T.; Sukhaimie, M.; Norasikin, M.; Rasid, A. Internet of Things Applications in Precision Agriculture: A Review. *J. Robot. Control (JRC)* **2022**, *3*, 338–347. [[CrossRef](#)]
186. Pal, P.; Sharma, R.P.; Tripathi, S.; Kumar, C.; Ramesh, D. 2.4 GHz RF received signal strength based node separation in WSN monitoring infrastructure for millet and Rice vegetation. *IEEE Sens. J.* **2021**, *21*, 18298–18306. [[CrossRef](#)]
187. Zamora-Izquierdo, M.A.; Santa, J.; Martínez, J.A.; Martínez, V.; Skarmeta, A.F. Smart farming IoT platform based on edge and cloud computing. *Biosyst. Eng.* **2019**, *177*, 4–17. [[CrossRef](#)]
188. Verma, P.; Bhutani, S.; Srividhya, S.; Karthikeyan, D.; Tong, C.S. Review of internet of things towards sustainable development in agriculture. *J. Crit. Rev.* **2019**, *7*, 2020.
189. Koubaa, A.; Aldawood, A.; Saeed, B.; Hadid, A.; Ahmed, M.; Saad, A.; Alkhouja, H.; Ammar, A.; Alkanhal, M. Smart Palm: An IoT framework for red palm weevil early detection. *Agronomy* **2020**, *10*, 987. [[CrossRef](#)]
190. Ojha, T.; Misra, S.; Raghuwanshi, N.S. Internet of things for agricultural applications: The state of the art. *IEEE Internet Things J.* **2021**, *8*, 10973–10997. [[CrossRef](#)]
191. Moiroux-Arvis, L.; Cariou, C.; Chanet, J.P. Evaluation of LoRa technology in 433-MHz and 868-MHz for underground to aboveground data transmission. *Comput. Electron. Agric.* **2022**, *194*, 106770. [[CrossRef](#)]
192. Khanna, A.; Kaur, S. Evolution of Internet of Things (IoT) and its significant impact in the field of Precision Agriculture. *Comput. Electron. Agric.* **2019**, *157*, 218–231. [[CrossRef](#)]
193. Kulmány, I.M.; Bede-Fazekas, Á.; Beslin, A.; Giczi, Z.; Milics, G.; Kovács, B.; Kovács, M.; Ambrus, B.; Bede, L.; Vona, V. Calibration of an Arduino-based low-cost capacitive soil moisture sensor for smart agriculture. *J. Hydrol. Hydromech.* **2022**, *70*, 330–340. [[CrossRef](#)]
194. Issad, H.A.; Aoudjit, R.; Rodrigues, J.J. A comprehensive review of Data Mining techniques in smart agriculture. *Eng. Agric. Environ. Food* **2019**, *12*, 511–525. [[CrossRef](#)]
195. Goldstein, A.; Fink, L.; Meitin, A.; Bohadana, S.; Lutenberg, O.; Ravid, G. Applying machine learning on sensor data for irrigation recommendations: Revealing the agronomist’s tacit knowledge. *Precis. Agric.* **2018**, *19*, 421–444. [[CrossRef](#)]
196. Pal, P.; Tripathi, S.; Kumar, C. Single Probe Imitation of Multi-Depth Capacitive Soil Moisture Sensor Using Bidirectional Recurrent Neural Network. *IEEE Trans. Instrum. Meas.* **2022**, *71*, 1–11. [[CrossRef](#)]
197. Yan, Q.; Lou, J.; Vuran, M.C.; Irmak, S. Scalable Privacy-preserving Geo-distance Evaluation for Precision Agriculture IoT Systems. *ACM Trans. Sens. Netw. (TOSN)* **2021**, *17*, 1–30. [[CrossRef](#)]
198. Bhat, S.A.; Huang, N.F.; Sofi, I.B.; Sultan, M. Agriculture-Food Supply Chain Management Based on Blockchain and IoT: A Narrative on Enterprise Blockchain Interoperability. *Agriculture* **2021**, *12*, 40. [[CrossRef](#)]
199. Gupta, M.; Abdelsalam, M.; Khorsandroo, S.; Mittal, S. Security and privacy in smart farming: Challenges and opportunities. *IEEE Access* **2020**, *8*, 34564–34584. [[CrossRef](#)]
200. Demestichas, K.; Peppas, N.; Alexakis, T. Survey on security threats in agricultural IoT and smart farming. *Sensors* **2020**, *20*, 6458. [[CrossRef](#)] [[PubMed](#)]
201. García, L.; Parra, L.; Jimenez, J.M.; Lloret, J.; Lorenz, P. IoT-based smart irrigation systems: An overview on the recent trends on sensors and IoT systems for irrigation in precision agriculture. *Sensors* **2020**, *20*, 1042. [[CrossRef](#)] [[PubMed](#)]
202. Ferrández-Pastor, F.J.; García-Chamizo, J.M.; Nieto-Hidalgo, M.; Mora-Martínez, J. Precision agriculture design method using a distributed computing architecture on internet of things context. *Sensors* **2018**, *18*, 1731. [[CrossRef](#)] [[PubMed](#)]
203. Yazdinejad, A.; Zolfaghari, B.; Azmoodeh, A.; Dehghantanha, A.; Karimipour, H.; Fraser, E.; Green, A.G.; Russell, C.; Duncan, E. A review on security of smart farming and precision agriculture: Security aspects, attacks, threats and countermeasures. *Appl. Sci.* **2021**, *11*, 7518. [[CrossRef](#)]

204. Symeonaki, E.; Arvanitis, K.; Piromalis, D. A context-aware middleware cloud approach for integrating precision farming facilities into the IoT toward agriculture 4.0. *Appl. Sci.* **2020**, *10*, 813. [CrossRef]
205. Alfred, R.; Obit, J.H.; Chin, C.P.Y.; Havaluddin, H.; Lim, Y. Towards paddy rice smart farming: A review on big data, machine learning, and rice production tasks. *IEEE Access* **2021**, *9*, 50358–50380. [CrossRef]
206. Guillén, M.A.; Llanes, A.; Imbernón, B.; Martínez-España, R.; Bueno-Crespo, A.; Cano, J.C.; Cecilia, J.M. Performance evaluation of edge-computing platforms for the prediction of low temperatures in agriculture using deep learning. *J. Supercomput.* **2021**, *77*, 818–840. [CrossRef]
207. Premkumar, S.; Sigappi, A. IoT-enabled edge computing model for smart irrigation system. *J. Intell. Syst.* **2022**, *31*, 632–650. [CrossRef]
208. Guardo, E.; Di Stefano, A.; La Corte, A.; Sapienza, M.; Scatà, M. A fog computing-based iot framework for precision agriculture. *J. Internet Technol.* **2018**, *19*, 1401–1411.
209. Zhou, L.; Tu, W.; Wang, C.; Li, Q. A Heterogeneous Access Metamodel for Efficient IoT Remote Sensing Observation Management: Taking Precision Agriculture as an Example. *IEEE Internet Things J.* **2021**, *9*, 8616–8632. [CrossRef]
210. Caruso, A.; Chessa, S.; Escolar, S.; Barba, J.; López, J.C. Collection of data with drones in precision agriculture: Analytical model and LoRa case study. *IEEE Internet Things J.* **2021**, *8*, 16692–16704. [CrossRef]
211. Abunadi, I.; Rehman, A.; Haseeb, K.; Parra, L.; Lloret, J. Traffic-Aware Secured Cooperative Framework for IoT-Based Smart Monitoring in Precision Agriculture. *Sensors* **2022**, *22*, 6676. [CrossRef]
212. Cubero, S.; Marco-Noales, E.; Aleixos, N.; Barbé, S.; Blasco, J. Robhortic: A field robot to detect pests and diseases in horticultural crops by proximal sensing. *Agriculture* **2020**, *10*, 276. [CrossRef]
213. Kour, K.; Gupta, D.; Gupta, K.; Juneja, S.; Kaur, M.; Alharbi, A.H.; Lee, H.N. Controlling Agronomic Variables of Saffron Crop Using IoT for Sustainable Agriculture. *Sustainability* **2022**, *14*, 5607. [CrossRef]
214. Khan, F.A.; Abubakar, A.; Mahmoud, M.; Al-Khasawneh, M.A.; Alarood, A.A. Cotton crop cultivation oriented semantic framework based on IoT smart farming application. *Int. J. Eng. Adv. Technol.* **2019**, *8*, 480–484.
215. Suresh Kumar, K.; Balakrishnan, S.; Janet, J. A cloud-based prototype for the monitoring and predicting of data in precision agriculture based on internet of everything. *J. Ambient Intell. Humaniz. Comput.* **2021**, *12*, 8719–8730. [CrossRef]
216. Sharma, A.; Jain, A.; Gupta, P.; Chowdary, V. Machine learning applications for precision agriculture: A comprehensive review. *IEEE Access* **2020**, *9*, 4843–4873. [CrossRef]
217. Rodríguez-Robles, J.; Martín, Á.; Martín, S.; Ruipérez-Valiente, J.A.; Castro, M. Autonomous sensor network for rural agriculture environments, low cost, and energy self-charge. *Sustainability* **2020**, *12*, 5913. [CrossRef]
218. Armenta-Medina, D.; Ramirez-delReal, T.A.; Villanueva-Vásquez, D.; Mejia-Aguirre, C. Trends on advanced information and communication technologies for improving agricultural productivities: A bibliometric analysis. *Agronomy* **2020**, *10*, 1989. [CrossRef]
219. Pham, V.B.; Diep, T.T.; Fock, K.; Nguyen, T.S. Using the Internet of Things to promote alternate wetting and drying irrigation for rice in Vietnam’s Mekong Delta. *Agron. Sustain. Dev.* **2021**, *41*, 1–9. [CrossRef]
220. Putra, B.T.W. A new low-cost sensing system for rapid ring estimation of woody plants to support tree management. *Inf. Process. Agric.* **2020**, *7*, 369–374. [CrossRef]
221. Keswani, B.; Mohapatra, A.G.; Mohanty, A.; Khanna, A.; Rodrigues, J.J.; Gupta, D.; De Albuquerque, V.H.C. Adapting weather conditions based IoT enabled smart irrigation technique in precision agriculture mechanisms. *Neural Comput. Appl.* **2019**, *31*, 277–292. [CrossRef]
222. Chaganti, R.; Varadarajan, V.; Gorantla, V.S.; Gadekallu, T.R.; Ravi, V. Blockchain-Based Cloud-Enabled Security Monitoring Using Internet of Things in Smart Agriculture. *Future Internet* **2022**, *14*, 250. [CrossRef]
223. López-Viana, R.; Díaz, J.; Díaz, V.H.; Martínez, J.F. Continuous delivery of customized SaaS edge applications in highly distributed IoT systems. *IEEE Internet Things J.* **2020**, *7*, 10189–10199. [CrossRef]
224. Brinkhoff, J.; Dunn, B.W.; Robson, A.J. Rice nitrogen status detection using commercial-scale imagery. *Int. J. Appl. Earth Obs. Geoinf.* **2021**, *105*, 102627. [CrossRef]
225. Alvarez-Vanhard, E.; Corpetti, T.; Houet, T. UAV & satellite synergies for optical remote sensing applications: A literature review. *Sci. Remote Sens.* **2021**, *3*, 100019. [CrossRef]
226. Ouhami, M.; Hafiane, A.; Es-Saady, Y.; El Hajji, M.; Canals, R. Computer Vision, IoT and Data Fusion for Crop Disease Detection Using Machine Learning: A Survey and Ongoing Research. *Remote Sens.* **2021**, *13*, 2486. [CrossRef]
227. Riihimäki, H.; Luoto, M.; Heiskanen, J. Estimating fractional cover of tundra vegetation at multiple scales using unmanned aerial systems and optical satellite data. *Remote Sens. Environ.* **2019**, *224*, 119–132. [CrossRef]
228. Melville, B.; Fisher, A.; Lucieer, A. Ultra-high spatial resolution fractional vegetation cover from unmanned aerial multispectral imagery. *Int. J. Appl. Earth Obs. Geoinf.* **2019**, *78*, 14–24. [CrossRef]
229. Nhamo, L.; Van Dijk, R.; Magidi, J.; Wiberg, D.; Tshikolomo, K. Improving the Accuracy of Remotely Sensed Irrigated Areas Using Post-Classification Enhancement Through UAV Capability. *Remote Sens.* **2018**, *10*, 712. [CrossRef]
230. Gomez Selvaraj, M.; Vergara, A.; Montenegro, F.; Alonso Ruiz, H.; Safari, N.; Raymaekers, D.; Ocimati, W.; Ntamwira, J.; Tits, L.; Omondi, A.B.; et al. Detection of banana plants and their major diseases through aerial images and machine learning methods: A case study in DR Congo and Republic of Benin. *ISPRS J. Photogramm. Remote Sens.* **2020**, *169*, 110–124. [CrossRef]
231. Zhou, X.; Yang, L.; Wang, W.; Chen, B. UAV Data as an Alternative to Field Sampling to Monitor Vineyards Using Machine Learning Based on UAV/Sentinel-2 Data Fusion. *Remote Sens.* **2021**, *13*, 457. [CrossRef]
232. Mokhtari, A.; Ahmadi, A.; Daccache, A.; Drechsler, K. Actual Evapotranspiration from UAV Images: A Multi-Sensor Data

- Fusion Approach. *Remote Sens.* **2021**, *13*, 2315. [[CrossRef](#)]
233. Maimaitijiang, M.; Sagan, V.; Sidike, P.; Daloye, A.M.; Erkbol, H.; Fritschi, F.B. Crop Monitoring Using Satellite/UAV Data Fusion and Machine Learning. *Remote Sens.* **2020**, *12*, 1357. [[CrossRef](#)]
234. Zhao, Y.; Liu, L.; Xie, C.; Wang, R.; Wang, F.; Bu, Y.; Zhang, S. An effective automatic system deployed in agricultural Internet of Things using Multi-Context Fusion Network towards crop disease recognition in the wild. *Appl. Soft Comput.* **2020**, *89*, 106128. [[CrossRef](#)]
235. Lin, Y.C.; Zhou, T.; Wang, T.; Crawford, M.; Ayman, H. New Orthophoto Generation Strategies from UAV and Ground Remote Sensing Platforms for High-Throughput Phenotyping. *Remote Sens.* **2021**, *13*, 860. [[CrossRef](#)]
236. Cucchiaro, S.; Fallu, D.J.; Zhang, H.; Walsh, K.; Van Oost, K.; Brown, A.G.; Tarolli, P. Multiplatform-SfM and TLS Data Fusion for Monitoring Agricultural Terraces in Complex Topographic and Landcover Conditions. *Remote Sens.* **2020**, *12*, 1946. [[CrossRef](#)]
237. Liu, H.; Dahlgren, R.A.; Larsen, R.E.; Devine, S.M.; Roche, L.M.; O' Geen, A.T.; Wong, A.J.; Covello, S.; Jin, Y. Estimating Rangeland Forage Production Using Remote Sensing Data from a Small Unmanned Aerial System (sUAS) and PlanetScope Satellite. *Remote Sens.* **2019**, *11*, 595. [[CrossRef](#)]
238. Lu, S.; Xuan, J.; Zhang, T.; Bai, X.; Tian, F.; Ortega-Farias, S. Effect of the Shadow Pixels on Evapotranspiration Inversion of Vineyard: A High-Resolution UAV-Based and Ground-Based Remote Sensing Measurements. *Remote Sens.* **2022**, *14*, 2259. [[CrossRef](#)]
239. Üstündağ, B. Data Fusion in Agricultural Information Systems. In *Agro-Geoinformatics: Theory and Practice*; Di, L., Üstündağ, B., Eds.; Springer International Publishing: Cham, Switzerland, 2021; pp. 103–141. [[CrossRef](#)]
240. Pantazi, X.; Moshou, D.; Alexandridis, T.; Whetton, R.; Mouazen, A. Wheat yield prediction using machine learning and advanced sensing techniques. *Comput. Electron. Agric.* **2016**, *121*, 57–65. [[CrossRef](#)]
241. Moeckel, T.; Safari, H.; Reddersen, B.; Fricke, T.; Wachendorf, M. Fusion of Ultrasonic and Spectral Sensor Data for Improving the Estimation of Biomass in Grasslands with Heterogeneous Sward Structure. *Remote Sens.* **2017**, *9*, 98. [[CrossRef](#)]
242. De Bernardis, C.; Vicente-Guijalba, F.; Martinez-Marin, T.; Lopez-Sanchez, J.M. Contribution to Real-Time Estimation of Crop Phenological States in a Dynamical Framework Based on NDVI Time Series: Data Fusion With SAR and Temperature. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* **2016**, *9*, 3512–3523. [[CrossRef](#)]
243. Guerrero, A.; De Neve, S.; Mouazen, A.M. Data fusion approach for map-based variable-rate nitrogen fertilization in barley and wheat. *Soil Tillage Res.* **2021**, *205*, 104789. [[CrossRef](#)]

Disclaimer/Publisher's Note: The statements, opinions and data contained in all publications are solely those of the individual author(s) and contributor(s) and not of MDPI and/or the editor(s). MDPI and/or the editor(s) disclaim responsibility for any injury to people or property resulting from any ideas, methods, instructions or products referred to in the content.

8 Conclusioni generali

In conclusione, gli esperimenti condotti nel corso dei tre anni del dottorato di ricerca forniscono delle basi per ulteriori sviluppi nel campo della gestione sostenibile del sistema vigneto, suggerendo nuove prospettive per l'ottimizzazione delle tecniche di analisi di immagine e per l'implementazione e applicazione di modelli predittivi relativi allo stato idrico della vite e alla gestione dell'irrigazione. L'analisi di immagini RGB si conferma efficace nella valutazione rapida e non distruttiva di parametri chiave come il numero di fiori, il numero di acini, il peso di uva prodotta e il peso del legno di potatura; le metodologie proposte colmano alcune lacune relative all'ottimizzazione delle modalità d'acquisizione delle immagini, mettendo in luce come la loro standardizzazione o la valutazione e l'implementazione di parametri fenotipici risultino strumenti efficaci nel rendere più efficiente l'analisi, in contrapposizione all'uso di algoritmi complessi che richiedono l'addestramento per mezzo di ampi set di dati e grandi potenze di calcolo necessarie all'estrazione delle ROI e del dato agronomico.

L'implementazione di modelli predittivi per la stima del potenziale idrico di piante allevate in condizioni caldo-aride mostra premesse interessanti per una gestione più mirata dell'irrigazione, con potenziali benefici sia in termini di resa e qualità dell'uva che di gestione della risorsa idrica. I risultati ottenuti, parallelamente a quelli già presenti in letteratura, confermano la possibilità di stimare indicatori dello stress con un margine d'errore tollerabile se si considera che il monitoraggio in continuo è impraticabile nella maggior parte dei contesti; inoltre, tali modelli risultano strumenti efficaci e flessibili nell'ottica di una gestione basata su sistemi di supporto alle decisioni, che si avvantaggiano dell'uso di grandi quantità di dati facilmente ottenibili in continuo da stazioni meteorologiche e da sensori del suolo. Tuttavia, per massimizzare l'applicabilità e l'affidabilità di tali approcci, è necessario condurre ulteriori ricerche su larga scala, su più varietà e in contesti pedologici differenti.

Inoltre, il confronto dei risultati ottenuti mette in luce come alla base dell'integrazione di questi strumenti nei sistemi produttivi risulta necessario un allineamento di chi opera nella ricerca per rendere possibile ed efficace il confronto dei risultati o la conduzione di meta-analisi indispensabili per migliorare la resilienza delle attività vitivinicole nel contesto di variazioni climatiche sempre meno prevedibili.

9 Ringraziamenti

L'autore desidera esprimere la sua profonda gratitudine a tutte le persone che hanno avuto un ruolo significativo nel suo percorso di conseguimento del dottorato di ricerca in *Biodiversity in Agriculture and Forestry*, ma in particolare:

Ringrazia i coordinatori del corso di dottorato nelle persone del Professor Tiziano Caruso (poi direttore del dipartimento SAAF) e del professor Riccardo Lo Bianco, per la professionalità e la puntualità con la quale lo hanno assistito e orientato.

Ringrazia il Professor Antonino Pisciotta, in qualità di tutor, per il prezioso e costante supporto sia scientifico e tecnico che, forse soprattutto, umano. La sua capacità di stimolare la curiosità e il dubbio, e di incoraggiare a non demordere di fronte a ogni traballante gradino lungo questo percorso, è stata fondamentale.

Ringrazia il Professor Rosario Di Lorenzo per essere stato un mentore eccezionale. La sua saggezza, ironia ed esperienza hanno costituito una bussola utilissima nei momenti più complicati.

Ringrazia il Professor Vittorio Farina per essere stato il primo a credere in lui ancora prima degli anni di dottorato. La sua guida nel fornire i primi rudimentali strumenti della ricerca, unita alla sua presenza come amico e figura paterna, sono inestimabili.

Ringrazia i colleghi Daniele Miccichè, Emanuele Santo Blando, Massimo Ferro, Eugenia Guccione e Lucia Turano per la lealtà, per non aver mai lesinato uno sforzo nell'aiutarlo e per avergli fatto conoscere il significato di lavoro di squadra.

Ringrazia i colleghi Dario Scuderi e Alessandro Carella ed il Dottor Roberto Massenti, vicini fin dall'inizio di questo percorso contraddistinto da ingenuità, entusiasmi, disillusioni, prese di coscienza e maturazione.

Ringrazia il Professor Giuseppe Sortino, il Dottor Giuseppe Gianguzzi e il Dottor Filippo Saletta per tutti gli insegnamenti e i consigli ricevuti, che tuttora costituiscono un punto di riferimento.

Ringrazia il Professor Stefano Barone e il Dottor Albert Comelli, in qualità di co-tutor, per il supporto e per aver reso più ampie le conoscenze che solitamente si attribuiscono ad un agronomo.

Ringrazia il Professor Carlos Manuel Lopes, il Professor Joaquim Miguel Costa, il Dottor Gonçalo Victorino, la Dottorissa Rebeca Mateus Campos e il Dottor Eugenio Degl'Innocenti, membri del gruppo di ricerca in Viticoltura all'Institut Superior de Agronomia di Lisbona, per la considerazione e la fiducia durante mesi di crescita i cui frutti non ha ancora smesso di raccogliere.

Ringrazia infine tutte le persone qui non citate che hanno influito nel conseguimento del dottorato di ricerca, titolo che considera, prima di tutto, una responsabilità.