

UNIVERSITÀ DEGLI STUDI DI PADOVA

DIPARTIMENTO DI AGRONOMIA ANIMALI ALIMENTI RISORSE
NATURALI E AMBIENTE

CORSO DI LAUREA MAGISTRALE IN
SCIENZE E TECNOLOGIE AGRARIE

Ottimizzazione delle tecniche di rilevamento delle piante infestanti da drone

Relatore

Prof. Roberta Masin

Correlatore

Dott. Nebojša Nikolić

Laureando

Domenico Giuseppe Coscia

Matricola n. 2039777

ANNO ACCADEMICO 2022/2023

Riassunto	2
Abstract	3
1. Introduzione	5
1.1 Scouting	7
1.2 Remote sensing in agricoltura di precisione	8
1.3 Remote sensing per il controllo delle infestanti	11
1.4 Obiettivo della tesi	14
2. Materiali e Metodi	15
2.1. Sito di Studio	15
2.2. Rilievo UAS	17
2.3. Metodi di rilevamento delle infestanti	18
2.3.1 Maximum Likelihood Classifier - Classificatore di massima verosimiglianza – MLC	18
2.3.2 Artificial Neural Network – Rete Neurale Artificiale (OpenCV) – ANN	19
2.3.3 Deep Learning – Apprendimento profondo	21
2.3.4. Valutazione dell'accuratezza	24
3. Risultati	25
3.1 Maximum Likelihood Classifier - Classificatore di massima verosimiglianza – MLC	25
3.2 ANN	26
3.3 Deep Learning	27
3.3.1. Campo C1	27
3.3.2. Campo C2	39
4. Discussione	51
5. Conclusioni	53
6. Bibliografia	54
7. Sitografia	60
8. Ringraziamenti	61

Riassunto

Le piante infestanti rappresentano uno dei maggiori problemi delle colture agrarie, in quanto provocano danni alla produzione sia nel breve che nel lungo periodo. Attualmente il controllo delle piante infestanti fa affidamento principalmente sul diserbo chimico e in minor misura sul controllo meccanico, operazioni che comportano elevati costi sia per i prodotti impiegati sia per la manodopera. Infatti, la gestione delle infestanti rappresenta uno dei maggiori costi della produzione agricola. Al fine di ridurre l'impiego di prodotti chimici e rendere più sostenibili le coltivazioni agrarie, è importante rendere il trattamento più efficace grazie all'identificazione delle malerbe a livello di specie e al monitoraggio accurato della loro distribuzione spaziale. Per raggiungere questo obiettivo, l'utilizzo dei droni per il rilevamento delle infestanti sembra essere un metodo promettente, consentendo la creazione di mappe di distribuzione delle infestanti realizzate in maniera automatica da specifici software e algoritmi. La tesi in oggetto si concentra sull'impiego dei droni per il rilevamento delle malerbe e mira a ottimizzare le procedure di identificazione. L'obiettivo principale è dimostrare che tramite l'ottimizzazione del rilevamento da drone è possibile, oltre che identificare la posizione, anche discriminare le infestanti a livello di specie.

La tesi si è focalizzata sull'ottimizzazione della risoluzione delle immagini acquisite tramite drone. Ciò è stato realizzato attraverso voli dedicati e l'acquisizione di fotografie a diverse altitudini, sorvolando campi coltivati di soia e girasole. Le altitudini selezionate sono state 5 m, 7.5 m, 10 m, 12.5 m, 15 m e 30 m, utilizzando il drone DJI Mavic 3 Enterprise equipaggiato con un sensore RGB. Nel tentativo di ottenere la classificazione a livello della specie delle infestanti delle immagini acquisite sono stati testati software (ArcGIS e SAGA) ed algoritmi dedicati quali Reti Neurali Artificiali (ANN), Classificatore delle Massime Verosimiglianze (MLC) e Deep Learning (DL). I risultati hanno dimostrato come non tutti gli algoritmi sono stati in grado di distinguere le specie dalla coltura, nello specifico ANN e MLC. I risultati migliori sono stati ottenuti tramite DL. I risultati prodotti usando questo algoritmo avevano l'accuratezza complessiva (overall accuracy) abbastanza elevata. Per il campo di soia i risultati ad altezza di 5 m erano pari a 94%, a 7,5 m pari a 79%, a 10 m pari a 80,8%, a 12,5 l'accuratezza era di 83%, a 15 m 88% e a 30 m 85,5%. Per quanto riguarda il campo di girasole l'accuratezza complessiva era di 98,8% a 5 m, 90,2% a 7,5 m, 86,1% a 10 m, 77,3% a 12,5 m, 91,4% a 15 m. Data la limitata accuratezza nella classificazione a 30 metri, è stata implementata una classificazione specifica per il campo di girasole, basata sulla distinzione tra specie a foglia larga e specie a foglia stretta. Questa modifica ha portato a un miglioramento significativo, con un'accuratezza complessiva del 96,2%. I risultati indicano che ottimizzando la risoluzione delle immagini ed applicando i software e gli algoritmi all'avanguardia, è possibile ottenere la

classificazione a livello di specie delle malerbe. L'accuratezza ottenuta relativa alla discriminazione a livello di specie nella stragrande maggioranza delle foto oggetto di tesi conferma la possibilità di utilizzo di tali tecnologie per i rilievi malerbologici e per la creazione di mappe di prescrizione, che offrirebbero informazioni relative sia alla posizione delle malerbe nel campo per la distribuzione sito-specifica, operata da macchinari, ma anche quelle relative all'approccio più adeguato come ad esempio la scelta degli erbicidi da applicare. La metodologia proposta in questa tesi, confermata dai risultati ottenuti, potrebbe portare ad un notevole aumento dell'efficacia delle operazioni di diserbo, riducendo, i costi relativi al controllo, salvaguardando l'ambiente.

Abstract

Weeds pose significant challenges in agricultural crop production, causing substantial short- and long-term damage. Today, weed control heavily relies on chemical and, to a lesser extent, mechanical interventions, incurring high costs for both weed control products and labour. Indeed, weed management stands out as one of the most substantial expenses in agricultural production. To enhance the sustainability of agricultural crop production by minimizing chemical usage, it becomes imperative to increase the effectiveness of treatments through precise species-level identification and accurate monitoring of spatial distribution.

The utilization of drones for weed detection emerges as a promising method, offering the potential to create automated weed distribution maps using specialized software and algorithms. This thesis concentrates on optimizing the procedures for weed detection through drones, with the primary goal of demonstrating that by refining weed detection from drones, not only can the exact location be identified, but also weeds can be discriminated at the species level.

The central focus of this thesis revolves around enhancing the resolution of drone-acquired images. This was achieved through dedicated flights and the acquisition of images at various altitudes over soybean and sunflower crop fields. Altitudes of 5 m, 7.5 m, 10 m, 12.5 m, 15 m, and 30 m were chosen, utilizing the DJI Mavic 3 Enterprise drone equipped with an RGB sensor.

In an effort to achieve species-level classification of weeds from the acquired images, various software tools (ArcGIS and SAGA) and dedicated algorithms such as Artificial Neural Networks (ANN), Maximum Likelihood Classifier (MLC), and Deep Learning (DL) were tested. Results indicated that not all algorithms could effectively distinguish weed species from the crops, specifically ANN and MLC. The most promising results were obtained through DL, displaying high

overall accuracy. For the soybean field, the accuracy at 5 m was 94%, at 7.5 m it was 79%, at 10 m it was 80.8%, at 12.5 m the accuracy was 83%, at 15 m it reached 88%, and at 30 m, it was 85.5%. Concerning the sunflower field, the overall accuracy was 98.8% at 5 m, 90.2% at 7.5 m, 86.1% at 10 m, 77.3% at 12.5 m, and 91.4% at 15 m. Recognizing the limited accuracy at 30 m, a specific classification was implemented for the sunflower field, focusing on the differentiation between broadleaf and narrowleaf species. This modification resulted in a significant improvement, achieving an overall accuracy of 96.2%. The outcomes suggest that by optimizing image resolution and employing advanced software and algorithms, species-level classification of weeds is achievable. The accuracy achieved in species-level discrimination across the extensive dataset covered in this thesis reaffirms the feasibility of using these technologies for weed surveys. Implementing this methodology for weed classification could enable the creation of high-precision prescription maps, providing information not only on weed location for site-specific distribution through machinery like tractors or robots with appropriate weed bars but also guiding the selection of herbicides and their targeted application. The proposed methodology, supported by the obtained results, holds the potential to significantly enhance the efficiency of weed control operations, reducing associated costs while preserving the environment.

1. Introduzione

Fin dall'antichità, gli agricoltori hanno dovuto compiere enormi sforzi al fine di controllare le piante infestanti negli agroecosistemi. Ad oggi, nonostante l'enorme evoluzione di tutte le tecniche colturali, le piante infestanti risultano essere una delle principali problematiche dell'agricoltura mondiale. Con il termine malerba o pianta infestante, infatti, si intende tutte le specie che vivono in zone in cui non dovrebbero, interferendo con le piante coltivate determinando perdite di produzione. La competizione delle piante infestanti riguarda principalmente risorse trofiche come l'acqua, spazio, luce e sostanze nutritive. Alcune specie sono in grado di rilasciare segnali chimici, come ad esempio le sostanze allelopatiche, che interferiscono con lo sviluppo delle piante agrarie. (Zohaib et al., 2016).

Le piante infestanti possono interagire con altri componenti biologici dell'ambiente, fornendo rifugio a parassiti delle piante come insetti, funghi e batteri in grado di danneggiare le colture vicine. (Esposito et al., 2021). Ad esempio, l'avena selvatica (*Avena fatua* L.), può ospitare gli agenti eziologici che causano l'oidio in colture come il frumento (*Triticum aestivum* L.) e l'orzo (*Hordeum vulgare* L.). (Eshed, 1975). Le piante infestanti possono contaminare i prodotti alimentari, sia freschi che trasformati, alterandone la qualità; infatti, i residui di piante infestanti possono causare sapori sgradevoli e, in alcuni casi, possono essere tossici per l'uomo e gli animali. (Esposito et al., 2021). Nonostante tutte le misure adoperate, come mezzi agronomici, meccanici, colturali, fisici e chimici, la perdita causata dalla competitività delle piante infestanti a livello mondiale è pari al 13,2%. (Zoschke, A. e Quadranti, 2002).

Se non si dovessero mettere in atto soluzioni per il contenimento, le perdite di produzione a livello mondiale potrebbero raggiungere il 34% (Oerke, 2006). Zanin stima per l'Italia una perdita: 23-30% nel grano, 33,3% nella soia, 33,9-37,5% nel mais e 50,2% per la barbabietola (Zanin et al., 1992). Quindi ad oggi l'agricoltura contemporanea non può fare a meno di gestire le piante infestanti.

I diserbanti nascono nella metà del XX secolo, allo scopo di rendere il controllo delle infestanti più efficace e più economico nei sistemi colturali in cui gli altri metodi non chimici si dimostravano poco efficaci. Tuttavia l'uso reiterato dei diserbanti ha generato diversi problemi, sia di tipo agronomico che ambientale (Zanin et al., 2011), come le popolazioni di piante resistenti e l'inquinamento delle falde acquifere (Rüegg et al., 2007). In merito a tali conseguenze, l'attenzione dell'opinione pubblica è aumentata riguardo ai rischi ambientali e per la salute, legata ai residui dei diserbanti. Questo ha stimolato l'Unione Europea alla ricerca e allo sviluppo di strategie di controllo che hanno come obiettivo quello di ridurre l'impiego di prodotti chimici.

Nel novembre del 2009 il parlamento europeo ha emanato la direttiva 2009/128/CE che istituisce un quadro per l'azione comunitaria ai fini dell'utilizzo sostenibile dei pesticidi, al fine di proteggere la

salute, sia dei lavoratori agricoli che dei consumatori e al contempo ridurre i costi di produzione (European Parliament, 2009). Per l'attuazione della direttiva 2009/128/CE sono stati definiti i Piani di Azione Nazionali (PAN), che stabiliscono gli obiettivi, le misure, i tempi e gli indicatori per la riduzione dei rischi e degli impatti che derivano dall'uso dei prodotti fitosanitari. Il PAN prevede l'adozione di prodotti maggiormente sostenibili al fine di ridurre l'impatto di tali prodotti negli agroecosistemi. A questo punto diventa cruciale l'esigenza di sviluppare sistemi di gestione delle infestanti economicamente vantaggiosi, impiegando minor quantità di erbicidi ma garantendo un'alta efficacia.

Secondo alcuni studi della FAO (Food and Agriculture Organization of the United Nations), la popolazione mondiale è destinata ad aumentare di oltre un terzo entro il 2050, pertanto la richiesta alimentare aumenterà nettamente (Lutz & Kc, 2010). In questo scenario, gli agricoltori si ritrovano ad affrontare una situazione in cui è cruciale aumentare le produzioni, pur avendo a disposizione la stessa superficie agricola. È importante quindi adottare sistemi che permettono il controllo delle infestanti in modo economico e sostenibile.

Una delle strategie più valide è l'Integrated Weed Management, strategia che si avvale di una combinazione di misure agronomiche, biologiche, colturali e chimiche che consentono la gestione delle infestanti in modo economicamente efficiente, rispettoso dell'ambiente e socialmente accettabile. L'approccio IWM si concentra sul controllo vero e proprio delle infestanti, ciò ne consegue che è necessario conoscere a fondo le caratteristiche biologiche di queste ultime al fine di effettuare interventi mirati. Gli interventi sulle malerbe infestanti mirano a mantenere un equilibrio tra piante coltivate e infestanti, adottando pratiche come la rotazione colturale, e a ridurre la quantità di semi e organi di propagazione vegetativa nel terreno. Per ridurre gli apporti di semi, si possono adottare misure come la prevenzione della diffusione accidentale e la disseminazione naturale, lavorazioni adeguate del terreno e la falsa semina (Chauhan, 2020; Chikowo et al., 2009; Zanin et al., 2011).

Il controllo delle malerbe si avvale di diversi metodi (meccanici, chimici, fisici e biologici) con lo scopo di apporre una bassa pressione di selezione che limita lo sviluppo e la crescita delle malerbe. L'IWM è un approccio promettente per il controllo delle malerbe, ma ha incontrato diverse difficoltà nell'adozione in quanto gli agricoltori sostengono che si tratti di un sistema che richiede continuamente il supporto tecnico e al contempo ritenuto complesso ed oneroso (Zanin et al., 2011). Negli ultimi anni l'agricoltura di precisione, tramite l'adozione di strumenti come il GPS, sistemi di telerilevamento, GIS e sistemi di controllo delle macchine, ha contribuito enormemente all'ottimizzazione della produzione agricola, prendendo in esame le reali necessità dei campi agricoli. Infatti l'agricoltura di precisione utilizza tecnologie che permettono di applicare gli input colturali in

modo variabile, in base alle proprietà chimico-fisiche e biologiche del suolo, con l'obiettivo di migliorare le performance della coltura riducendo al contempo i costi colturali ed ambientali (Godwin et al., 2003).

La distribuzione localizzata di diserbanti, esclusivamente laddove presenti le infestanti, permette di ridurre i costi dei trattamenti. Questo è importante in quanto in Europa, gli erbicidi rappresentano il 40% del costo totale di tutti i prodotti chimici impiegati in agricoltura (Mattivi et al., 2021). Si tratta di un valore significativo, poiché indica che gli erbicidi ricoprono un costo importante per gli agricoltori. L'agricoltura di precisione applicata alla gestione delle infestanti è nota come Site Specific Weed Management (SSWM). Si tratta di una delle pratiche più promettenti per rendere più sostenibile la gestione delle infestanti.

Questo approccio può portare vantaggi ambientali ed economici, tra cui:

- Riduzione delle quantità di erbicida utilizzate: la distribuzione localizzata di erbicidi consente di applicare solo la quantità necessaria per controllare le infestanti, riducendo così l'inquinamento ambientale e il rischio di resistenza agli erbicidi;
- Riduzione del tempo di lavoro: la distribuzione localizzata di erbicidi richiede meno tempo e manodopera rispetto ai trattamenti tradizionali, riducendo così i costi di produzione;
- Riduzione della compattazione del suolo: l'utilizzo di mezzi irroratrici più leggeri consente di ridurre la compattazione del suolo, migliorando la sua struttura e la sua permeabilità;

Il Site Specific Weed Management (SSWM) è una tecnica di gestione delle infestanti che tiene conto della distribuzione spaziale delle infestanti per la creazione di mappe di applicazione degli erbicidi (Huang et al., 2018; López-Granados et al., 2016; Peña et al., 2013). La distribuzione in campo delle infestanti viene stimata attraverso l'operazione di scouting.

1.1 Scouting

Il processo di scouting delle infestanti è un processo tecnico e metodico utilizzato in ambito agricolo per identificare, monitorare e valutare le popolazioni di piante infestanti presenti in un campo coltivato. Gli agronomi o gli operatori agricoli impegnati in questa attività adottano approcci precisi per raccogliere dati dettagliati che risulteranno essere fondamentali per l'adozione di strategie di gestione delle infestanti. Il rilevamento delle infestanti avviene attraverso l'ispezione visiva delle piante, con particolare attenzione ai dettagli morfologici, al loro stadio fenologico e alla densità nelle diverse zone del campo. Durante le ispezioni, gli operatori utilizzano strumenti come schede di rilevamento, tabelle di conteggio e software installati talvolta su PC o smartphone al fine di registrare dati dettagliati su ciascuna specie di pianta infestante. Tali software talvolta permettono tramite GPS

la localizzazione dell'infestazione. Ad oggi, la valutazione della distribuzione delle infestanti è effettuata prevalentemente tramite perlustrazione ed osservazione del campo. Tale metodo però si rivela oneroso sia in termini di tempo che di risorse, oltre essere poco affidabile (Hanzlik & Gerowitt, 2016).

L'impiego di tecnologie avanzate, come droni o immagini satellitari ad alta risoluzione, possono facilitare la mappatura delle infestazioni, riducendo notevolmente i tempi. L'analisi delle immagini può anche essere supportata da algoritmi di elaborazione dati, consentendo una valutazione quantitativa della distribuzione spaziale delle infestanti per la generazione di mappe.

Anche il ricorso a modelli predittivi basati su dati storici, meteorologici e ambientali consente di anticipare la dinamica delle popolazioni delle piante infestanti nel tempo.

L'approccio tecnico dello scouting è fondamentale per una gestione sostenibile delle infestanti. Sulla base dei dati raccolti si pianificano operazioni tempestive ed efficienti affinché tali piante siano controllate, contribuendo così a ottimizzare la resa delle colture e a ridurre l'impatto ambientale delle pratiche di diserbo, trattando solo le zone in cui risulta necessario.

Come alcuni studi sostengono, le popolazioni di malerbe si ritrovano spesso a macchie nei pressi dei bordi o strisce tra le file o nelle file (Cardina et al., 1997; Gerhards & Christensen, 2003; Marshall, 1988), pertanto, l'impiego di sensori remoti per l'acquisizione dei dati, può rivelarsi un'opportunità per la mappatura delle infestanti nei campi coltivati (Kim et al., 2019; Tamouridou et al., 2017). Oltre a questo l'impiego di questi sensori e degli algoritmi per il riconoscimento delle piante infestanti, potrebbe sostituire lo scouting tradizionale, facilitando la creazione delle mappe di prescrizione e aumentandone la precisione (Nikolić et al., 2021)

1.2 Remote sensing in agricoltura di precisione

Nell'ambito dell'agricoltura di precisione, si fa ampio ricorso a diverse piattaforme di remote sensing, che comprendono dispositivi portatili, aerei e satelliti. Attraverso il remote sensing si acquisiscono dati qualitativi e quantitativi di oggetti che di solito si trovano a distanze considerevoli dall'osservatore. Queste distanze possono variare da pochi metri fino a centinaia di chilometri, come nel caso delle osservazioni effettuate dai satelliti. Questi strumenti consentono di raccogliere dati con varie risoluzioni spaziali, temporali e spettrali, offrendo un quadro dettagliato delle condizioni delle coltivazioni e dell'ambiente circostante.

La scelta della soluzione più adeguata per l'agricoltura di precisione (AP) è influenzata da una serie di fattori, che includono gli obiettivi di gestione, le tipologie di coltivazioni e le loro fasi di sviluppo, le dimensioni del campo coltivato e la capacità delle macchine agricole di regolare gli input, quali

fertilizzanti, diserbanti e irrigazione. Ad oggi vengono utilizzate varie piattaforme di remote sensing, tra cui dispositivi portatili, aerei e satelliti, che possono essere utilizzate per raccogliere dati con diverse risoluzioni spaziali, temporali e spettrali. Ad esempio, per il rilevamento delle piante infestanti nelle colture, è necessario disporre di dati che abbiano una risoluzione spaziale molto elevata ($< 0,1$ m), i quali permettono di differenziare le infestanti dalle piante coltivate (Gnädinger & Schmidhalter, 2017; Varela et al., 2018; Z. Yu et al., 2013), mentre per la stima della resa del raccolto la risoluzione spaziale è maggiore (1–3 m) (Fernandez-Ordonez & Soria-Ruiz, 2017);

Le immagini multispettrali si rivelano utili per valutare i modelli di salute delle colture, aspetto che le immagini visibili (VIS) non sono in grado di rilevare (Yao et al., 2017), mentre le immagini termiche svolgono un ruolo significativo nel rilevare la pressione dei parassiti (Calderón et al., 2013; Khanal et al., 2017), monitorare l'umidità del suolo (Hassan-Esfahani et al., 2017), e identificare lo stress idrico delle colture (Park et al., 2017), aspetti che non possono essere rilevate dall'occhio umano. I sistemi di telerilevamento impiegati nell'Agricoltura di Precisione (PA) e nell'agricoltura in generale possono essere suddivisi in base a due criteri principali: in base alla piattaforma su cui risiedono i sensori (satelliti, veicoli aerei con pilota e senza pilota come gli UAS e dispositivi terrestri come macchine agricole) e in base alla tipologia di sensore. Le piattaforme terrestri possono essere distinte inoltre in portatili, indipendenti sul campo e montate su trattori o altre macchine agricole. I sistemi terrestri, noti anche come sistemi di telerilevamento prossimale, assumono tale denominazione poiché operano in prossimità della superficie target, che può essere la superficie terrestre o la vegetazione coltivata. Ciò li distingue dalla modalità di operare delle piattaforme aeree o satellitari, che raccolgono dati da distanze maggiori e sono identificati come sistemi di telerilevamento remoti (Figura 1).




Figura 1. Satellite Sentinel-2 in orbita

I sensori di telerilevamento registrano i dati in formato analogico, come nel caso delle fotografie aeree catturate da un aereo dotato di cinepresa, oppure in formato digitale, rappresentato da una matrice bidimensionale di pixel che memorizzano i valori di radiazione elettromagnetica (EMR) rilevati da fotocamere o sensori digitali montati su satellite o aeromobile, la cui adozione è attualmente più diffusa). Questi sensori si presentano in due varianti: passivi e attivi. I sensori passivi di telerilevamento, ossia non dotati di una propria sorgente luminosa, registrano la radiazione riflessa o emessa dagli oggetti, catturando quindi l'EMR naturale. D'altra parte, i sensori attivi emettono la propria radiazione, interagendo con l'oggetto di studio e rilevandone il riflesso attraverso lo strumento di misurazione (Omia et al., 2023). Un esempio concreto è rappresentato dai sistemi di applicazione a dose variabile di fertilizzanti, come Green Seeker e Crop Circle (Figura 2 e 3).



Figura 2. GreenSeeker posizionato nella parte anteriore del trattore al fine di variare la dose di fertilizzante



Figura 3. Modalità di funzionamento di Crop circle

1.3 Remote sensing per il controllo delle infestanti

Nella SSWM ci si può orientare verso sistemi di rilevazione a distanza delle infestanti, cioè tramite il telerilevamento da piattaforma aerea o satellitare, oppure verso sistemi di identificazione a distanza ravvicinata. Uno dei metodi più semplici, per mappare le infestanti, può essere quello del rilievo manuale in campo utilizzando veicoli dotati di GPS, delineando le aree ad alta infestazione. È stato osservato che l'autocorrelazione spaziale per la maggior parte delle specie infestanti si estende per brevi distanze, cioè gli intervalli del semi-variogramma sono generalmente piccoli, dell'ordine di 30-50 m (Blanco-Moreno et al., 2006; Nordmeyer, 2009). Ciò è dovuto principalmente alla loro distribuzione a macchie all'interno del campo, che è collegato a sua volta alla dispersione del seme od ai meccanismi di propagazione vegetativa, nonché a fattori di gestione come direzione delle lavorazioni e alle proprietà del suolo (Castaldi et al., 2017). Pertanto, al fine di ottenere un semivariogramma affidabile nel descrivere l'autocorrelazione spaziale delle infestanti, è necessario raccogliere un consistente numero di campioni sull'intero campo. Poiché il costo dello scouting manuale per la produzione di mappe può essere proibitivo, un sistema automatico di mappatura delle infestanti potrebbe essere la soluzione ideale. L'utilizzo del telerilevamento per catturare immagini ad elevata risoluzione spaziale, al fine di ottenere in modo tempestivo informazioni sulla distribuzione spaziale delle infestanti, risulta l'unico approccio praticabile (Thorp & Tian, 2004).

Ad oggi però, nonostante i notevoli progressi raggiunti nella risoluzione spaziale, spettrale e temporale dei sensori satellitari, l'utilizzo delle immagini satellitari rimane limitato nel contesto della produzione agricola commerciale. A causa della loro risoluzione spaziale (da 30 a 0,2 metri), la restrizione nella flessibilità delle soluzioni di imaging su richiesta, i costi elevati associati, le limitazioni imposte dalla copertura nuvolosa e la mancanza di infrastrutture automatizzate o consolidate per l'analisi e l'applicazione delle immagini, sono fattori chiave che incidono sull'adozione su larga scala delle immagini satellitari nell'ambito dell'agricoltura di precisione (Sisodia et al., 2014). Ottenere una scansione satellitare costante o frequente durante una stagione di crescita delle colture può risultare problematico a causa della presenza di copertura nuvolosa e di altre limitazioni o incertezze legate alla piattaforma del sensore, come ad esempio il periodo di rivisitazione da parte del satellite (Primicerio et al., 2012).

Tali limitazioni hanno suscitato un crescente interesse per le tecniche di telerilevamento prossimale attraverso sensori montati su piattaforme terrestri e impiego degli UAS. I sensori installati su macchinari agricoli come trattori e irroratrici allo scopo di rilevare le infestanti possono essere suddivisi in due categorie principali, sensori basati sulla diversa risposta spettrale delle infestanti rispetto al suolo e ai residui colturali e sensori dotati di capacità di "visione artificiale" in grado di

identificare le infestanti in base alla loro forma. I sensori basati sulla risposta spettrale, generalmente multispettrali con poche bande, permettono la discriminazione delle infestanti dal suolo. Tuttavia, essi non sono adatti per l'uso in presenza della coltura a causa della somiglianza nella risposta spettrale di entrambe le specie. Questi sensori trovano applicazione in operazioni di diserbo in pre-semina su terreni nudi e coltivazioni a filare (Castaldi et al., 2017). Un esempio di tecnologia per il diserbo, montato direttamente sull'irroratrice, è il Weedseeker di Trimble (Sunnyvale, CA, USA). Questo sistema utilizza una sorgente di luce interna per illuminare il bersaglio. Un sensore rileva la luce riflessa dal suolo e dalla vegetazione, i dati di riflettanza vengono utilizzati per calcolare l'NDVI (un indice di vegetazione), e un'informazione viene inviata a un'elettrovalvola che si attiva in presenza di vegetazione. Un vantaggio di questo sistema è la sua indipendenza dalle condizioni di illuminazione ambientale, consentendo il suo impiego anche di notte (Figura 4).



Figura 4. Weedseeker in funzione

D'altra parte, i sistemi a "visione artificiale" sono stati sviluppati per rilevare le infestanti anche in presenza della coltura. Questi utilizzano telecamere montate direttamente sui macchinari per acquisire immagini digitali, successivamente elaborate per discriminare la vegetazione dal terreno e distinguere le infestanti dalla coltura. Tuttavia, a causa della loro elevata risoluzione spaziale, richiedono elaborazioni complesse e comportano costi significativi, motivo per cui non sono ancora ampiamente disponibili sul mercato per l'applicazione specifica del diserbo. I droni hanno ricevuto un riconoscimento significativo in quanto sono stati inclusi nella lista delle dieci innovazioni tecnologiche destinate a diventare fondamentali per il futuro, stilata dal Massachusetts Institute of Technology (Anderson, 2014). Queste sofisticate apparecchiature possono essere dotate di una gamma diversificata di sensori, che spaziano dalle tradizionali telecamere RGB ai sensori multi ed

iperspettrali. La categorizzazione dei droni avviene principalmente in due macrocategorie: quelli ad ala fissa e quelli multirottore, quest'ultimi suddivisi in base al numero di motori, quali quadricotteri, esacotteri, optocotteri, e così via (Figura 5 e 6).



Figura 5. Drone ad ala fissa



Figura 6. Droni multirottore di dimensioni differenti

L'utilizzo dei droni per la mappatura delle infestanti costituisce un'alternativa promettente ai sistemi di rilevamento in tempo reale, come il precedentemente menzionato Weedseeker, e soprattutto alle altre piattaforme di telerilevamento da remoto, quali aerei o satelliti. Rispetto all'impiego di sistemi per l'identificazione delle infestanti in tempo reale, nonché agli aerei e ai satelliti, l'utilizzo dei droni presenta diversi vantaggi, tra cui la capacità di ottenere immagini con un'elevata risoluzione spaziale, la possibilità di effettuare acquisizioni in tempi rapidi rispetto al momento del trattamento e la capacità di effettuare acquisizioni anche in presenza di condizioni atmosferiche non favorevoli. L'elevata risoluzione spaziale delle immagini ottenibili dai droni, inferiore a 5 cm, li posiziona come strumenti ad alto potenziale nell'ambito dell'agricoltura di precisione per una gestione sostenibile delle infestanti mediante l'applicazione della tecnica della SSWM in quanto quest'ultima richiede informazioni precise sulla distribuzione spaziale delle malerbe (Hamouz et al., 2014), dato che spesso sono distribuite in piccole "chiazze". L'ottenimento di mappe relative alla distribuzione spaziale delle infestanti attraverso l'uso di immagini acquisite da droni è possibile mediante l'applicazione di diverse tecniche di elaborazione.

Ad esempio mappe dettagliate sulla distribuzione spaziale delle infestanti sono state prodotte attraverso l'impiego di una classificazione supervisionata SVM (Pelosi et al., 2015), mediante l'utilizzo di una tecnica di classificazione basata sugli oggetti (López-Granados et al., 2016; Peña et al., 2013; Torres-Sánchez et al., 2014), ma anche impiegando la tecnica del deep learning (Hasan et al., 2021) e delle ANN (Mattivi et al., 2021).

Va sottolineato però che l'impiego di UAS comporta l'acquisizione di una licenza per droni (Ali et al., 2017), richiede le conoscenze adeguate all'utilizzo di software specializzati per l'analisi dei dati e delle immagini, processi che possono risultare complessi e che richiedono talvolta tempi considerevoli (Khanal et al., 2018). Tuttavia, anche se la capacità di utilizzo di tali software, uniti ai costi relativi all'acquisto o utilizzo degli UAS, possano rappresentare ad oggi dei limiti per gli agricoltori, è ammissibile che i benefici a lungo termine giustifichino tali limitazioni, considerando inoltre lo sviluppo rapido e continuo di tali tecnologie sempre più alla portata di tutti e i potenziali risparmi nei costi di produzione (Abdullahi et al., 2015; Honrado et al., 2017).

1.4 Obiettivo della tesi

La ricerca è stata condotta con l'obiettivo di valutare l'efficacia e l'applicabilità del remote sensing nel rilevamento delle infestanti nelle coltivazioni di soia e girasole, mediante l'utilizzo di droni. L'obiettivo principale era quello di ricercare l'altezza di volo ottimale per il rilevamento delle infestanti, in grado di aiutare a sviluppare un sistema per la gestione sostenibile delle infestanti, basato sulle tecnologie proprie dell'agricoltura di precisione, al fine di ottimizzare il diserbo. La valutazione di tale sistema è stata condotta attraverso metodologie sperimentali appropriate, con l'obiettivo di quantificare i potenziali vantaggi in termini agronomici. Le attività di ricerca si sono focalizzate su vari aspetti, tra cui:

- La valutazione quantitativa e qualitativa delle informazioni ottenute tramite le immagini RGB acquisite a diverse altezze di volo;
- La classificazione delle immagini, sia in maniera supervisionata che automatica, assegnando a ciascun pixel una classe (Tabella 2);
- Individuare l'altezza di volo in cui le classificazioni risultano più efficaci;
- Individuare accorgimenti tecnici utili per ottimizzare l'attività di rilevamento, al fine di renderla più efficiente.

2. Materiali e Metodi

2.1. Sito di Studio

I siti di studio sono due campi adiacenti di girasole e soia, in località Pozzoveggiani (PD), situati a 12 mt slm nella Pianura alluvionale della Pianura Padana, all'interno del sistema idrografico della Laguna di Venezia. Entrambi i campi fanno parte dell'Azienda Sperimentale "Lucio Toniolo" dell'Università di Padova. La topografia dei siti di studio è essenzialmente pianeggiante.



Figura 7. Siti di studio nella regione del Veneto



Figura 8. Siti di studio: in giallo il campo C1 e in arancione il campo C2, Pozzoveggiani (PD)

Il campo C1, con coordinate $45^{\circ}20'39.2''\text{N}$ $11^{\circ}54'34.5''\text{E}$ e una superficie di circa 12000 m^2 , era coltivato a soia (*Glycine max*), mentre il campo C2, con coordinate $45^{\circ}20'39.1''\text{N}$ $11^{\circ}54'36.0''\text{E}$ e con un'area di circa 11200 m^2 , era coltivato a girasole (*Helianthus annuus*). Relativamente al campo C1, alla data del volo, le piante di soia si presentavano allo stadio di secondo nodo (stadio V2) e infestate principalmente da *Portulaca oleracea* L. (Portulaca), a seguire *Solanum nigrum* L. (Morella comune), *Persicaria maculosa* L. (Poligono persicaria) e *Sorghum halepense* L. (Sorghetta). Per quanto riguarda il campo C2, alla data del volo, le piante di girasole si trovavano allo stadio di due paia di foglie (B3-B4) e il campo era infestato prevalentemente da *Sorghum halepense* L. (Sorghetta) e in misura minore da *Solanum nigrum* L. (Morella comune), *Persicaria maculosa* L. (Poligono persicaria) e *Convolvulus arvensis* L. (Convolvolo). Per scopi sperimentali, in entrambi i campi, non erano stati effettuati interventi di diserbo fino alla data del volo.

2.2. Rilievo UAS

Il rilievo aereo è stato condotto in data 23 giugno 2023, utilizzando un drone DJI Mavic 3 Enterprise (Figura 9), con peso massimo al decollo di 1050g e un'autonomia di volo massima di 45 minuti. Il drone era dotato di un sensore RGB (che acquisisce la luce nello spettro visibile) ottico CMOS da 4/3" con lunghezza focale di 24 mm e risoluzione di 20 MP (5280×3956 pixel) e HFOV di 84°.



Figura 9. Drone DJI Mavic 3 Enterprise pronto al decollo nel campo C1

Il piano di volo è stato precedentemente impostato nel software del drone, in modo da permettergli di raggiungere l'altitudine e il grado di sovrapposizione richiesto. Sono stati realizzati diversi voli e le immagini sono state acquisite a 5 m, 7.5 m, 10 m, 12.5 m, 15 m e 30 m. I rilievi aerei sono stati effettuati sia per il campo C1 che per il campo C2. Le immagini scattate a 15 m e a 30 m sono state successivamente elaborate per la realizzazione di ortomosaici. Per l'analisi spaziale, gli ortomosaici sono stati georeferenziati utilizzando la mappa base satellitare Bing Map, che è stata caricata in QGIS. Le coordinate GPS del set di dati fotografici sono state utilizzate per allineare gli ortomosaici alla mappa base. Il sistema di riferimento delle coordinate geografiche utilizzato è WGS84 UTM 32N. Le ortofoto che sono state ottenute sono state utilizzate come base per le intere analisi, fornendo i dati raster necessari per tutti i calcoli.

Tabella 1. Durata volo e numero immagini per ciascun volo nei campi C1 e C2

Campo	Altitudine di volo (m)	Durata del volo (min)	# Immagini	Dimensione pixel (mm)
Soia (C1)	15	15:10	469	19
	30	8:05	142	30
Girasole (C2)	15	14:30	428	19
	30	7:25	117	30

2.3. Metodi di rilevamento delle infestanti

Per le operazioni di classificazione delle piante infestanti, è stato utilizzato il software open source SAGA GIS (versione 9.1.2) e ArcGIS Pro (versione 3.1).

2.3.1 *Maximum Likelihood Classifier - Classificatore di massima verosimiglianza – MLC*

Il primo metodo utilizza un algoritmo di classificazione di massima verosimiglianza (MLC), si tratta di un metodo comune per classificare i dati di telerilevamento (Bolstad & Lillesand, 1991; Otukey & Blaschke, 2010). MLC è stato utilizzato diffusamente per rilevare le piante infestanti (de Castro et al., 2012; Tamouridou et al., 2017). La MLC si basa su due principi: che le celle di ogni campione di classe nello spazio multidimensionale siano normalmente distribuite e sul teorema di Bayes del processo decisionale. Tenendo conto di questi due principi, per ogni cella corrispondente a un singolo pixel, viene calcolata la probabilità statistica per ogni classe, per determinare l'associazione di ogni singola cella a una classe specifica. L'MLC rappresenta una classificazione in cui un pixel con la massima verosimiglianza viene classificato nella classe corrispondente (Sisodia et al., 2014; Sun et al., 2013). L'MLC richiede come dati di input un file raster e una classificazione campione con classi definite come dati di input, in base ai quali produrrà la classificazione a massima verosimiglianza (Conrad et al., 2015; Sisodia et al., 2014). La classificazione è stata eseguita utilizzando lo strumento Supervised Classification for Grids di SAGA GIS. Il set di addestramento è stato creato manualmente dall'analisi dell'ortofoto, selezionando regioni di interesse (ROI) per ciascuna classe: coltura, le diverse specie di infestanti e terreno nudo. Le ROI sono state selezionate in modo casuale su tutto l'ortomosaico per rappresentare tutte le possibili condizioni del campo. Il set di addestramento finale è costituito da diverse ROI prelevate casualmente all'interno del campo. Successivamente, la mappa ottenuta è stata sottoposta a un processo di filtraggio tramite l'applicazione dell'apertura morfologica. Tale processo aveva lo scopo di rimuovere i pixel isolati e indesiderati al fine di migliorare la continuità spaziale della mappa. L'apertura morfologica rappresenta un processo in cui un'immagine subisce prima un'erosione e poi una dilatazione consecutive (Said et al., 2016). L'erosione rimuove le piccole aree, mentre la dilatazione le ripristina. L'apertura morfologica è stata eseguita utilizzando lo strumento Filtro Morfologico di OpenCV. Il processo è rappresentato nella figura 10.

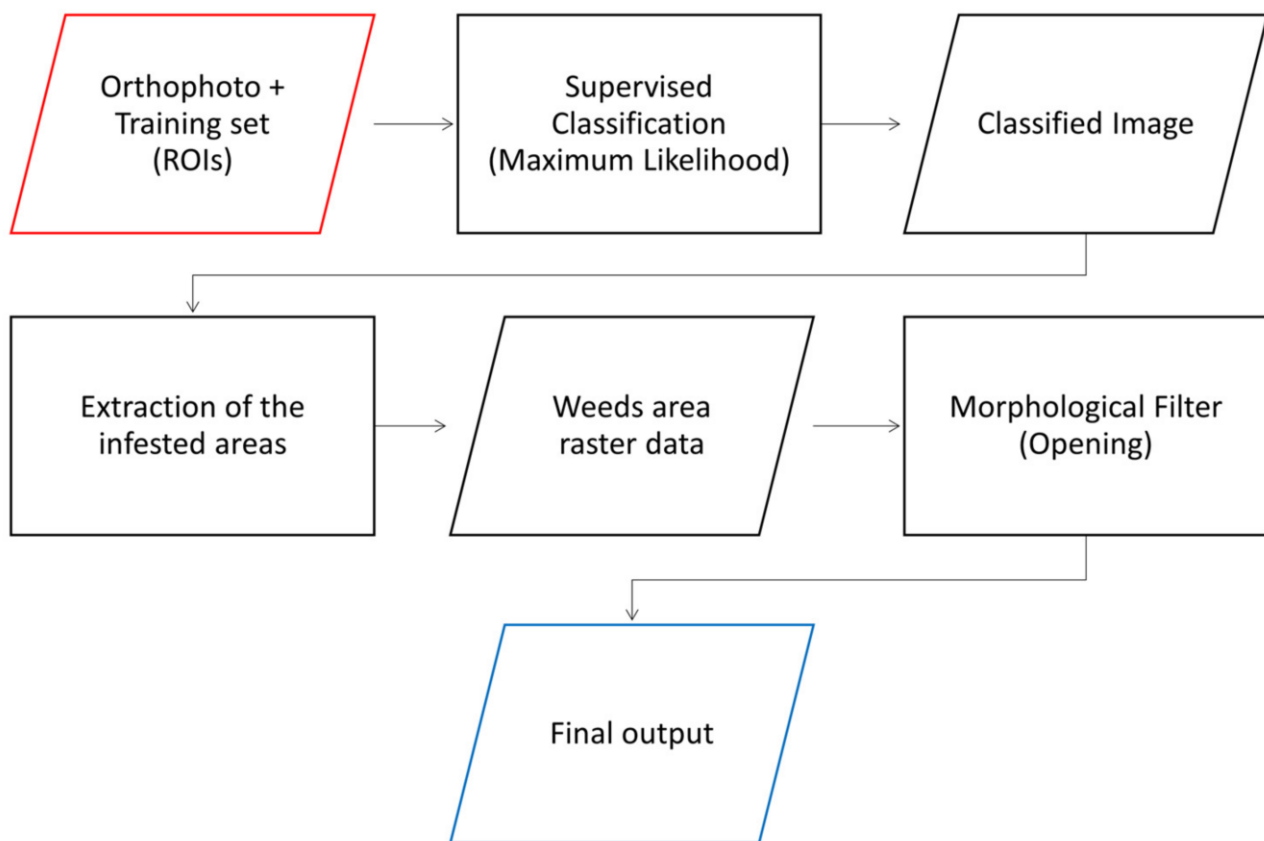


Figura 10. Flusso di lavoro per il metodo di mappatura delle infestanti con classificazione della massima verosimiglianza

2.3.2 Artificial Neural Network – Rete Neurale Artificiale (OpenCV) – ANN

Il secondo metodo utilizza modelli di rete neurale artificiale (ANN) implementati nel software SAGA GIS. Lo strumento richiede due tipi di dati come input. Il primo tipo di input è un raster composto da tre bande, tipicamente derivato da una ortofoto acquisita da un sistema di rilevamento UAS e comprendente le bande RGB della gamma dello spettro visibile. Il secondo tipo di input è un set di dati vettoriali, costituito da campioni di aree che definiscono le regioni di addestramento per la rete neurale. L'utente deve quindi impostare i parametri dello strumento, che determinano la struttura e il funzionamento del modello di rete neurale artificiale (ANN). Questi parametri includono il numero di strati nascosti e il numero di neuroni di ciascuno di essi, il numero di iterazioni e la variazione minima dell'errore tra le iterazioni per terminare l'algoritmo, i parametri della funzione di attivazione e il metodo di addestramento e il tasso di apprendimento. Il risultato del modello ANN è un raster che associa a ciascun pixel una classe definita dal set di dati di addestramento (Egmont-Petersen et al., 2002; *Neural Networks*, n.d.). La rete neurale artificiale (ANN) è stata addestrata utilizzando lo stesso

insieme di dati di addestramento impiegato nella procedura di classificazione basata sulla massima verosimiglianza. Dopo aver completato la classificazione basata sulla ANN, è stata eseguita un'operazione di apertura morfologica sui dati raster della classe delle piante infestanti. Questa operazione mirava a migliorare la continuità spaziale e a rimuovere i pixel indesiderati nel risultato ottenuto. Il flusso di lavoro è visibile nella figura 11.

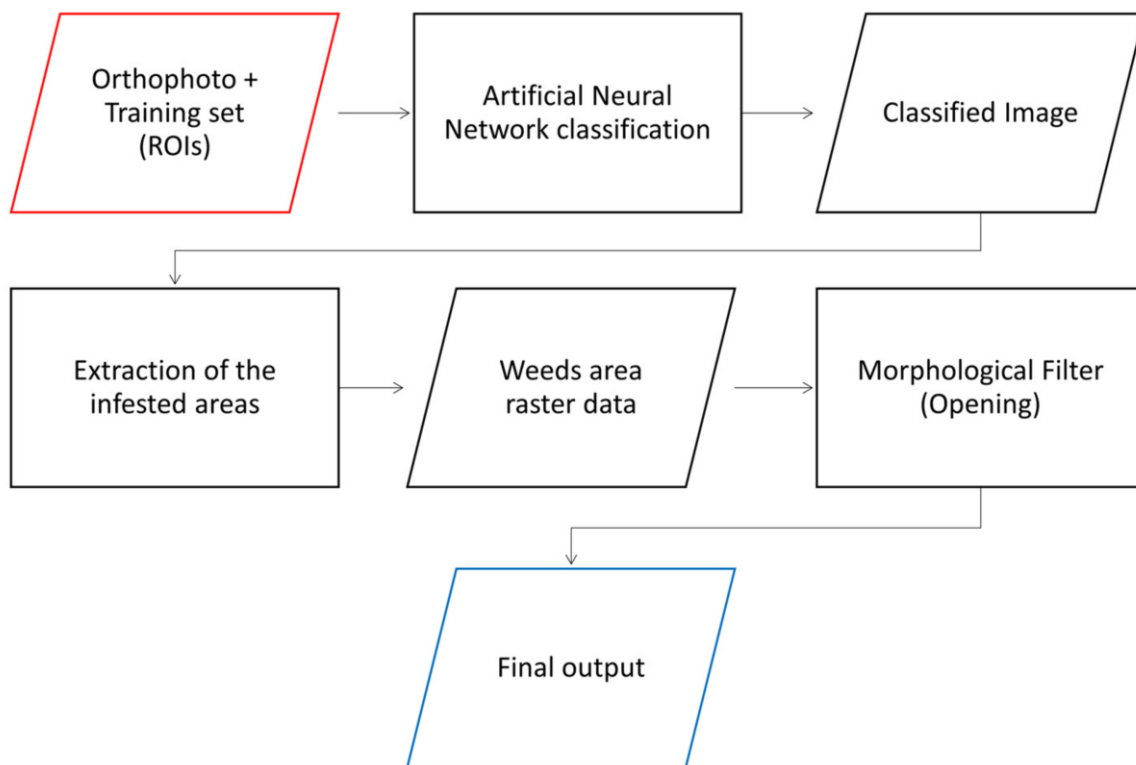


Figura 11. Flusso di lavoro del metodo di mappatura delle infestanti della Rete Neurale Artificiale

2.3.3 Deep Learning – Apprendimento profondo

Il deep learning è un ramo del Machine Learning ed è impiegato per la classificazione delle immagini, il rilevamento e il riconoscimento degli oggetti. Esso si concentra sull'uso di reti neurali artificiali profonde per apprendere e rappresentare dati complessi. Questo approccio deriva dalla struttura "profonda" di tali reti, caratterizzate da numerosi strati di nodi interconnessi, chiamati neuroni artificiali, ispirati al funzionamento del cervello umano. Queste architetture possono essere addestrate per distinguere, ad esempio, piante coltivate da piante infestanti. Nel contesto del rilevamento degli oggetti, esistono due categorie di metodi. Il primo prevede l'individuazione di riquadri di delimitazione attorno alle immagini, mentre il secondo si concentra sulla classificazione dei pixel degli oggetti. Dal punto di vista dell'etichettatura, tracciare riquadri di delimitazione rettangolari risulta più agevole rispetto all'etichettatura pixel per pixel tuttavia, dal punto di vista della precisione della mappatura, il rilevamento degli oggetti a livello di pixel supera la tecnica dei riquadri. La classificazione basata su pixel prende il nome di segmentazione semantica. Tale classificazione però non è completamente sfruttata nelle immagini agricole a causa della limitata disponibilità di immagini etichettate pixel per pixel. L'architettura impiegata per la classificazione pixel usando il deep learning si basa sulla struttura di U-Net, una rete di segmentazione semantica molto comune. La rete assume la forma di una "U". (Figura 12).




Figura 12. Struttura U-Net

Inizialmente sviluppato per la segmentazione di immagini biologiche, U-Net ha dimostrato la sua efficacia spaziando anche in altri settori. Questo successo è attribuibile a due principali motivi. Innanzitutto, il modello è in grado di estrarre caratteristiche globali, relative alle informazioni locali mediante l'utilizzo di livelli di convoluzione. In secondo luogo, U-Net si distingue per la sua capacità di eseguire un addestramento efficace anche con un numero molto limitato di campioni. Tuttavia, a

causa della complessità della rete e del notevole consumo di risorse computazionali, presentava limitazioni nella velocità di elaborazione.

Questa struttura adotta un approccio di rete relativamente semplice. Nel processo di codifica, l'immagine iniziale ad alta dimensionalità viene compressa in una mappa di caratteristiche a bassa dimensionalità, catturando informazioni semantiche chiave. Successivamente, durante la fase di decodifica, la mappa di caratteristiche viene ricondotta alla sua forma ad alta dimensionalità mediante l'operazione di up-sampling. I dati forniti alla rete includono immagini RGB che contengono sia la coltura che le specie di infestanti. In parallelo, vengono fornite le immagini etichettate corrispondenti per il processo di addestramento (Figura 13).



Figura 13. Immagine RGB (A) e immagine etichettata (B)

Questa configurazione consente al modello di apprendere la correlazione tra le caratteristiche visive delle immagini e le rispettive etichette, affinando la sua capacità di distinguere la zona coltivata dalle diverse specie infestanti durante la fase di segmentazione.

Nel presente lavoro di tesi, l'obiettivo è stato mappare le infestanti al contempo discriminandole a livello di specie. Per raggiungere questo obiettivo, si applica la segmentazione semantica ad immagini ad alta risoluzione provenienti da campi di girasole e soia, addestrando modelli su dati reali.

Nella fase di pre-elaborazione dei dati, per il rilevamento delle infestanti, sono stati creati manualmente dei poligoni per ogni specie di pianta infestante, creando un set che sarà utilizzato per la verifica dell'accuratezza del modello. Successivamente, diversi poligoni delle specie infestanti sono stati etichettati e impiegati per la creazione del training data per il deep learning. Per ogni specie infestante è stato attribuito un valore di classe (Tabella 2).

Tabella 2. Valori di classe per Soia e Girasole

Coltura	Classe	Valore
Soia	<i>Sorgum halepense</i>	1
	<i>Solanum nigrum</i>	2
	<i>Persicaria maculosa</i>	3
	<i>Portulaca oleracea</i>	4
Girasole	<i>Sorgum halepense</i>	1
	<i>Solanum nigrum</i>	2
	<i>Persicaria maculosa</i>	3

Le immagini mosaicate originali risultavano eccessivamente grandi per essere utilizzate direttamente nell'addestramento delle reti neurali di deep learning. Pertanto, sono state implementate procedure di ritaglio casuale, generando così una serie di immagini, ciascuna delle dimensioni 256×256 pixel, da diverse sezioni delle immagini mosaicate. Per arricchire le immagini campione e migliorare l'adattabilità delle reti neurali, è stata adottata una strategia di aumento dei dati: è stata utilizzata la rotazione di $\pm 45^\circ$ e una sovrapposizione del 50% su ciascuna immagine. Queste operazioni di aumento sono state eseguite sia sulle immagini RGB che su quelle etichettate.

In seguito a questo processo di aumento, è stato creato un nuovo set di dati, che costituirà il pool di addestramento per la costruzione delle architetture delle reti neurali da zero. Per il processo di convalida, viene utilizzato `validation_split = 0.1` (10%), che suddivide le immagini di training in 90% immagini a scopo di training e 10% immagini a scopo di convalida. Per l'addestramento di una rete, vengono implementate 20 epoche di addestramento.

Dopo circa 20 epoche di addestramento, impiegando sei ore, la precisione e il valore della perdita tendevano a essere stabili (Figura 14). Ciò ha dimostrato che il modello ha ottenuto un buon effetto formativo.

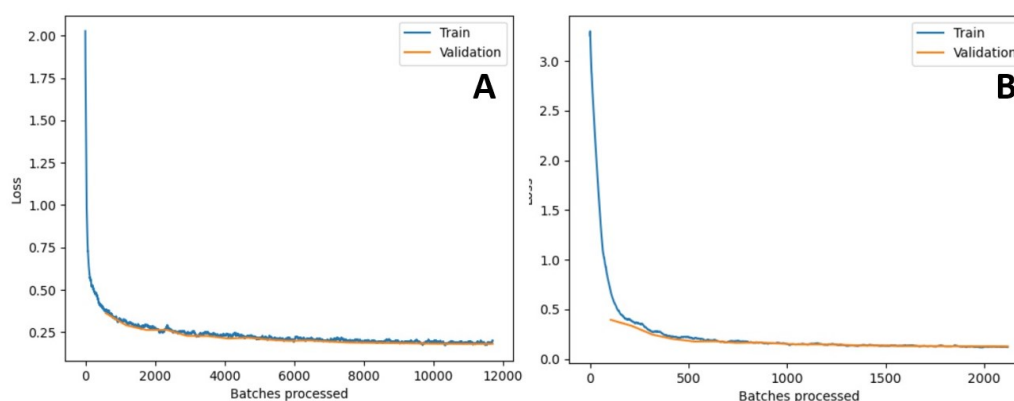


Figura 14. Risultati dei modelli di apprendimento

Tutto il lavoro di segmentazione è stato svolto con un PC portatile con una CPU Intel Core i5-10300h, 16 GB di memoria e una NVIDIA GeForce GTX 1650 Ti 4 GB. L'ambiente software utilizzato è stato Windows 11 e ArcGIS Pro 3.1.

2.3.4. Valutazione dell'accuratezza

La valutazione dell'accuratezza dei metodi testati è stata effettuata utilizzando il programma open source SAGA GIS (versione 9.1.2), avvalendosi della opzione che confronta i poligoni (classificazione fatta da esperti) con quella di rete raster (grid), ovvero la classificazione prodotta dal software. L'accuratezza delle classificazioni è stata valutata mediante una matrice di errore (poligoni/grid), che è una tecnica comune per valutare le classificazioni di immagini satellitari, la quale però si può applicare anche ad altre immagini classificate. La matrice di errore è un array quadrato, con un numero di righe e colonne pari al numero di classi considerate. In questo caso, le classi sono riportate nella Tabella 2. Per ogni classe, viene riportato il numero di pixel in relazione alla categoria effettiva riconosciuta dai dati di riferimento. (Mattivi et al., 2021).

A partire dalla matrice di errore, è stata calcolata la "Overall Accuracy" ossia la Precisione complessiva (Equazione (1)).

$$\text{Precisione complessiva} = \frac{TP+TN}{PT+TN+FP+FN} \quad (1)$$

Inoltre, sono stati calcolati la Precisione del Produttore, la quale rappresenta quanto accuratamente il creatore della mappa è riuscito a riflettere le reali caratteristiche del terreno sulla mappa. Essa riflette la probabilità che una specifica copertura del suolo in un'area del terreno venga classificata correttamente sulla mappa, e la precisione dell'utente, si riferisce alla precisione della mappa dal punto di vista di chi la utilizza, che in questo caso è la classificazione svolta dai diversi classificatori. Questa misura indica quanto frequentemente la classe, rappresentata sulla mappa, corrisponde effettivamente a ciò che si trova sul terreno. La precisione dell'utente riflette l'affidabilità della mappa nella rappresentazione accurata delle caratteristiche del terreno (Mattivi et al., 2021).

3. Risultati

I risultati delle immagini classificate, acquisite a diverse altezze di volo tramite sensore RGB sono i seguenti. Non tutti i metodi di classificazione sono stati in grado di distinguere le specie infestanti dalle colture.

3.1 Maximum Likelihood Classifier - Classificatore di massima verosimiglianza – MLC




Figura 15. Foto campo C1 5m (A), classificazione MLC (B)

Da una prima osservazione visiva si nota che la MLC non è risultata efficace per la classificazione specie-specifica. Tale classificazione non ha funzionato probabilmente a causa della somiglianza spettrale.

3.2 ANN




Figura 16. Ritaglio ortofoto 15 m campo C2 (A) e Classificazione svolta da ANN (B)

Da una prima osservazione visiva si nota che anche la ANN non è risultata efficace per la classificazione specie-specifica, di conseguenza è stato deciso di concentrarci su tecniche più efficaci.

3.3 Deep Learning

L'unico metodo di classificazione che ha prodotto dei risultati validi è stato il deep learning. Di seguito sono riportati i risultati della classificazione eseguita per ogni campo alle diverse altezze.

3.3.1. Campo C1

I dati raccolti sono stati utili ad una valutazione quantitativa e qualitativa della flora infestante.

L'analisi dei dati ha evidenziato come il campo C1 sia caratterizzato dalla presenza di alcune specie infestanti come *Portulaca oleracea* L. (Portulaca), *Solanum nigrum* L. (Solanum), *Persicaria maculosa* L. (Persicaria) e *Sorghum halepense* L. (Sorghetta).




Figura 17. Foto ad altezza di 5 m del campo C1

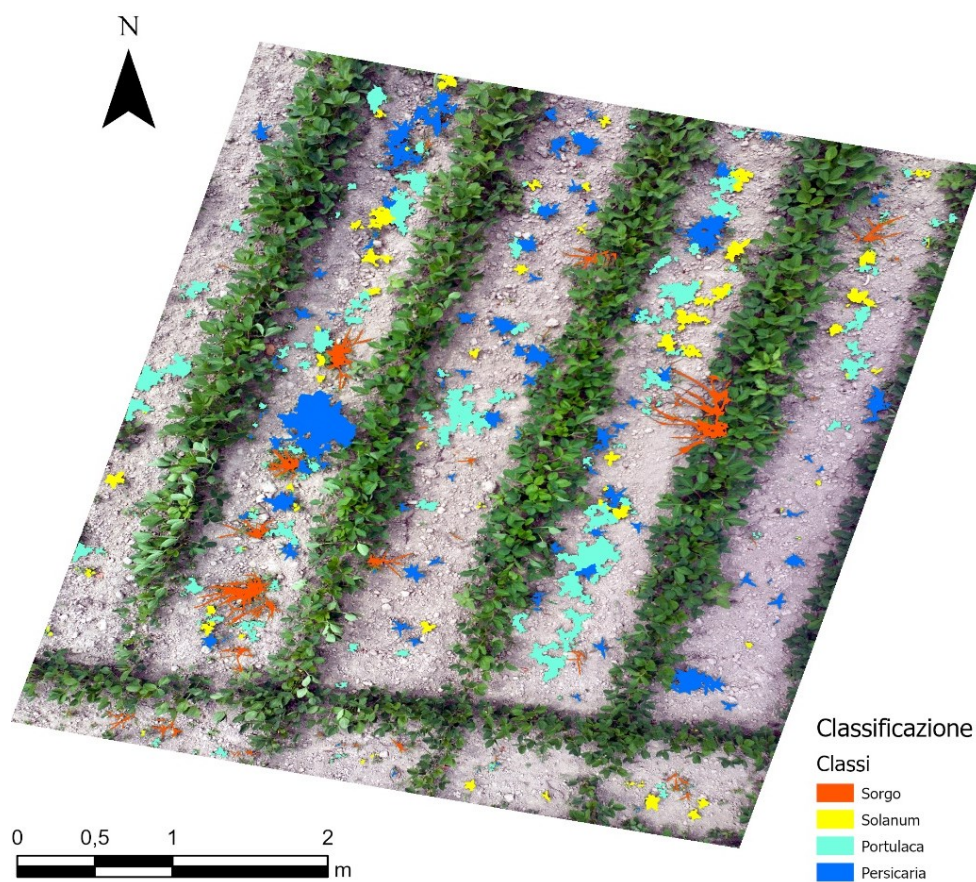


Figura 18. Classificazione foto a 5 m eseguita tramite deep learning

Tabella 3. Valutazione dell'accuratezza della classificazione a 5 m

Classe	Precisione produttore	Precisione utente	Kappa	Overall Accuracy
<i>S. halepense</i>	0.976	0.979		
<i>S. nigrum</i>	0.883	0.868		
<i>P. oleracea</i>	0.937	0.950		
<i>P. maculosa</i>	0.954	0.943		
Kappa			0.912	
Overall Accuracy				0.940

La classificazione tramite deep learning, su foto realizzate a 5 m ha avuto un'accuratezza complessiva del 94%. È stata in grado di classificare *S. halepense* al 97,9%, *S. nigrum* al 86,8%, *P. oleracea* al 95% e *P. maculosa* al 94,3%.




Figura 19. Foto ad altezza di 7,5 m del campo C1




Figura 20. Classificazione foto a 7,5 m eseguita tramite deep learning

Tabella 4. Valutazione dell'accuratezza della classificazione a 7,5 m

Classe	Precisione produttore	Precisione utente	Kappa	Overall Accuracy
<i>S. halepense</i>	0.869	0.841		
<i>S. nigrum</i>	0.691	0.918		
<i>P. oleraceae</i>	0.947	0.709		
<i>P. maculosa</i>	0.658	0.907		
Kappa			0.698	
Overall Accuracy				0.797

La classificazione tramite deep learning, su foto realizzate a 7,5 m ha avuto un'accuratezza complessiva del 79,7%. È stata in grado di classificare *S. halepense* al 84,1%, *S. nigrum* al 91,8%, *P. oleracea* al 70,9% e *P. maculosa* al 90,7%.




Figura 21. Foto ad altezza di 10 m del campo C1




Figura 22. Classificazione foto a 10 m eseguita tramite deep learning

Tabella 5. Valutazione dell'accuratezza della classificazione a 10 m

Classe	Precisione produttore	Precisione utente	Kappa	Overall Accuracy
<i>S. halepense</i>	0.844	0.694		
<i>S. nigrum</i>	0.779	0.941		
<i>P. oleraceae</i>	0.830	0.724		
<i>P. maculosa</i>	0.945	0.563		
Kappa			0.699	
Overall Accuracy				0.808

La classificazione tramite deep learning, su foto realizzate a 10 m ha avuto un'accuratezza complessiva del 80,8%. È stata in grado di classificare *S. halepense* al 69,4%, *S. nigrum* al 94,1%, *P. oleracea* al 72,4% e *P. maculosa* al 56,3%.




Figura 23. Foto ad altezza di 12,5 m del campo C1




Figura 24. Classificazione foto a 12,5 m eseguita tramite deep learning

Tabella 7. Valutazione dell'accuratezza della classificazione a 12,5 m

Classe	Precisione produttore	Precisione utente	Kappa	Overall Accuracy
<i>S. halepense</i>	0.824	0.759		
<i>S. nigrum</i>	0.903	0.914		
<i>P.oleraceae</i>	0.732	0.737		
<i>P. maculosa</i>	0.859	0.766		
Kappa			0.723	
Overall Accuracy				0.832

La classificazione tramite deep learning, su foto realizzate a 12,5 m ha avuto un'accuratezza complessiva del 83,2%. È stata in grado di classificare *S. halepense* al 75,9%, *S. nigrum* al 91,4%, *P. oleracea* al 73,7% e *P. maculosa* al 76,6%.




Figura 25. Foto ad altezza di 15 m del campo C1




Figura 26. Classificazione foto a 15 m eseguita tramite deep learning

Tabella8. Valutazione dell'accuratezza della classificazione a 15 m

Classe	Precisione produttore	Precisione utente	Kappa	Overall Accuracy
<i>S. halepense</i>	0.804	0.853		
<i>S. nigrum</i>	0.956	0.909		
<i>P. oleraceae</i>	0.648	0.771		
<i>P. maculosa</i>	0.796	0.866		
Kappa			0.772	
Overall Accuracy				0.883

La classificazione tramite deep learning, su foto realizzate a 15 m ha avuto un'accuratezza complessiva del 88,3%. È stata in grado di classificare *S. halepense* al 85,3%, *S. nigrum* al 90,9%, *P. oleracea* al 77,1% e *P. maculosa* al 86,6%.




Figura 27. Foto ad altezza di 30 m del campo C1




Figura 28. Classificazione foto a 30 m eseguita tramite deep learning

Tabella 9. Valutazione dell'accuratezza della classificazione a 30 m

Classe	Precisione produttore	Precisione utente	Kappa	Overall Accuracy
<i>S. nigrum</i>	0.599	0.850		
<i>P. oleracea</i>	0.950	0.870		
<i>P. maculosa</i>	0.735	0.821		
Kappa			0.713	
Overall Accuracy				0.855

La classificazione tramite deep learning, su foto realizzate a 30 m ha avuto un'accuratezza complessiva del 85,5%. È stata in grado di classificare *S. nigrum* al 85%, *P. oleracea* al 87% e *P. maculosa* al 82,1%.

3.3.2. Campo C2

L'analisi dei dati ha evidenziato come il campo C2 sia caratterizzato dalla presenza di alcune specie infestanti come *S. halepense* (Sorgo), *S. nigrum* (Solanum) e *P. maculosa* (Persicaria).




Figura 29. Foto ad altezza di 5 m del campo C2




Figura 30. Classificazione foto a 5 m eseguita tramite deep learning

Tabella9. Valutazione dell'accuratezza della classificazione a 5 m

Classe	Precisione produttore	Precisione utente	Kappa	Overall Accuracy
<i>S. halepense</i>	0.988	0.999		
<i>S. nigrum</i>	0.705	0.914		
<i>P. maculosa</i>	0.994	0.951		
Kappa			0.779	
Overall Accuracy				0.988

La classificazione tramite deep learning, su foto realizzate a 5 m ha avuto un'accuratezza complessiva del 98,8%. È stata in grado di classificare *S. halepense* al 99,9%, *S. nigrum* al 91,4% e *P. maculosa* al 95,1%.




Figura 31. Foto ad altezza di 7,5 m del campo C2




Figura 32. Classificazione foto a 7,5 m eseguita tramite deep learning

Tabella 10. Valutazione dell'accuratezza della classificazione a 7,5 m

Classe	Precisione produttore	Precisione utente	Kappa	Overall Accuracy
<i>S. halepense</i>	0.966	1.000		
<i>S. nigrum</i>	0.503	0.914		
<i>P. maculosa</i>	0.912	0.951		
Kappa			0.751	
Overall Accuracy				0.902

La classificazione tramite deep learning, su foto realizzate a 7,5 m ha avuto un'accuratezza complessiva del 90,2%. È stata in grado di classificare *S. halepense* al 100%, *S. nigrum* al 91,4% e *P. maculosa* al 95,1%.




Figura 33. Foto ad altezza di 10 m del campo C2




Figura 34. Classificazione foto a 10 m eseguita tramite deep learning

Tabella 11. Valutazione dell'accuratezza della classificazione a 10 m

Classe	Precisione produttore	Precisione utente	Kappa	Overall Accuracy
<i>S. halepense</i>	0.947	0.987		
<i>S. nigrum</i>	0.451	0.934		
<i>P. maculosa</i>	0.601	0.912		
Kappa			0.641	
Overall Accuracy				0.861

La classificazione tramite deep learning, su foto realizzate a 10 m ha avuto un'accuratezza complessiva del 86,1%. È stata in grado di classificare *S. halepense* al 98,7%, *S. nigrum* al 93,4% e *P. maculosa* al 91,2%.




Figura 35. Foto ad altezza di 12,5 m del campo C2

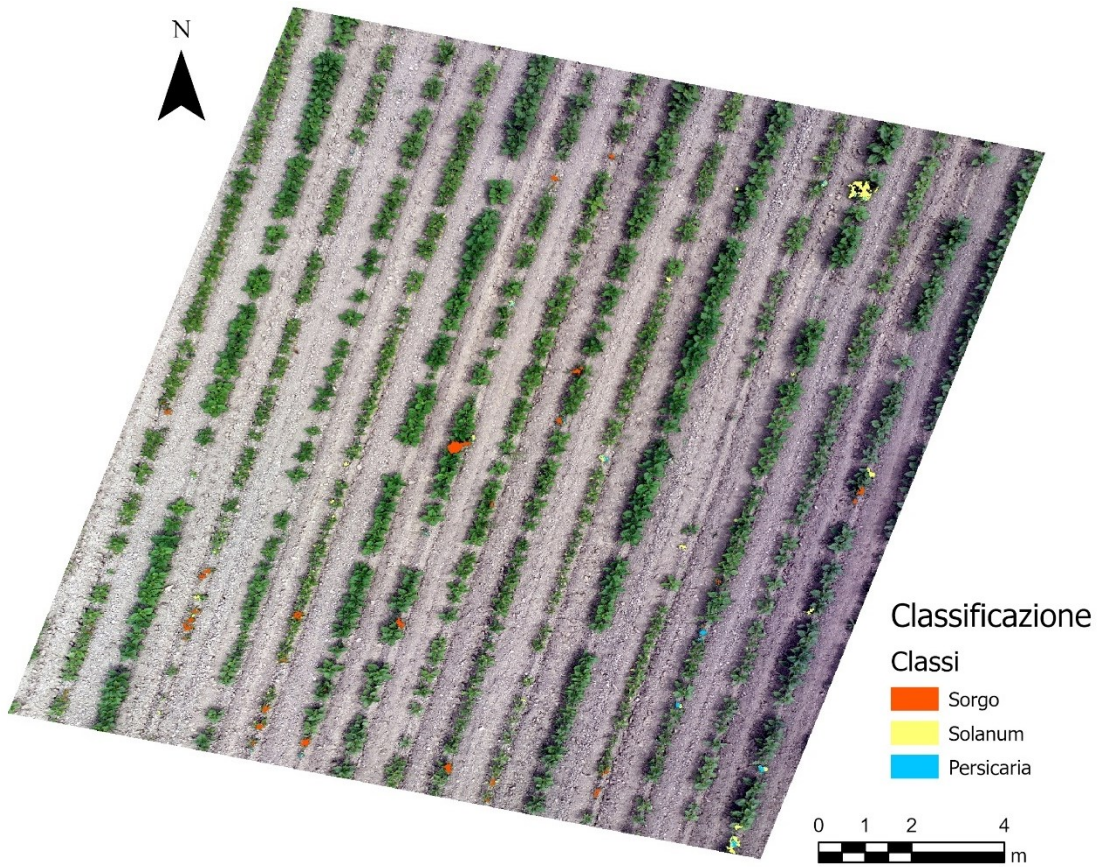


Figura 36. Classificazione foto a 12,5 m eseguita tramite deep learning

Tabella 12. Valutazione dell'accuratezza della classificazione a 12,5 m

Classe	Precisione produttore	Precisione utente	Kappa	Overall Accuracy
<i>S. halepense</i>	0.914	0.986		
<i>S. nigrum</i>	0.221	0.239		
<i>P. maculosa</i>	0.687	0.535		
Kappa			0.572	
Overall Accuracy				0.773

La classificazione tramite deep learning, su foto realizzate a 12,5 m ha avuto un'accuratezza complessiva del 77,3%. È stata in grado di classificare *S. halepense* al 98,6%, *S. nigrum* al 23,9% e *P. maculosa* al 53,5%.




Figura 37. Ortofoto ad altezza di 15 m del campo C2




Figura 38. Classificazione ortofoto a 15 m eseguita tramite deep learning

Tabella 13. Valutazione dell'accuratezza della classificazione a 15 m

Classe	Precisione produttore	Precisione utente	Kappa	Overall Accuracy
<i>S. halepense</i>	0.995	0.994		
<i>S. nigrum</i>	0.549	0.701		
<i>P. maculosa</i>	0.875	0.786		
Kappa			0.830	
Overall Accuracy				0.914

La classificazione tramite deep learning, su ortofoto realizzata a 15 m ha avuto un'accuratezza complessiva del 91,4%. È stata in grado di classificare *S. halepense* al 99,4%, *S. nigrum* al 70,1% e *P. maculosa* al 78,6%.




Figura 39. Ortofoto ad altezza di 30 m del campo C2 (A) e Classificazione ortofoto a 30 m eseguita tramite deep learning (B)

Tabella14. Valutazione dell'accuratezza della classificazione a 30 m

Classe	Precisione produttore	Precisione utente	Kappa	Overall Accuracy
<i>S. halepense</i>	0.064	0.847		
<i>S. nigrum</i>	0.360	0.031		
<i>P. maculosa</i>	0.000	0.000		
Kappa			-0.009	
Overall Accuracy				0.06

La classificazione tramite deep learning, su ortofoto realizzata a 30 m ha avuto un'accuratezza complessiva estremamente bassa 0,06%. È stata in grado di classificare il *S. halepense* al 84,7%, *S. nigrum* al 0,03% e non è stato in grado di classificare la *P. maculosa*.

Per questo motivo è stato deciso di provare a fare una classificazione separando le infestanti in due categorie, infestanti a foglia stretta e infestanti a foglia larga.




Figura 42. Ortofoto ad altezza di 30 m del campo C2 (A) e Classificazione ortofoto a 30 m eseguita tramite deep learning (B)

Tabella14. Valutazione dell'accuratezza della classificazione a 30 m

Classe	Precisione produttore	Precisione utente	Kappa	Overall Accuracy
Foglia stretta	0.979	0.987		
Foglia larga	0.629	0.435		
Kappa			0.496	
Overall Accuracy				0.962

La classificazione tramite deep learning, su ortofoto realizzata a 30 m, con le sole due categorie, ha avuto un'accuratezza complessiva del 96,2%. È stata in grado di classificare le specie a foglia stretta al 98,7%, e le specie a foglia larga al 43,5%.

4. Discussione

Alla luce dei risultati ottenuti, è possibile affermare che le classificazioni MLC e ANN hanno dimostrato di non essere in grado di distinguere le piante infestanti dalle colture. Nonostante siano stati condotti numerosi studi al fine di classificare le infestanti impiegando tali sistemi (de Castro et al., 2013; Mattivi et al., 2021), in questo studio si sono rivelate non idonee. Le cause di tale inefficacia possono essere attribuite a diversi fattori. Nelle immagini sottoposte a classificazione, grazie alla elevata risoluzione del sensore equipaggiato sul drone, sono presenti numerosi pixel che assumono varie colorazioni che hanno condizionato notevolmente il risultato della classificazione. Inoltre, poiché il colore dei pixel delle erbe infestanti risultava simile a quello dei pixel della coltura, è possibile che anche tale fattore abbia influito significativamente sul risultato finale (Asad & Bais, 2020; Hasan et al., 2021). Un'ulteriore limitazione potrebbe essere rappresentata dall'ombreggiamento causato dalle piante rispetto al suolo e alle piante infestanti (Eddy et al., 2006). Osservando i dati, emerge che le prestazioni più elevate sono state ottenute tramite l'approccio di classificazione basato sul deep learning. È evidente che, all'aumentare dell'altitudine di volo, si verifica una diminuzione dell'accuratezza, suggerendo la possibilità che una determinata specie possa essere erroneamente classificata come un'altra.

È rilevante notare che l'accuratezza della classificazione è influenzata anche dal livello di infestazione della coltura. In questo studio, il campo C1, dedicato alla coltivazione di soia, mostrava un livello di infestazione significativamente più elevato rispetto al campo C2, coltivato con girasoli.

Di conseguenza, le classificazioni effettuate a diverse altitudini nel campo C1 risultano meno precise rispetto a quelle eseguite nel campo C2.

È essenziale evidenziare anche il marcato sbilanciamento delle specie infestanti (Hasan et al., 2021), il quale potrebbe aver influito notevolmente sul modello di apprendimento utilizzato per le classificazioni. Nel campo C1, infatti, si osserva che la specie *S. halepense* rappresentava solo il 2,08% del totale, mentre per quanto riguarda il campo C2, la specie *P. maculosa* costituiva solo l'1,66% del totale.

Di conseguenza, nella mappa a 30 m il modello tendeva erroneamente a classificare la specie *P. maculosa* come *S. nigrum*.

Al fine di correggere tali errori di classificazione, è stata eseguita una nuova classificazione sul campo C2, ad un'altitudine di 30 m, basata sulla distinzione tra specie a foglia stretta e a foglia larga. I risultati di questa nuova classificazione hanno registrato un notevole miglioramento.

Come dimostrato in diversi studi (Hasan et al., 2021), nelle prime fasi di crescita delle piante il modello di classificazione basato su pixel può presentare dei limiti, in quanto i colori dei pixel delle piante coltivate risultano essere simili ai pixel delle malerbe, di conseguenza l'uso di altri indici spettrali potrebbe migliorare ulteriormente le prestazioni (Hasan et al., 2021).

È evidente che il deep learning (DL), in particolare la segmentazione semantica, è la tecnica maggiormente impiegata per la classificazione delle malerbe (Rai et al., 2023) come dimostrano diversi studi (Chicchón Apaza et al., 2020; Milioto et al., 2018; Rosas et al., 2022; Wang et al., 2020; Zou et al., 2021), mostra buone prestazioni nel contesto del telerilevamento (Hasan et al., 2021) e che l'altezza di volo ha un impatto significativo sull'accuratezza delle classificazioni (Rai et al., 2023). Le migliori classificazioni risultano essere state eseguite su immagini acquisite ad un'altitudine di 5 m, caratterizzate da una risoluzione molto elevata.

Tuttavia, la produzione di ortofoto ad un'altitudine così ridotta comporta un notevole aumento dei tempi sia per l'acquisizione che per l'elaborazione delle immagini.

Utilizzare un'immagine aerea con una risoluzione molto elevata, ossia ricca di dettagli, comporta un notevole aumento del tempo necessario per sviluppare modelli di apprendimento automatico e per eseguire le successive classificazioni. Questo è evidente anche dai risultati presentati in questa tesi, dove si è cercato di addestrare il modello usando le immagini acquisite a 15 m e cercando di applicarlo alle immagini scattate a 12,5 m e a 10 m. Il risultato è stata la perdita dell'accuratezza della mappa, che ci porta alla conclusione che per aumentare la precisione delle classificazioni è cruciale addestrare i modelli di riconoscimento usando le immagini scattate sempre alla stessa quota, che però impone di spendere più tempo nell'addestramento dei modelli (Rai et al., 2023), che saranno limitati solo ad alcune immagini od ortofoto acquisite.

Pertanto, è cruciale cercare un compromesso tra la precisione desiderata e il tempo complessivo dedicato al processo, considerando che una maggiore risoluzione implica un carico computazionale più elevato. È importante sottolineare che vi è ancora spazio per migliorare l'efficacia del deep learning. L'adozione di tecnologie emergenti può contribuire a potenziare la precisione e la velocità dei sistemi di rilevamento automatico delle malerbe, evitando il ricorso alla laboriosa etichettatura manuale eseguita dagli esperti, specialmente quando si tratta di un elevato numero di immagini.

Attualmente, la mancanza di database completi sulle colture e sulle piante infestanti costituisce una limitazione. Creare un vasto database di riferimento che includa una diversificata gamma di colture ed erbe infestanti provenienti da svariate posizioni geografiche, condizioni meteorologiche e fasi di crescita differenti, aumenterebbe di gran lunga l'impiego del DL (Yu et al., 2019). Tuttavia, è importante notare che creare questi ampi set di dati potrebbe comportare dei costi significativi (Hasan et al., 2021).

5. Conclusioni

Si può affermare quindi che nei campi C1 e C2 è presente una flora specializzata, caratterizzata dalla presenza di numerosi individui appartenenti a poche specie con una capacità di adattamento alla gestione colturale notevolmente elevata. Questa situazione può avere notevole impatto sulla resa della coltura, poiché rende complesso il controllo delle malerbe e l'effetto competitivo esercitato da alcune di queste specie nei confronti della coltura è alto.

La creazione accurata di mappe delle infestanti è cruciale per valutare la densità e pianificare l'applicazione differenziata di erbicidi. La segmentazione semantica mediante l'utilizzo del deep learning si prospetta come una promettente tecnica per raggiungere questo obiettivo.

Tale tecnologia può apportare un significativo contributo agli agricoltori nelle attività di monitoraggio, in quanto si dimostra capace di delineare con precisione l'intera superficie infestata, un aspetto cruciale per valutare sia l'entità dell'infestazione che lo sviluppo della coltura.

La finalità principale di creare un sistema automatico per il rilevamento delle erbe infestanti è fornire una tecnica di gestione che minimizzi i costi e massimizzi i rendimenti agricoli.

Per raggiungere questo obiettivo, è opportuno concepire un sistema applicabile in numerosi scenari, che possa essere adottato su larga scala, su dispositivi con requisiti computazionali più contenuti e che sia in grado di effettuare un rilevamento accurato delle malerbe.

Ad oggi, tuttavia, alcune limitazioni consentono un utilizzo a scopo esclusivamente sperimentale. Queste includono la mancanza di un database idoneo per l'addestramento di un modello su larga scala, la non adeguata precisione dei modelli pre-addestrati disponibili in rete e l'impiego di modelli di apprendimento che richiedono numerose ore di addestramento. Pertanto, la ricerca deve dedicarsi a superare tali ostacoli al fine di poter sfruttare appieno il potenziale del deep learning per il SSWM.

6. Bibliografía

- Abdullahi, H. S., Mahieddine, F., & Sheriff, R. E. (2015). Technology impact on agricultural productivity: A review of precision agriculture using unmanned aerial vehicles. *Lecture Notes of the Institute for Computer Sciences, Social-Informatics and Telecommunications Engineering, LNICST*, 154, 388–400. https://doi.org/10.1007/978-3-319-25479-1_29
- Ali, M. M., Al-Ani, A., Eamus, D., & Tan, D. K. Y. (2017). Leaf nitrogen determination using non-destructive techniques—A review. *Journal of Plant Nutrition*, 40(7), 928–953. <https://doi.org/10.1080/01904167.2016.1143954>
- Anderson, C. (2014). *Agricultural Drones | MIT Technology Review*. <https://www.technologyreview.com/technology/agricultural-drones/>
- Asad, M. H., & Bais, A. (2020). Weed detection in canola fields using maximum likelihood classification and deep convolutional neural network. *Information Processing in Agriculture*, 7(4), 535–545. <https://doi.org/10.1016/j.inpa.2019.12.002>
- Blanco-Moreno, J. M., Chamorro, L., & Sans, F. X. (2006). Spatial and temporal patterns of *Lolium rigidum*-*Avena sterilis* mixed populations in a cereal field. *Weed Research*, 46(3), 207–218. <https://doi.org/10.1111/j.1365-3180.2006.00493.x>
- Bolstad, P. V., & Lillesand, T. M. (1991). Rapid maximum likelihood classification. *Photogrammetric Engineering & Remote Sensing*, 57(1), 67–74.
- Calderón, R., Navas-Cortés, J. A., Lucena, C., & Zarco-Tejada, P. J. (2013). High-resolution airborne hyperspectral and thermal imagery for early detection of *Verticillium* wilt of olive using fluorescence, temperature and narrow-band spectral indices. *Remote Sensing of Environment*, 139, 231–245. <https://doi.org/10.1016/j.rse.2013.07.031>
- Cardina, J., Johnson, G. A., & Sparrow, D. H. (1997). The nature and consequence of weed spatial distribution. *Weed Science*, 45(3), 364–373. <https://doi.org/10.1017/S0043174500092997>
- Castaldi, F., Pelosi, F., Pascucci, S., & Casa, R. (2017). Assessing the potential of images from unmanned aerial vehicles (UAV) to support herbicide patch spraying in maize. *Precision Agriculture*, 18(1), 76–94. <https://doi.org/10.1007/s11119-016-9468-3>
- Chauhan, B. S. (2020). Grand Challenges in Weed Management. *Frontiers in Agronomy*, 1(January), 1–4. <https://doi.org/10.3389/fagro.2019.00003>
- Chicchón Apaza, M. Á., Monzón, H. M. B., & Alcarria, R. (2020). *Semantic Segmentation of Weeds and Crops in Multispectral Images by Using a Convolutional Neural Networks Based on U-Net* (pp. 473–485). https://doi.org/10.1007/978-3-030-42520-3_38

- Chikowo, R., Faloya, V., Petit, S., & Munier-Jolain, N. M. (2009). Integrated Weed Management systems allow reduced reliance on herbicides and long-term weed control. *Agriculture, Ecosystems and Environment*. <https://doi.org/10.1016/j.agee.2009.04.009>
- Conrad, O., Bechtel, B., Bock, M., Dietrich, H., Fischer, E., Gerlitz, L., Wehberg, J., Wichmann, V., & Böhner, J. (2015). System for Automated Geoscientific Analyses (SAGA) v. 2.1.4. *Geoscientific Model Development*, 8(7), 1991–2007. <https://doi.org/10.5194/gmd-8-1991-2015>
- de Castro, A. I., Jurado-Expósito, M., Peña-Barragán, J. M., & López-Granados, F. (2012). Airborne multi-spectral imagery for mapping cruciferous weeds in cereal and legume crops. *Precision Agriculture*, 13(3), 302–321. <https://doi.org/10.1007/s11119-011-9247-0>
- de Castro, A. I., López-Granados, F., & Jurado-Expósito, M. (2013). Broad-scale cruciferous weed patch classification in winter wheat using QuickBird imagery for in-season site-specific control. *Precision Agriculture*, 14(4), 392–413. <https://doi.org/10.1007/s11119-013-9304-y>
- Eddy, P. R., Smith, A. M., Hill, B. D., Peddle, D. R., Coburn, C. A., & Blackshaw, R. E. (2006). Comparison of neural network and maximum likelihood high resolution image classification for weed detection in crops: Applications in precision agriculture. *International Geoscience and Remote Sensing Symposium (IGARSS)*, 116–119. <https://doi.org/10.1109/IGARSS.2006.35>
- Egmont-Petersen, M., De Ridder, D., & Handels, H. (2002). Image processing with neural networks- A review. *Pattern Recognition*, 35(10), 2279–2301. [https://doi.org/10.1016/S0031-3203\(01\)00178-9](https://doi.org/10.1016/S0031-3203(01)00178-9)
- Eshed, N. (1975). Role of Wild Grasses in Epidemics of Powdery Mildew n Small Grains in Israel. In *Phytopathology* (Vol. 65, Issue 1, p. 57). <https://doi.org/10.1094/phyto-65-57>
- Esposito, M., Crimaldi, M., Cirillo, V., Sarghini, F., & Maggio, A. (2021). Drone and sensor technology for sustainable weed management: a review. *Chemical and Biological Technologies in Agriculture*, 8(1), 1–11. <https://doi.org/10.1186/s40538-021-00217-8>
- European Parliament. (2009). Directive 2009/128/EC of the European Parliament and the Council of 21 October 2009 establishing a framework for Community action to achieve the sustainable use of pesticides. *October*, 309, 71–86. https://doi.org/10.3000/17252555.L_2009.309
- Fernandez-Ordonez, Y. M., & Soria-Ruiz, J. (2017). Maize crop yield estimation with remote sensing and empirical models. *International Geoscience and Remote Sensing Symposium (IGARSS)*, 2017-July, 3035–3038. <https://doi.org/10.1109/IGARSS.2017.8127638>
- Gerhards, R., & Christensen, S. (2003). Real-time weed detection, decision making and patch spraying in maize, sugarbeet, winter wheat and winter barley. *Weed Research*, 43(6), 385–392. <https://doi.org/10.1046/j.1365-3180.2003.00349.x>

- Gnädinger, F., & Schmidhalter, U. (2017). Digital counts of maize plants by Unmanned Aerial Vehicles (UAVs). *Remote Sensing*, *9*(6). <https://doi.org/10.3390/rs9060544>
- Godwin, R. J., Richards, T. E., Wood, G. A., Welsh, J. P., & Knight, S. M. (2003). An economic analysis of the potential for precision farming in UK cereal production. *Biosystems Engineering*, *84*(4), 533–545. [https://doi.org/10.1016/S1537-5110\(02\)00282-9](https://doi.org/10.1016/S1537-5110(02)00282-9)
- Hamouz, P., Hamouzová, K., Tyšer, L., & Holec, J. (2014). Effect of site-specific weed management in winter crops on yield and weed populations. *Plant, Soil and Environment*, *60*(1), 27–35. <https://doi.org/10.17221/574/2013-pse>
- Hanzlik, K., & Gerowitt, B. (2016). Methods to conduct and analyse weed surveys in arable farming: a review. *Agronomy for Sustainable Development*, *36*(1), 1–18. <https://doi.org/10.1007/s13593-015-0345-7>
- Hasan, A. S. M. M., Soheli, F., Diepeveen, D., Laga, H., & Jones, M. G. K. (2021). A survey of deep learning techniques for weed detection from images. *Computers and Electronics in Agriculture*, *184*(March), 106067. <https://doi.org/10.1016/j.compag.2021.106067>
- Hassan-Esfahani, L., Torres-Rua, A., Jensen, A., & Mckee, M. (2017). Spatial Root Zone Soil Water Content Estimation in Agricultural Lands Using Bayesian-Based Artificial Neural Networks and High-Resolution Visual, NIR, and Thermal Imagery. *Irrigation and Drainage*, *66*(2), 273–288. <https://doi.org/10.1002/ird.2098>
- Honrado, J. L. E., Solpico, D. B., Favila, C. M., Tongson, E., Tangonan, G. L., & Libatique, N. J. C. (2017). UAV imaging with low-cost multispectral imaging system for precision agriculture applications. *GHTC 2017 - IEEE Global Humanitarian Technology Conference, Proceedings, 2017-Janua*(October), 1–7. <https://doi.org/10.1109/GHTC.2017.8239328>
- Huang, H., Deng, J., Lan, Y., Yang, A., Deng, X., Wen, S., Zhang, H., & Zhang, Y. (2018). Accurate weed mapping and prescription map generation based on fully convolutional networks using UAV imagery. *Sensors (Switzerland)*, *18*(10). <https://doi.org/10.3390/s18103299>
- Khanal, S., Fulton, J., Klopfenstein, A., Douridas, N., & Shearer, S. (2018). Integration of high resolution remotely sensed data and machine learning techniques for spatial prediction of soil properties and corn yield. *Computers and Electronics in Agriculture*, *153*(August), 213–225. <https://doi.org/10.1016/j.compag.2018.07.016>
- Khanal, S., Fulton, J., & Shearer, S. (2017). An overview of current and potential applications of thermal remote sensing in precision agriculture. *Computers and Electronics in Agriculture*, *139*, 22–32. <https://doi.org/10.1016/j.compag.2017.05.001>
- Kim, D.-W., Kim, Y., Kim, K.-H., Kim, H.-J., & Chung, Y. S. (2019). Case Study: Cost-effective

- Weed Patch Detection by Multi-Spectral Camera Mounted on Unmanned Aerial Vehicle in the Buckwheat Field. *Korean J. Crop Sci.*, 64(2)(2), 159-164. <https://doi.org/10.7740/kjcs.2019.64.2.159>
- López-Granados, F., Torres-Sánchez, J., Serrano-Pérez, A., de Castro, A. I., Mesas-Carrascosa, F. J., & Peña, J. M. (2016). Early season weed mapping in sunflower using UAV technology: variability of herbicide treatment maps against weed thresholds. *Precision Agriculture*, 17(2), 183–199. <https://doi.org/10.1007/s11119-015-9415-8>
- Lutz, W., & Kc, S. (2010). Dimensions of global population projections: What do we know about future population trends and structures? *Philosophical Transactions of the Royal Society B: Biological Sciences*, 365(1554), 2779–2791. <https://doi.org/10.1098/rstb.2010.0133>
- MARSHALL, E. J. P. (1988). Field-scale estimates of grass weed populations in arable land. *Weed Research*, 28(3), 191–198. <https://doi.org/10.1111/j.1365-3180.1988.tb01606.x>
- Mattivi, P., Pappalardo, S. E., Nikolić, N., Mandolesi, L., Persichetti, A., De Marchi, M., & Masin, R. (2021). Can commercial low-cost drones and open-source gis technologies be suitable for semi-automatic weed mapping for smart farming? A case study in ne italy. *Remote Sensing*, 13(10). <https://doi.org/10.3390/rs13101869>
- Milioto, A., Lottes, P., & Stachniss, C. (2018). Real-Time Semantic Segmentation of Crop and Weed for Precision Agriculture Robots Leveraging Background Knowledge in CNNs. *Proceedings - IEEE International Conference on Robotics and Automation*, 2229–2235. <https://doi.org/10.1109/ICRA.2018.8460962>
- Neural Networks*. (n.d.). Docs.Opencv.Org. Retrieved October 25, 2023, from https://docs.opencv.org/2.4/modules/ml/doc/neural_networks.html
- Nikolić, N., Rizzo, D., Marraccini, E., Ayerdi Gotor, A., Mattivi, P., Saulet, P., Persichetti, A., & Masin, R. (2021). Site- and time-specific early weed control is able to reduce herbicide use in maize - a case study. *Italian Journal of Agronomy*, 16(4). <https://doi.org/10.4081/ija.2021.1780>
- Nordmeyer, H. (2009). Spatial and temporal dynamics of *Apera spica-venti* seedling populations. *Crop Protection*, 28(10), 831–837. <https://doi.org/10.1016/j.cropro.2009.06.006>
- Oerke, E. C. (2006). Crop losses to pests. *Journal of Agricultural Science*, 144(1), 31–43. <https://doi.org/10.1017/S0021859605005708>
- Omia, E., Bae, H., Park, E., Kim, M. S., Baek, I., Kabenge, I., & Cho, B. K. (2023). Remote Sensing in Field Crop Monitoring: A Comprehensive Review of Sensor Systems, Data Analyses and Recent Advances. *Remote Sensing*, 15(2). <https://doi.org/10.3390/rs15020354>
- Otukei, J. R., & Blaschke, T. (2010). Land cover change assessment using decision trees, support

- vector machines and maximum likelihood classification algorithms. *International Journal of Applied Earth Observation and Geoinformation*, 12(SUPPL. 1), S27–S31. <https://doi.org/10.1016/j.jag.2009.11.002>
- Park, S., Ryu, D., Fuentes, S., Chung, H., Hernández-Montes, E., & O’Connell, M. (2017). Adaptive estimation of crop water stress in nectarine and peach orchards using high-resolution imagery from an unmanned aerial vehicle (UAV). *Remote Sensing*, 9(8). <https://doi.org/10.3390/rs9080828>
- Pelosi, F., Castaldi, F., & Casa, R. (2015). Operational unmanned aerial vehicle assisted post-emergence herbicide patch spraying in maize: a field study. In *Precision agriculture '15* (pp. 159–166). Brill | Wageningen Academic. https://doi.org/10.3920/978-90-8686-814-8_19
- Peña, J. M., Torres-Sánchez, J., de Castro, A. I., Kelly, M., & López-Granados, F. (2013). Weed Mapping in Early-Season Maize Fields Using Object-Based Analysis of Unmanned Aerial Vehicle (UAV) Images. *PLoS ONE*, 8(10), 1–11. <https://doi.org/10.1371/journal.pone.0077151>
- Primicerio, J., Di Gennaro, S. F., Fiorillo, E., Genesio, L., Lugato, E., Matese, A., & Vaccari, F. P. (2012). A flexible unmanned aerial vehicle for precision agriculture. *Precision Agriculture*, 13(4), 517–523. <https://doi.org/10.1007/s11119-012-9257-6>
- Rai, N., Zhang, Y., Ram, B. G., Schumacher, L., Yellavajjala, R. K., Bajwa, S., & Sun, X. (2023). Applications of deep learning in precision weed management: A review. *Computers and Electronics in Agriculture*, 206(January), 107698. <https://doi.org/10.1016/j.compag.2023.107698>
- Rosas, D. L., Gonzalez, U. G., & Huitron, V. G. (2022). *A Multispectral U-Net Framework for Crop-Weed Semantic Segmentation* (pp. 15–24). https://doi.org/10.1007/978-3-030-82064-0_2
- Rüegg, W. T., Quadranti, M., & Zoschke, A. (2007). Herbicide research and development: Challenges and opportunities. *Weed Research*, 47(4), 271–275. <https://doi.org/10.1111/j.1365-3180.2007.00572.x>
- Said, K. A. M., Jambek, A. B., & Sulaiman, N. (2016). A study of image processing using morphological opening and closing processes. *International Journal of Control Theory and Applications*, 9(31), 15–21.
- Sisodia, P. S., Tiwari, V., & Kumar, A. (2014). Analysis of Supervised Maximum Likelihood Classification for remote sensing image. *International Conference on Recent Advances and Innovations in Engineering, ICRAIE 2014*, 14–17. <https://doi.org/10.1109/ICRAIE.2014.6909319>
- Sun, J., Yang, J., Zhang, C., Yun, W., & Qu, J. (2013). Automatic remotely sensed image

- classification in a grid environment based on the maximum likelihood method. *Mathematical and Computer Modelling*, 58(3–4), 573–581. <https://doi.org/10.1016/j.mcm.2011.10.063>
- Tamouridou, A. A., Alexandridis, T. K., Pantazi, X. E., Lagopodi, A. L., Kashefi, J., & Moshou, D. (2017). Evaluation of UAV imagery for mapping *Silybum marianum* weed patches. *International Journal of Remote Sensing*, 38(8–10), 2246–2259. <https://doi.org/10.1080/01431161.2016.1252475>
- Thorp, K. R., & Tian, L. F. (2004). A review on remote sensing of weeds in agriculture. *Precision Agriculture*, 5(5), 477–508. <https://doi.org/10.1007/s11119-004-5321-1>
- Torres-Sánchez, J., Peña, J. M., de Castro, A. I., & López-Granados, F. (2014). Multi-temporal mapping of the vegetation fraction in early-season wheat fields using images from UAV. *Computers and Electronics in Agriculture*, 103, 104–113. <https://doi.org/10.1016/j.compag.2014.02.009>
- Varela, S., Dhodda, P. R., Hsu, W. H., Prasad, P. V. V., Assefa, Y., Peralta, N. R., Griffin, T., Sharda, A., Ferguson, A., & Ciampitti, I. A. (2018). Early-season stand count determination in Corn via integration of imagery from unmanned aerial systems (UAS) and supervised learning techniques. *Remote Sensing*, 10(2). <https://doi.org/10.3390/rs10020343>
- Wang, A., Xu, Y., Wei, X., & Cui, B. (2020). Semantic Segmentation of Crop and Weed using an Encoder-Decoder Network and Image Enhancement Method under Uncontrolled Outdoor Illumination. *IEEE Access*, 8, 81724–81734. <https://doi.org/10.1109/ACCESS.2020.2991354>
- Yao, X., Wang, N., Liu, Y., Cheng, T., Tian, Y., Chen, Q., & Zhu, Y. (2017). Estimation of wheat LAI at middle to high levels using unmanned aerial vehicle narrowband multispectral imagery. *Remote Sensing*, 9(12). <https://doi.org/10.3390/rs9121304>
- Yu, J., Schumann, A. W., Cao, Z., Sharpe, S. M., & Boyd, N. S. (2019). Weed Detection in Perennial Ryegrass With Deep Learning Convolutional Neural Network. *Frontiers in Plant Science*, 10(October), 1–9. <https://doi.org/10.3389/fpls.2019.01422>
- Yu, Z., Cao, Z., Wu, X., Bai, X., Qin, Y., Zhuo, W., Xiao, Y., Zhang, X., & Xue, H. (2013). Automatic image-based detection technology for two critical growth stages of maize: Emergence and three-leaf stage. *Agricultural and Forest Meteorology*, 174–175(June), 65–84. <https://doi.org/10.1016/j.agrformet.2013.02.011>
- Zanin, G., Berti, A., & Giannini, M. (1992). Economics of herbicide use on arable crops in north-central Italy. *Crop Protection*, 11(2), 174–180. [https://doi.org/10.1016/0261-2194\(92\)90102-B](https://doi.org/10.1016/0261-2194(92)90102-B)
- Zanin, G., Ferrero, A., & Sattin, M. (2011). La gestione integrata delle malerbe: Un approccio sostenibile per il contenimento delle perdite di produzione e la salvaguardia dell'ambiente.

- Italian Journal of Agronomy*, 6(SUPPL. 2), 31–38. <https://doi.org/10.4081/ija.2011.6.s2.e6>
- ZOHAIB, A., ABBAS, T., & TABASSUM, T. (2016). Weeds Cause Losses in Field Crops through Allelopathy. *Notulae Scientia Biologicae*, 8(1), 47–56. <https://doi.org/10.15835/nsb.8.1.9752>
- ZOSCHKE, A. e QUADRANTI, M. (2002). *Weed Biology and Management*. <https://doi.org/https://doi.org/10.1046/j.1445-6664.2002.00039.x>
- Zou, K., Chen, X., Zhang, F., Zhou, H., & Zhang, C. (2021). A field weed density evaluation method based on uav imaging and modified u-net. *Remote Sensing*, 13(2), 1–19. <https://doi.org/10.3390/rs13020310>

7. Sitografia

<https://agrielectronics.blogspot.com/2013/10/portable-crop-health-sensor.html>

<https://bim.acca.it/droni-in-edilizia/>

<https://cnes.fr/en/media/iss2adsjpg>

https://docs.opencv.org/2.4/modules/ml/doc/neural_networks.html

<https://enterprise.dji.com/it/mavic-3-enterprise/specs>

<https://it.wikipedia.org/wiki/Veneto>

https://nik.bg/en/precision-farming_/weedseeker-system/

<https://phototrend.fr/guides-dachat-phototrend-meilleurs-drones-photo-et-video/>

<https://www.comunicitta.it/frazioni-del-comune-di-padova-28060>

<https://www.nextfarming.fr/agriculteur/produits/technologie-de-capteurs/next-greenseeker>

8. Ringraziamenti

Alla mia relatrice, Prof.ssa Roberta Masin, esprimo la mia riconoscenza per avermi concesso l'opportunità di esplorare il tema a me particolarmente caro.

Al mio correlatore Dott. Nebojša Nikolić, per la sua disponibilità e sostegno dimostratomi durante questo percorso, anche nelle ore più insolite.

Alla DRONEZONE, desidero esprimere la mia gratitudine per la cortese fornitura dei dati indispensabili per la corretta esecuzione delle attività lavorative in questione.

Alla mia famiglia, per aver creduto nelle mie capacità e per avermi dato fiducia in questo nuovo percorso. Ogni successo ottenuto è stato possibile anche grazie vostro costante sostegno.

A Sara, grazie per aver condiviso con me i momenti più felici di questo percorso ma anche per essermi stata vicino e per avermi incoraggiato nei momenti più difficili. Grazie per la pazienza dimostrata, soprattutto nell'ultimo periodo, sono grato di avervi al mio fianco e di poter condividere con te questo importante traguardo.