POLITECNICO DI TORINO

Corso di Laurea Magistrale in Ingegneria per l'Ambiente e il Territorio

TESI DI LAUREA MAGISTRALE

Very Deep Super Resolution (VDSR): Applicazione su dati acquisiti da UAV e da satellite in ambito agricoltura di precisione

Relatore:
Prof. Lingua Andrea Maria

Candidato:
Marco Pillosu, S262906

Anno accademico 2019/2020

SOMMARIO

1 INTRODUZIONE 1

2 TELERILEVAMENTO 3

2.1 Sensori e piattaforme 6

2.1.1 Spaceborne platforms 8

2.1.2 Airborne platforms 9

2.1.2.1 Sensori per UAV 11

2.1.3 Ground based platforms 15

3 TELERILEVAMENTO IN AGRICOLTURA 16

3.1 UAV in agricoltura di precisione 19

3.2 Vantaggi dell'agricoltura di precisione 21

4 DEEP LEARNING NEL TELERILEVAMENTO 22

4.1 Concetti base di deep learning 22

4.2 Very Deep Super-Resolution (VDSR) 24

5 CASO STUDIO 29

5.1 Strumentazione 30

5.2 Acquisizione dei dati 32

5.3 Elaborazione delle immagini 33

6 APPLICAZIONE DELLA RETE NEURALE 42

6.1 Creazione del data set di training 42

6.2 Aumento del data set di training 43

6.3 Parametri del training 43

6.4 Esecuzione della rete VDSR e miglioramento dell'output 43

6.5 Descrizione del codice 45

7 RISULTATI 51

7.1 Analisi su un'area di 1,5 ettari 51

7.1.1 Calcolo NDVI 54

7.1.2 Confronto con interpolazione bicubica 55

7.2 Analisi su un’area di 26 ettari 59
8 CONCLUSIONI 62
9 RINGRAZIAMENTI 64
10 BIBLIOGRAFIA 65
11 ALLEGATI 70
11.1 Specifiche tecniche Phantom 4 di DJI 70
11.2 Codice rete VDSR 72
11.3 Elaborati grafici 77

1 INTRODUZIONE

Il telerilevamento è una tecnologia che trova applicazione in numerosi contesti. In particolare, svolge un ruolo primario nel monitoraggio ambientale. Uno dei principali ambiti di applicazione del telerilevamento è l'agricoltura, in cui viene impiegato per il monitoraggio e, per la predizione della produzione agricola stagionale e, di conseguenza, per l'ottimizzazione della produzione stessa. Misurando la riflettanza della vegetazione a varie lunghezze d'onda è possibile raccogliere molte informazioni sullo stato delle piante.

I progressi nella tecnologia di telerilevamento e il costo ridotto dei sensori consentono oggigiorno un uso più diffuso di tali apparecchiature. Con l'uso di questi sensori è possibile identificare quali particolari aree del campo hanno bisogno di un qualche trattamento, per poter così concentrare l'irrigazione o l'applicazione di sostanze chimiche solo in aree specifiche e ben individuate. In questo modo si diminuisce la quantità di sostanze chimiche utilizzate e, in generale, si riducono i costi e si abbatte l'impatto ambientale.

Nelle pratiche più tradizionali i vari trattamenti delle colture, come l'irrigazione, l'applicazione di fertilizzanti, pesticidi ed erbicidi, vengono applicati uniformemente, ignorando qualsiasi variabilità all'interno del campo. L'insieme delle pratiche agricole che si concentrano su aree specifiche del campo in un determinato momento nel tempo rientra, invece, nella c.d. agricoltura di precisione.

Poiché l'agricoltura di precisione opera su singole porzioni, di piccole dimensioni, all'intero di aree più vaste, è necessaria una precisione spaziale molto elevata. I dati acquisiti da satellite, caratterizzati da risoluzioni piuttosto basse, in questo ambito, non sempre risultano sufficienti: proprio per tale ragione negli ultimi anni ha subito un forte sviluppo l'utilizzo di aeromobili a pilotaggio remoto (o UAV, dall'acronimo inglese "*Unmanned aerial vehicle*"), comunemente noti come "droni".

Parimenti, in questo contesto, può risultare fondamentale l'applicazione di reti neurali e, in particolare, l'applicazione della Super-Risoluzione, ossia il processo per aumentare la risoluzione di un'immagine.

Il presente studio si focalizza sull'applicazione della rete neurale VDSR (Very Deep Super Resolution), il cui obiettivo è quello di recuperare gli elementi di dettaglio che non è possibile apprezzare nell'immagine a bassa risoluzione di partenza.

Il metodo consiste nell'addestrare la rete neurale VDSR in modo che essa sia in grado di fornire un'immagine ad alta risoluzione a partire da un'immagine a bassa risoluzione.

L'addestramento della rete neurale viene eseguito con immagini estratte dall'ortomosaico generato a partire dai dati acquisiti con UAV; come dato di input vengono impiegate immagini satellitari acquisite da *Sentinel-2*.

Il presente lavoro è finalizzato alla valutazione della VDSR per applicazioni di monitoraggio in agricoltura di precisione, mediante analisi sia su immagini a colori reali che su immagini a falsi colori.

2 TELERILEVAMENTO

Il telerilevamento è la disciplina tecnico-scentifica che si occupa di acquisire informazioni di carattere spettrale, spaziale e temporale su oggetti materiali, su una determinata area o relativamente a uno specifico fenomeno, senza entrare in contatto fisico con l'oggetto di studio, o con il fenomeno in esame. Il trasferimento di informazioni è realizzato mediante l'uso di radiazioni elettromagnetiche (EMR) emesse o riflesse dagli oggetti osservati.

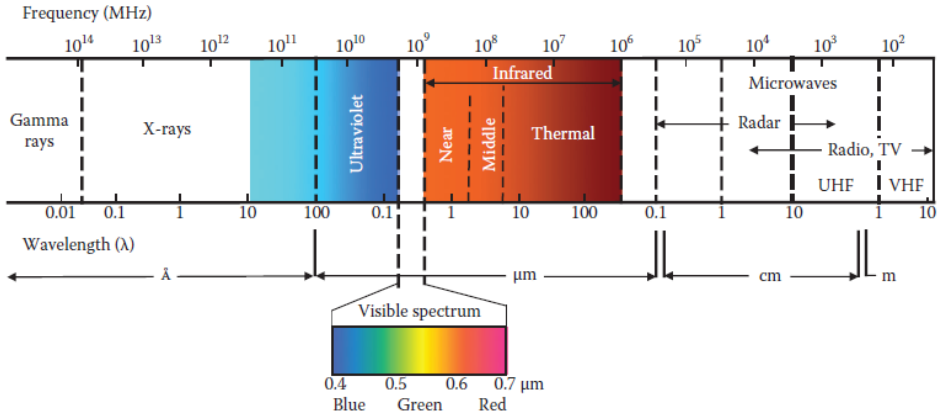

Figura 2.1 Bande dello spettro elettromagnetico [1]

Il telerilevamento è, dunque, la misurazione o l'acquisizione di informazioni di alcune proprietà di un oggetto o fenomeno, da un dispositivo di registrazione che non è in contatto con l'oggetto o il fenomeno in esame. [2]

I dispositivi che vengono utilizzati in questo ambito sono diversi: fotocamere, laser e ricevitori a radiofrequenza, sistemi radar.

Questa tecnologia è ampiamente impiegata nell' osservazione della superficie terrestre. Nello svolgimento di tale attività i sensori sono posti a quote elevate in modo tale da poter acquisire immagini di aree molto vaste. I sensori non usano solo la luce visibile ma operano anche mediante altre bande dello spettro elettromagnetico (*Figura 2.1*) come infrarossi, microonde e ultravioletto [1].

Negli ultimi decenni il telerilevamento ha subito degli sviluppi tali da essere, oggigiorno, uno strumento fondamentale per la raccolta di informazioni su quasi ogni aspetto della terra.

Il telerilevamento può trovare applicazione in numerosi contesti [3], accomunati dalla necessità di acquisire dati relativi a un'area molto estesa. Attualmente tra le applicazioni del telerilevamento si ha la mappatura e l'analisi dell'uso del suolo, il monitoraggio della vegetazione in ambito agricolo e forestale, il monitoraggio delle risorse idriche, della neve e del ghiaccio, della fauna selvatica, le indagini archeologiche, la gestione di eventi calamitosi, la gestione delle risorse costiere, applicazioni in ambito militare e molte altre.

Ogni applicazione ha necessità di sensori con caratteristiche tecniche differenti, con specifiche capacità di risoluzione spettrale, risoluzione spaziale, risoluzione radiometrica e risoluzione temporale. Inoltre, i sistemi di telerilevamento possono fornire dati e informazioni in aree in cui l'accesso è difficile a causa della conformazione terreno o delle condizioni meteorologiche.

Nel telerilevamento è inoltre compresa anche l'analisi e l'interpretazione di dati e immagini. Questo aspetto è fondamentale in quanto per poter cogliere le informazioni chiave per l'obiettivo che si sta perseguendo bisogna avere buona comprensione della base fisica e del processo di acquisizione, nonché di una solida conoscenza degli algoritmi utilizzati per elaborare i dati.

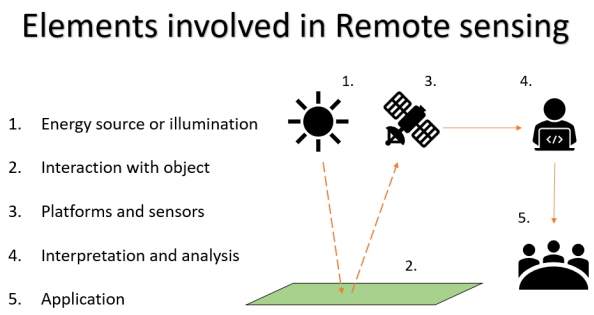

Figura 2.2 Schema degli elementi che costituiscono il telerilevamento

Il telerilevamento è una tecnica che coinvolge diversi elementi e più soggetti (*Figura 2.2*) [3].

- Una **fonte di energia**, in grado di produrre la radiazione elettromagnetica che interagendo con una superficie, possa essere captata dal sensore.

- Una **superficie terrestre** di riferimento, costituita da vegetazione, terreni, acqua, rocce, neve, ghiaccio e strutture di origine antropica. Tale superficie rice l'energia incidente emanata dalla sorgente e, a seguito dell'interazione fisica e chimica con l'energia in entrata, riflette ed emette una parte di quell'energia verso il sensore. Una parte dell'impulso energetico, o addirittura la sua interità, può essere filtrata dall'atmosfera, a seconda delle sue concentrazioni di gas e particolato, e della distanza tra superficie e sensore.

- **Sensore e piattaforma**. Il sensore è lo strumento che misura e registra l'energia proveniente dalla superficie. La piattaforma costituisce invece la base deputata a fornire i principali servizi per il funzionamento del sensore, come il controllo dell'orbita, l'alimentazione energetica e le comunicazioni con il sistema di ricezione al suolo. A seconda del tipo di piattaforma possono essere inclusi anche più sensori. I satelliti meteorologici, ad esempio, includono comunemente sensori per rilevare l'umidità atmosferica, la temperatura, le concentrazioni di ozono o le concentrazioni di aerosol.

- L'**analista**, che converte i dati immagine elaborati in informazioni tematiche di interesse, utilizzando tecniche visive e/o digitali.

- La **comunità di utenti**, che utilizza per le più svariate finalità le informazioni estratte.

2.1 Sensori e piattaforme

Come si ha appena avuto modo di spiegare, tra gli elementi fondamentali del telerilevamento ricoprono un ruolo primario le piattaforme e i sensori, che consentono l'acquisizione delle informazioni.

I sensori possono essere classificati in base diversi fattori [4]. Una delle classificazioni più comuni vede i sensori suddivisi in due gruppi: sensori passivi e sensori attivi.

I **sensori passivi** si limitano a misurare la radiazione elettromagnetica derivata da fonti esterne: ad esempio, l' energia della radiazione solare riflessa dalla superficie terrestre o l'energia direttamente emanata dalla Terra. Questi sensori sono stati ampiamente utilizzati nel telerilevamento negli ultimi decenni e includono fotocamere, scanner elettro-ottici e radiometri a microonde.

I **sensori attivi** sono invece quelli che misurano la radiazione emessa da una fonte di energia incorporata nello strumento stesso e che viene riflessa dalle superfici inquadrate. Questi sono in grado di inviare impulsi e registrare in seguito la loro riflessione per caratterizzare gli oggetti.

La strumentazione attiva più comune agli albori del telerilevamento era il radar, il quale, come è noto, utilizza le onde radio. Attualmente è diventata di uso più comune anche la tecnica LIDAR, che non solo permette di determinare la distanza di un oggetto o di una superficie utilizzando un impulso laser, ma è anche in grado di determinare la concentrazione di specie chimiche nell'atmosfera e nelle distese d'acqua. Come per il radar, che al posto della luce utilizza onde radio, la distanza dell'oggetto è determinata misurando il tempo trascorso fra l'emissione dell'impulso e la ricezione del segnale.

In base al numero di bande che sono in grado di acquisire, i sensori possono essere multispettrali o iperspettrali. I sensori multispettrali di solito riescono ad acquisire da 3 a 10 bande circa. Le bande che vengono normalmente acquisite sono quelle del visibile, rosso, verde, blu, e quella del vicino infrarosso. I sensori iperspettrali, invece, misurano l'energia in bande più strette e numerose rispetto ai sensori multispettrali. Le immagini iperspettrali, infatti, possono contenere fino a 200 (o più) bande spettrali.

I dati vengono acquisiti dai sensori, i quali devono essere installati su specifiche piattaforme, mezzi o veicoli. Droni, aerei e satelliti raccolgono la maggior parte dei dati ma molti di questi strumenti possono essere installati anche su piattaforme terrestri, come autocarri e trattori.

Nella figura seguente è riportato un semplice schema che descrive le tipologie di piattaforme (*Figura 2.3*).

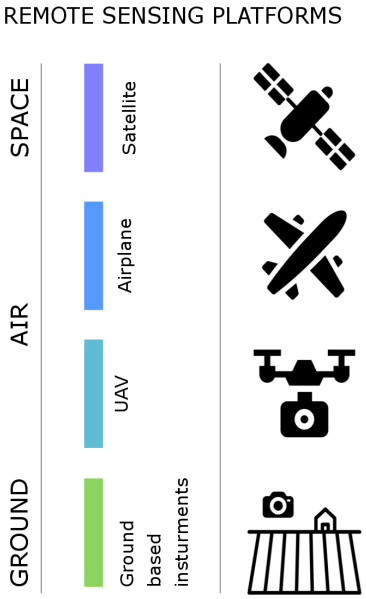

Figura 2.3 Schema delle piattaforme impiegate per il telerilevamento

2.1.1 Spaceborne platforms

Le *spaceborne platforms* sono quelle piattaforme che acquisiscono informazioni dallo spazio e sono principalmente i satelliti. Piattaforme di questo tipo, capaci di acquisire ampie aree di dati in un breve lasso di tempo, possono essere utilizzate per i1 monitoraggio della superficie terrestre, per studiare le dinamiche atmosferiche e per tante altre applicazioni.

Il telerilevamento mediante satelliti offre la possibilità di coprire grandi aree con una buona frequenza, ripetuta in un'area di interesse. Viene fornita una misura quantitativa delle caratteristiche della superficie inquadrata a un costo relativamente basso se considerato per unità di area di copertura.

È inoltre possibile acquisire immagini dell'intero pianeta senza particolari autorizzazioni, attraverso servizi messi gratuitamente a disposizione per il pubblico, dai vari enti spaziali, come la *European Space Agency* (ESA) o la *National Aeronautics and Space Administration* (NASA).

La frequenza con la quale i dati vengono acquisiti dipende dal sensore stesso e dalle caratteristiche dell'orbita satellitare. Un'orbita è un percorso circolare o ellittico descritto dal satellite nel suo movimento intorno alla Terra. Nell'ambito del telerilevamento, la frequenza di copertura totale varia da due volte al giorno a una volta ogni 16 giorni. I satelliti per il telerilevamento sono caratterizzati da tre possibili tipologie di orbita: orbita geostazionaria, orbita equatoriale e orbita eliosincrona. [4]

Il telerilevamento satellitare presenta diversi vantaggi rispetto ad altri metodi convenzionali di campionamento e monitoraggio ambientale, come le misurazioni sul campo o i sensori a terra. Le acquisizioni effettuate da satellite forniscono una visione globale sulla superficie terrestre, in momenti periodici e includendo regioni non visibili dello spettro elettromagnetico. I dati sono accessibili rapidamente e possono essere facilmente collegati ad altri database, creando così una fonte di informazioni adatta per l'integrazione dei dati spaziali. [1]

2.1.2 Airborne platforms

Le più tradizionali piattaforme aeree impiegate nel telerilevamento sono principalmente gli aerei ma, occasionalmente, vengono utilizzati anche gli elicotteri. Gli elicotteri, tuttavia, a causa della loro dinamica di volo mancano di stabilità.

In generale, più in alto un aereo può volare, più stabile è il suo volo, ma di conseguenza anche il costo aumenta. L'utilizzo di aerei come piattaforme presenta dunque lo svantaggio di implicare un alto costo in rapporto all'area di copertura a terra.

Negli ultimi anni a queste piattaforme si sono affiancati gli *Unmanned Aerial Vehicle* (UAV). I termini "UAV" e "drone", sono spesso impropriamente utilizzati in modo intercambiabile. In realtà, il termine "drone" individua strumenti con caratteristiche limitate, non adatti ad applicazioni complesse. Per tale ragione, nell'ambito del nostro studio, si parlerà di UAV, poiché i mezzi impiegati per il telerilevamento hanno generalmente delle caratteristiche tecniche superiori a quelle dei comuni "droni" impiegati per scopi ludici o amatoriali.

L'utilizzo di UAV come piattaforme offre un'elevata versatilità e flessibilità rispetto ai sistemi aviotrasportati o ai satelliti.

Tra i metodi di classificazione degli UAV [5] i più comuni sono basati sulla dimensione, sulla copertura spaziale e sull'altitudine massima raggiungibile. Un'altra classificazione piuttosto comune distingue gli UAV in UAV ad ala fissa o multirotore.

Gli **UAV ad ala fissa** sono caratterizzati da una struttura con ali più o meno rigide. La portanza si manifesta come risultato della forma dell'ala e della velocità dell'aereo, garantita da un motore elettrico o a combustione interna.

Gli **UAV multirotore** generano invece una spinta verticale. Creano portanza deviando l'aria verso il basso.

Nonostante gli UAV ad ala fissa si muovano a una velocità superiore e abbiano solitamente una capacità di carico superiore, il loro utilizzo è meno diffuso rispetto a quelli multirotore. Infatti, oltre al costo maggiore degli UAV ad ala fissa, questi necessitano di una pista di decollo/atterraggio e non possono effettuare un volo stazionario.

Gli UAV possono essere controllati manualmente o tramite un sistema di navigazione pre-programmato. Il controllo manuale di solito implica l'utilizzo di un *pad* o qualche tipo di dispositivo di puntamento (*mouse* o *trackball*) che consente di controllare la posizione dell'UAV regolando manualmente la direzione, l'altitudine e la velocità.

In confronto ad aerei e satelliti, gli UAV operano a quote inferiori, e le loro acquisizioni non dipendono dalle condizioni di copertura nuvolosa, ma le problematiche sono principalmente legate all'autonomia, che è inferiore rispetto a quella delle altre due piattaforme citate. Le acquisizioni da areo sono una via di mezzo tra le acquisizioni effettuate da satellite e quelle effettuate da UAV in quanto l'aereo ha flessibilità superiore rispetto al satellite e minore rispetto allo UAV e, al contempo, maggiore autonomia rispetto all'UAV ma inferiore rispetto al satellite. [6] [38]

Rispetto ai tradizionali approcci di telerilevamento, gli UAV sono una soluzione economica, flessibile e relativamente facile da usare per acquisire dati ad alta risoluzione spaziale e temporale.

Tabella 1 Comparazione delle caratteristiche delle piattaforme per il teleilevamento (++ ottimo, + buono, o medio, - scarso) [6]

		UAV	Aircraft	Satellite
Mission	Range	-	+	++
	Flexibility	++	+	-
	Endurance	-	++	++
	Cloud cover dependency	++	+	-
	Reliability	o	+	++
Processing	Payload	o	+	++
	Resolution	++	+	o
	Precision	++	+	o
	Mosaicking and geocoding effort	-	o	++
	Processing time	o	+	+

L'acquisizione di immagini rappresenta la loro applicazione più comune, tuttavia gli UAV vengono impiegati anche per applicazioni di non-imaging come, ad esempio, misurazioni di temperatura, pressione, umidità e campionamento atmosferico, utilizzando ad esempio sensori in grado di rilevare CO2, metano e altri gas. [7]

2.1.2.1 Sensori per UAV

Di seguito vengono riportate le caratteristiche di alcuni sensori multispettrali presenti in commercio.

La **Mapir Survey3** (*Figura 2.4*) è una camera multispettrale le cui immagini acquisite hanno una risoluzione di 12 megapixel (4000 x 3000 px) e sono in formato RAW e JPG, rispettivamente a 12 e 8 bit.

Figura 2.4 Camera Mapir Survey3 (sulla sinistra), Pacchetto dei target di calibrazione a terra (a destra) [8]

Questo tipo di camera è ideale per l'acquisizione di dati da zone vegetate. Infatti, grazie a essa, le immagini possono essere acquisite con sei differenti filtri, generati dalle combinazioni di tre differenti bande. I filtri sono OCN, RGN, NGB, RE, NIR e RGB. Ognuno di questi filtri si adatta meglio a certe caratteristiche della scena da acquisire.

Sulla camera montare due lenti ottiche diverse:

- La *Survey3W: (87° HFOV (19mm) f/2.8 Aperture, -1% Extreme Low Distortion (Non-Fisheye) Glass Lens);*
- la *Survey3N: (41° HFOV (47mm) f/3.0 Aperture, -1% Extreme Low Distortion (Non-Fisheye) Glass Lens).*

Per quanto riguarda la memoria, può essere dotata di Micro SD (fino a 128GB).

Una volta che le immagini sono catturate dalle telecamere modello OCN, RGN, NGB, RE e NIR, devono essere calibrate utilizzando il target di calibrazione mostrato nella figura sopra. Una volta calibrate le immagini possono essere trasferite ed elaborate in uno dei vari programmi come *Pix4D, Agisoft, Drone Deploy, Agribotix, MapsMadeEasy, Simactive, Icaros*, ecc.

La **Parrot Sequoia+** è una fotocamera multispettrale costituita da quattro fotocamere monocrome da 1,2 megapixel che acquisiscono in 4 lunghezze d'onda differenti. Una nel verde (550 nm), una nel rosso (660 nm), una nel *red edge* (735 nm) e una nell'infrarosso vicino (790 nm). In più è presente una quinta fotocamera da 16 milioni di pixel che acquisisce a colori reali (RGB).

Figura 2.5 Camera Parrot SEQUOIA+ (dx), sensore di luminosità (sx) [9]

Tale fotocamera è stata progetta con la specifica finalità di studiare lo stato di vigore della vegetazione attraverso la misurazione della quantità di luce assorbita dalle piante e poi riflessa. Oltre al sensore multispettrale è dotata anche di un sensore di luminosità.

Il sensore multispettrale rivolto verso le piante cattura la luce che riflettono in quattro bande: nella banda del verde, del rosso e in due bande infrarosse, invisibili all'occhio umano. Posizionato sul drone, il sensore della luminosità registra l'intensità della luce emanata dal sole in queste quattro bande.

I dati acquisiti possono essere facilmente elaborati mediante il software Pix4D. Tramite esso è possibile effettuare una calibrazione radiometrica completa consentendo di ottenere misure precise di riflettanza senza l'utilizzo di pannelli di calibrazione

La **MAIA** è una camera multispettrale, appositamente progettata per essere applicata all'agricoltura di precisione e per altre applicazioni di monitoraggio ambientale. Essa viene fornita con i dati di ***cal***ibrazione geometrica di ciascuna lente.

Figura 2.6 MAIA fronte (sx) e retro(dx) [10]

La telecamera è dotata di 9 sensori d'immagine, di cui 8 sono monocromatici, mentre il restante acquisisce a colori reali (RGB). I sensori offrono una risoluzione di 1.2 megapixel. I sensori sono accoppiati con filtri passa banda e acquisiscono lunghezze d'onda comprese tra i 395 nm e i 950 nm, comprendendo sia la regione dello spettro visibile (VIS) che la regione vicino infrarosso (NIR).

La camera è dotata di tecnologia *Global shutter* che garantisce l'acquisizione simultanea di immagini prive di artefatti da movimento a un frame rate fino a 5 Hz.

La MAIA può essere interfacciata con un modulo GPS esterno per comandare lo scatto automatico con l'acquisizione delle coordinate della posizione. La camera memorizza le immagini geo-referenziate nella memoria interna**.**

Il *software* per il pre-processamento dei dati è incluso nel pacchetto MAIA e consente di unire le singole immagini scattate per ciascuna banda in un'unica immagine. Fornisce inoltre, la possibilità di effettuare il calcolo di indici agronomici come l'NDVI o altri indici personalizzati.

2.1.3 Ground based platforms

Le piattaforme a terra includono dispositivi portatili, treppiedi, gru, torri e veicoli terrestri [4]. Le piattaforme a terra sono relativamente poco costose, stabili e, essendo impiegate a livello del terreno, forniscono dati ad alta risoluzione.

Gli strumenti a terra, ponendosi a una distanza ravvicinata dagli oggetti da esaminare, sono spesso utilizzati per una caratterizzazione di dettaglio di oggetti di dimensioni contenute. Ad esempio, per studiare le proprietà di una singola pianta o di una piccola macchia d'erba, avrebbe senso utilizzare uno strumento a terra.

Una sottocategoria degli strumenti a terra sono le piattaforme terrestri permanenti, tipicamente utilizzate per monitorare i fenomeni atmosferici. Le torri e le gru sono spesso utilizzate nell'ambito di progetti di ricerca in cui è necessaria una piattaforma ragionevolmente stabile e a lungo termine.

3 TELERILEVAMENTO IN AGRICOLTURA

Uno dei principali ambiti di applicazione del telerilevamento è l'agricoltura. Le informazioni acquisite possono riguardare il terreno, lo stato di salute della vegetazione e la fase di maturazione del prodotto finale. In questo modo si può determinare il momento ideale per il raccolto. Tutte queste informazioni, grazie a questa tecnologia, possono essere ottenute in tempi brevi su superficie ampie, e più volte nel corso del ciclo colturale.

L'applicazione del telerilevamento, in agricoltura così come negli altri ambiti, è fondata sul concetto di firma spettrale, e quindi di energia assorbita e riflessa dalle superfici. Le firme spettrali, specifiche per le varie superfici, sono la variazione della riflettività in funzione della lunghezza d'onda dell'energia elettromagnetica riflessa per superfici omogenee.

Le proprietà spettrali e la caratterizzazione della vegetazione sono uno dei problemi più importanti e impegnativi nel telerilevamento. Le proprietà di riflettanza delle fronde della vegetazione sono complesse e sono il risultato di molti fattori biochimici e biofisici e dei fattori esterni che influenzano il segnale rilevato al sensore.

La firma spettrale complessiva di una foglia o di una pianta è influenzata dall'età delle foglie, dallo stress nutritivo e dalla salute (malattia, vigore, ecc.). Una tipica firma di riflettanza spettrale di una foglia verde ottenuta dalle misurazioni di laboratorio è illustrata nella figura seguente.

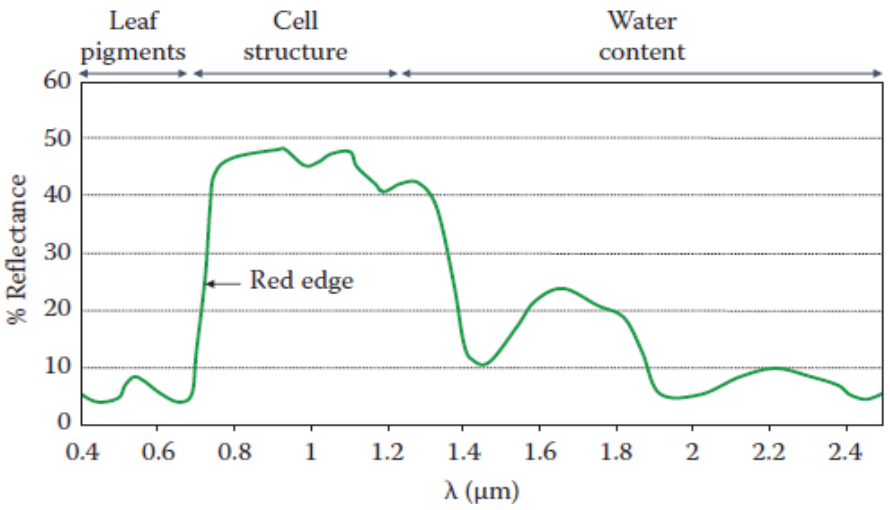

Figura 3.1 Firma spettrale della vegetazione [1]

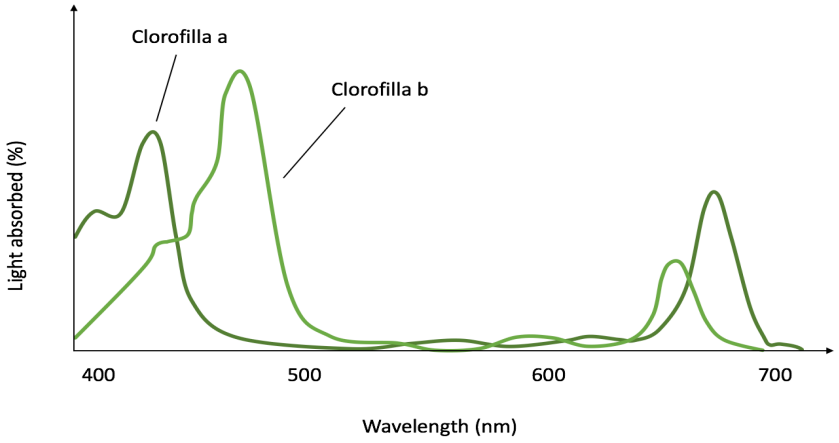

Figura 3.2 Spettro di assorbimento della clorofilla a e clorofilla b

Ci sono tre principali domini spettrali che influenzano le proprietà ottiche delle foglie, vale a dire il visibile (VIS), l'infrarosso vicino (NIR) e il dominio dell'infrarosso a onde corte (SWIR).

La bassa riflettanza nella regione del VIS (0,4–0,7 m) è dovuta all'effetto assorbente dei pigmenti delle foglie, principalmente clorofilla a, clorofilla b, carotenoidi e xantofuli. La clorofilla rappresenta il 65% dei pigmenti ed è responsabile

dell'assorbimento nella regione del blu dello spettro EM centrata su lunghezze d'onda di 0,45 μm, e anche nella regione del rosso dello spettro, 0,65 μm.

Tra le regioni spettrali del blu e del rosso, c'è una regione spettrale di radiazioni meno intensamente assorbite, un picco di riflettanza nel verde a 0,55 μm, che è responsabile dell'aspetto verde delle foglie sane.

Nelle bande dell'Infrarosso vicino (NIR), tra 0,7 e 1,35 μm il comportamento spettrale è funzione della struttura fogliare, ossia l'organizzazione delle cellule della foglia, che varia da una specie all'altra e in base allo stato di salute della pianta.

Infine, nel dominio dell'infrarosso a onde corte (SWIR), tra i 1.35 e i 2.70 μm, le proprietà spettrali dipendono dal contenuto d'acqua nella foglia. In tal modo si può avere un metodo di diagnostica dello stress idrico della vegetazione.

Il telerilevamento della vegetazione viene eseguito principalmente ottenendo le informazioni sulla riflettanza delle onde elettromagnetiche dalle foglie utilizzando sensori passivi. A partire dalla combinazione della percentuale di radiazione riflessa nelle diverse bande è possibile calcolare gli indici di vegetazione.

L'indice per la vegetazione attualmente più utilizzato è il *Normalized Difference Vegetation Index* (NDVI) proposto per la prima volta da Rouse Jr. e altri [11]. Esso si esprime come:

$$NDVI = \frac{(\rho_{NIR} - \rho_{RED})}{(\rho_{NIR} + \rho_{RED})},$$

Dove ρ indica la misura di riflettanza spettrale delle regioni del rosso (ρ_{RED}) e del vicino infrarosso (ρ_{NIR}).

L'intervallo di valori dell'NDVI è compreso tra -1 e 1 e descrive il livello di vigoria della coltura.

Tabella 2: Interpretazione valori NDVI (Dalezios, 2002) [12]

NDVI	INTERPRETAZIONE
0.5 - 1	Thick Vegetation
0.140 - 0.5	Medium Vegetation
0.09 – 0.140	Scarce Vegetation
0.025 – 0.090	Bare Ground
0.020 – 0.025	Clouds
-0.046 – 0.020	Ice and Snow
-1 – -0.046	Water

Il valore dell'NDVI medio in un campo dipende sia dalla fase fenologica della coltura. A parità di stadio fenologico, le aree con NDVI molto inferiore rispetto al valore medio del campo sono soggette a problemi di sviluppo, dipendenti da vari fattori: stress nutrizionale, presenza di parassiti, danni generati da eventi calamitosi importanti.

Per rappresentare visivamente le aree potenzialmente problematiche all'interno di un campo, si può realizzare una mappa dei valori di NDVI il valore minimo e il valore massimo di NDVI nel campo.

3.1 UAV in agricoltura di precisione

La mappatura della vegetazione con gli UAV ha recentemente trovato molte applicazioni nell'agricoltura di precisione.

Il principale vantaggio degli UAV rispetto ad altre piattaforme di telerilevamento è rappresentato dalla capacità di raccogliere dati ad alta risoluzione spaziale con una certa flessibilità, in quanto essi consentono all'utente di definire tempi di acquisizione appropriati per i fenomeni esaminati.

I prodotti più comuni delle indagini sulla vegetazione UAV multispettrale sono le mappe ortorettificate di riflettanza superficiale e gli indici di vegetazione (VI),

come il *Normalized difference Vegetation Index* (NDVI). Oltre all'NDVI i dati forniti dai sensori ottici dei sistemi di immagini multispettrali e iperspettrali sono sfruttati per calcolare anche altri indici come il *wide dynamic range vegetation index*, il *normalised difference red-edge inde*x e altri ancora. Tuttavia, tra l'ampia gamma di indici spettrali definiti, l'indice di variazione normalizzata (NDVI) è uno dei più ampiamente utilizzati, in quanto strettamente correlato alla vigoria delle colture e, quindi, alla stima della qualità e quantità di produzione agricola.

Le immagini multispettrali satellitari (MSI), grazie alle caratteristiche dei sensori e all'altitudine delle piattaforme, coprono aree estese e molti programmi satellitari (come *Landsat, Modis, Aster, SPOT, Sentinel-1* e *Sentinel-2*) forniscono attualmente set di dati gratuiti, favorendo così lo sfruttamento delle immagini satellitari per molte applicazioni agricole.

Il problema principale legato alle immagini satellitari è la risoluzione spaziale. Ad esempio, *Sentinel-2* offre una risoluzione decametrica. Immagini satellitari a risoluzione decametrica risultano sicuramente più efficaci nel descrivere lo stato e la variabilità della vegetazione se applicate ad aree molto vaste come foreste o piantagioni estensive.

Tuttavia, quando si considerano colture con *layout* discontinuo, come vigneti e frutteti, il telerilevamento diventa più impegnativo [13]. In effetti, la presenza di percorsi inter-fila e vegetazione erbacea all'interno del campo può influenzare profondamente il calcolo degli indici spettrali complessivi, portando a una valutazione parziale dello stato delle colture. Le piattaforme a bassa quota, come gli UAV, fornendo immagini con un'alta risoluzione spaziale (anche di pochi centimetri) e una programmazione di volo flessibile, consentono di distinguere più facilmente le viti dalle erbacce e altri oggetti.

3.2 Vantaggi dell'agricoltura di precisione

Il telerilevamento rappresenta un modo pratico, sistematico ed economico di acquisire e aggiornare le informazioni finalizzate alla gestione dei processi produttivi; in particolare, mediante l'impiego di UAV [14].

L'adozione di pratiche sostenibili per il processo di produzione attuato da un'azienda agricola è oggi uno dei più importanti e strategici aspetti per il miglioramento dell'efficienza in agricoltura e la soluzione di alcune problematiche ambientali [15] [16].

L'Agricoltura di precisione si basa sui principi di un'agricoltura conservativa che è costituita da un insieme di pratiche agricole che mirano alla conservazione delle caratteristiche degli appezzamenti agricoli e a ottimizzare l'uso delle risorse ambientali, cercando di ridurre nello stesso tempo il degrado del terreno, attraverso una gestione integrata e razionale del suolo, dell'acqua e delle risorse biologiche esistenti, in associazione con i fattori di produzione esterni.

L'adozione di sistemi in grado di consentire l'esecuzione degli interventi colturali a intensità variabile rappresenta un'opportunità per programmare con precisione l'intensità degli interventi sul terreno, la distribuzione di fertilizzanti e di fitofarmaci. La possibilità di effettuare una razionalizzazione degli interventi in base alle esigenze effettive riscontrate in un appezzamento del terreno e della coltura in atto rappresenta un'importante prospettiva per le aziende agricole.

I benefici, anche di natura economica [17] [18], derivano da una generale ottimizzazione degli interventi agronomici e da una razionalizzazione delle pratiche agricole. L'entità dei benefici conseguibili, non solo economici, è comunque variabile. In particolare, va rilevato che i benefici ambientali saranno direttamente proporzionali alla capacità di monitorare gli effetti dei trattamenti e la loro distribuzione [19].

4 DEEP LEARNING NEL TELERILEVAMENTO

L'applicazione del *deep learning* al telerilevamento è sempre più frequente e l'aumento degli articoli pubblicati sull'argomento conferma il crescente interessamento da parte della comunità scientifica [20] [21].

4.1 Concetti base di deep learning

Le reti neurali tradizionali hanno un *layer* di input, un *layer* di output e due o tre livelli *hidden layer*.

I *deep neural networks*, invece, hanno un livello di input, un livello di output e possono avere fino a centinaia di *hidden layer*. Più è alto il numero degli *hidden layer* più la rete è definite "profonda". Per la loro complessità, i *deep network* richiedono elevata potenza di elaborazione e velocità di calcolo, database di grandi dimensioni e un software appropriato.

Nonostante le complesse strutture che caratterizzano tutti i metodi basati sul *deep learning*, questi sono descritti da uno schema generale (*Figura 4.1*) che include tre componenti principali: i dati di input, gli *hidden layer* e i dati di output. I dati di input e quelli di output attesi sono dipendenti dal tipo di applicazione.

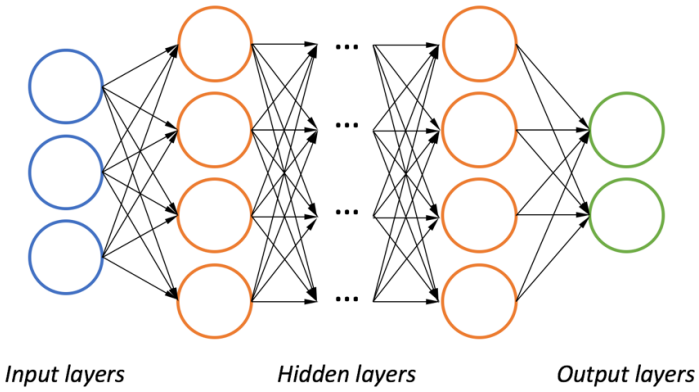

Figura 4.1 Schema generale dei Deep Neural Network

I *Convolutional Neural Network* (CNN) sono un tipo di rete di *deep learning*, ispirati alla struttura della corteccia visive dei mammiferi [22]. Sono già stati applicati con successo nell'ambito della classificazione delle immagini [23] e dell'identificazione di oggetti [24] e recentemente sono stati applicati anche all'ambito della super risoluzione [25].

I CNN devono il loro nome ai *layer* convoluzionali che li caratterizzano. Ogni *layer* convoluzionale contiene al suo interno dei filtri che individuano e permettono di estrarre delle caratteristiche, come forme, bordi o spigali, dall'immagine di input.

Il processo di convoluzione, che caratterizza i *layer* convoluzionali, consiste nello scorrimento di un filtro, ossia una matrice di dimensioni solitamente contenute, ad esempio 3×3, su un'immagine; e nel calcolo, a partire dai pixel inquadrati di una "*activation map*" la cui dimensione è definita da alcuni parametri che vanno definiti prima dell'esecuzione della convoluzione. Questi parametri sono: il numero di filtri, il passo o *stride* con cui il filtro scorre sull'immagine di input e l'applicazione o meno dello *zero padding*, ossia la generazione di una cornice di pixel con valore nullo che viene inserita all'immagine di output che altrimenti avrebbe dimensione ridotta rispetto a quella di input.

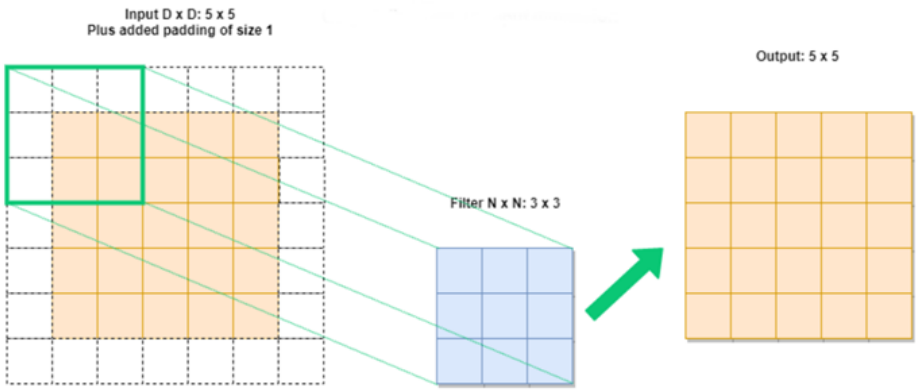

Figura 4.1 Schema di funzionamento del layer convoluzionale [26]

I *valori* di questi filtri da sola durante il processo training della rete neurale. Maggiore è il numero di filtri che abbiamo, più funzionalità dell'immagine vengono estratte e migliore è la nostra rete a riconoscere i modelli in immagini invisibili.

I primi CNN erano finalizzati principalmente per scopi di riconoscimento di elementi semplici, come ad esempio le cifre [27]. La struttura di queste prime reti neurali affianca ai *layer* convoluzionali i *layer* ReLU (*Rectified Linear Unit*) che, posti di seguito ai *layer* convoluzionali, sostituiscono con zero tutti i pixel di valore negativo della mappa di attivazione, e altre tipologie di *layer* a seconda dell'applicazione della rete neurale.

Sulla base di quelle prime ricerche sono state definite numerosissime reti convoluzionali ognuna delle quali con una sua architettura che dipende dall'applicazione per cui viene progettata.

4.2 Very Deep Super-Resolution (VDSR)

La qualità delle immagini dipende fortemente dalla qualità dei sensori e, nella maggior parte dei casi, l'accesso a sensori ad alta precisione in grado di osservare la Terra ad alta risoluzione, è complicato.

Recentemente, la disponibilità di immagini satellitari a basso costo e a bassa risoluzione è molto aumentata. Per esempio, i dati forniti dai satelliti della famiglia *Sentinel* sono distribuiti ad accesso libero sul portale ESA [28].

Sebbene queste soluzioni offrano prospettive molto interessanti in termini di copertura e di ripetibilità dell'acquisizione, c'è un distacco tra le loro capacità e l'attuale necessità di immagini ad alta risoluzione spaziale.

Gli studi che di recente si sono concentrati sulle tecniche di *deep learning* per il miglioramento della risoluzione di immagini a bassa risoluzione sono diversi [20] [21] [29].

Queste tecniche considerano la stima delle immagini ad alta risoluzione come un problema di apprendimento automatico, con la relazione tra l'input a risoluzione inferiore e l'output ad alta risoluzione non specificato in modo esplicito, ma appreso dai dati di esempio.

Gli approcci basati sul *deep learning* acquisiscono relazioni molto complesse e di conseguenza, richiedono grandi quantità di dati di training e grandi risorse computazionali.

In base al numero di immagini di input a bassa risoluzione, è possibile suddividere i metodi in *multi-image super-resolution* (MISR) e *single-image super-resolution* (SISR). Dal confronto di queste due categorie si nota che il metodo SISR è molto più popolare e può risultare più efficiente [30].

La super-risoluzione richiede che la maggior parte delle informazioni contenute in un'immagine a bassa risoluzione sia preservata e trasmessa nell'immagine ad alta risoluzione che viene generata. I vari modelli sono quasi tutti basati sulla generazione di residui tra un'immagine a bassa risoluzione e quella ad alta risoluzione. [31]

Tra queste tecniche si ha anche la *Very Deep Super-Resolution* (VDSR), la quale è stata applicata al caso studio in esame. La VDSR è una rete neurale convoluzionale progettata per eseguire, a partire da una singola immagine, un miglioramento della sua risoluzione [32].

La rete VDSR impara a stimare un'immagine residua, ossia la differenza tra un'immagine ad alta risoluzione e un'immagine a bassa risoluzione. L'immagine residua contiene informazioni sui dettagli ad alta frequenza dell'immagine e viene calolata, come differenza tra l'immagine ad alta risoluzione e quella a bassa risoluzione, sul canale della luminanza (Y):

$$Y_{residual} = Y_{High\ Res} - Y_{Low\ Res};$$

La strategia di apprendimento si basa sul fatto che le immagini a bassa risoluzione e quelle ad alta risoluzione hanno un contenuto simile e differiscono principalmente nei dettagli ad alta frequenza [33].

La stima dell'immagine residua dall'immagine di input viene eseguita a partire dai dati di training e, una volta stimata, viene sommata al canale della luminanza dell'immagine di partenza, ricampionato mediante interpolazione bicubica, generando così un'immagine a risoluzione aumentata.

La rete impiegata è composta da 41 *layer*: un livello di input, 19 coppie di *layer* convoluzionali e *layer* ReLU e un'ultima coppia in cui il *layer* convoluzionale non è seguito da un *layer* ReLU ma da un *layer* di regressione che ricostruisce l'immagine.

I *layer* convoluzionali individuano delle *feature* delle immagini, come ad esempio curve, angoli, circonferenze o quadrati mediante l'utilizzo di filtri. Maggiore è il numero di filtri applicabili maggiore è la complessità delle *feature* che si potranno individuare. I *layer* ReLU hanno la funzione di annullare i valori negativi ottenuti nei *layer* convoluzionali che li precedono. [25]

Il primo livello, *imageInputLayer*, suddivide l'immagine in porzioni la cui dimensione è definita dal campo ricettivo della rete, ovvero l'area dell'immagine che influisce sulla risposta del livello successivo della rete.

La dimensione del campo ricettivo corrisponde alla quantità di informazioni che possono essere sfruttate per dedurre componenti ad alta frequenza. Un campo ricettivo di grandi dimensioni implica che la rete ha a disposizione più elementi per prevedere i dettagli dell'immagine.

La dimensione del campo ricettivo per una rete con profondità D, è definito dalla relazione:

$$(2D + 1) \times (2D + 1);$$

La rete VDSR è caratterizzata da una profondità D=20, di conseguenza il campo ricettivo ha dimensioni pari a 41 x 41.

L' *imageInputLayer* è seguito da un primo livello convoluzionale 2D contenente 128 filtri di dimensione 3 x 3. Il numero dei filtri è determinato dal numero di *patch*, definito nella fase di aumento del data set di training. Questo *layer*, è seguito da un *layer* ReLU, che introduce la non linearità nella rete. A questi due *layer* seguono altre 18 coppie di *layer* convoluzionali e i rispettivi *layer* ReLU.

Il penultimo livello è un livello convoluzionale con un singolo filtro di dimensione 3 x 3 x 128 che ricostruisce l'immagine. Infine, l'ultimo livello anziché essere livello ReLU. è un *layer* di regressione Il livello di regressione calcola l'errore medio quadrato tra l'immagine residua e la stima della rete.

Il risultato della convoluzione (la mappa di attivazione) si ottiene sommando i risultati ottenuti effettuando il prodotto scalare dei valori del filtro con il campo ricettivo dell'immagine; per coprire tutta l'immagine il filtro si comporta come una finestra mobile spostandosi di un passo assegnato. Ogni volta che vengono applicate operazioni di convoluzione le dimensioni della mappa di attivazione

vengono ridotte. Questo viene evitato impiegando la tecnica, denominata *Zero Padding* che definisce un contorno di pixel dal valore pari a zero per mantenere le dimensioni delle immagini di attivazione costanti.

5 CASO STUDIO

Lo studio in campo è stato eseguito in data 15/09/2020 in un vigneto, dell'azienda agricola Brevi Pendii, di superficie pari a circa 1,6 ettari con un dislivello di circa 55 metri e una pendenza del 40%.

Il vigneto è localizzato a Noche, frazione del comune di Vinchio, in provincia di Asti (Piemonte, nord-ovest d'Italia). Le viti sono ancora giovani in quanto la loro crescita ha subito un forte rallentamento causato da eventi meteorici particolarmente intensi.

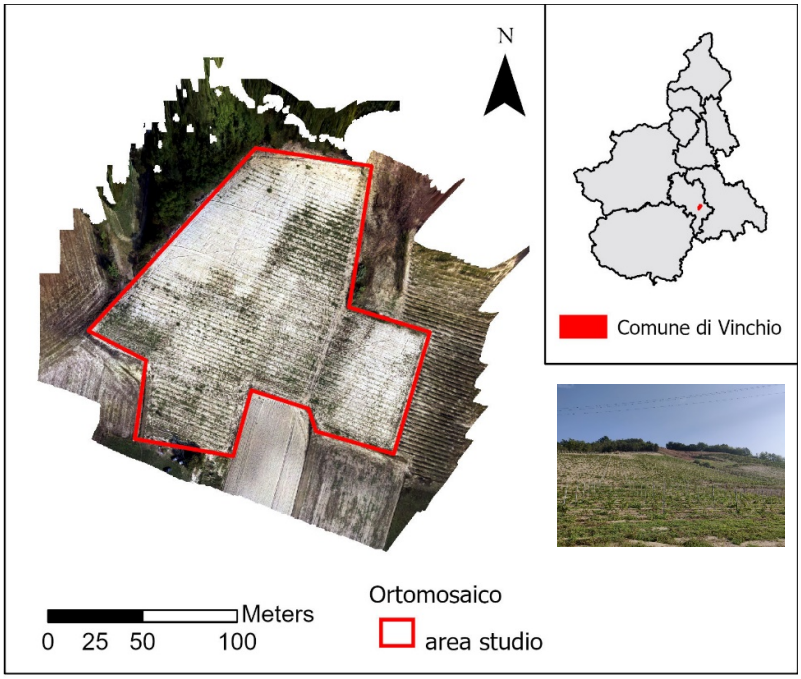

Figura 5.1 Vigneto di proprietà dell'azienda agricola Brevi Pendii

Il lavoro era così organizzato: a una prima fase di pianificazione del volo è seguita quella di acquisizione dei dati. Durante questo step, svolto sul campo, sono stati eseguiti in parallelo il volo dello UAV e il rilievo GPS. Successivamente i dati sono stati elaborati mediante il *software Agisoft Metashape Professional 1.6.3* e sono

stati ottenuti come risultati la nuvola di punti sparsa, la nuvola di punti densa, il *Digital Elevation Model* (DEM), le ortofoto e l'ortomosaico.

La struttura del lavoro è schematizzata nella figura seguente.

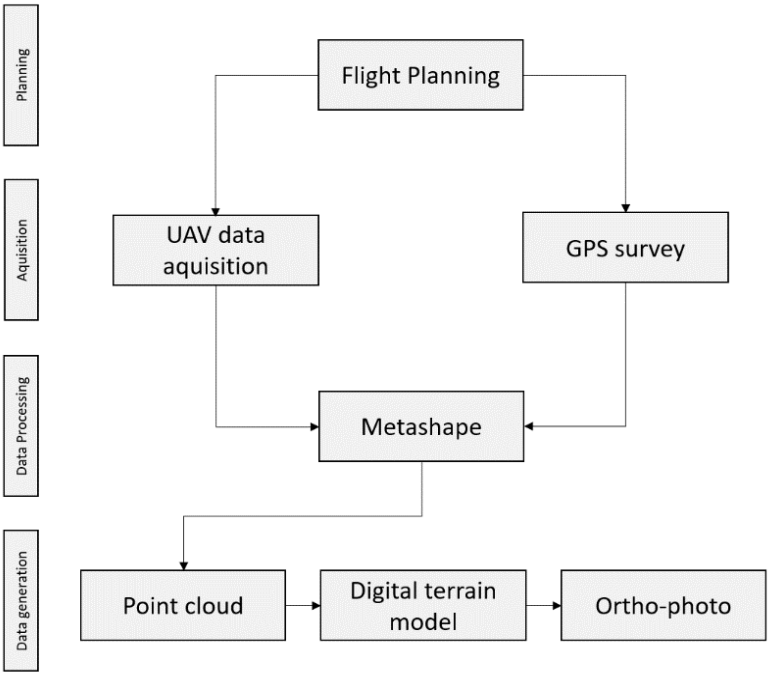

Figura 5.2 Workflow

5.1 Strumentazione

Le immagini sono state acquisite mediante l'impiego di un *Phantom 4 multispectral di DJI*. Questo UAV è progettato per scopi di agricoltura e monitoraggio ambientale ad alta precisione, a scala centimetrica. Ha un peso di circa 1380 g, è dotato di quattro rotori, ha un'autonomia di volo di circa 30 minuti e 7 km di raggio di trasmissione con il sistema *OcuSync*.

Figura 5.3 Phantom 4 di DJI

Ha incorporati una serie di sensori tra cui GPS, giroscopio, barometro e accelerometro, una telecamera e un *gimbal* a 3 assi con controller di volo e sistema di controllo della telemetria.

La fotocamera multispettrale ha un sensore da 12 megapixel (4000 x 3000 pixel) che acquisisce immagini RGB e in cinque bande: blu, verde, rosso, *Red-Edge* (RE) e infrarosso vicino o *Near-Infrared* (NIR) (*Figura 5.4*).

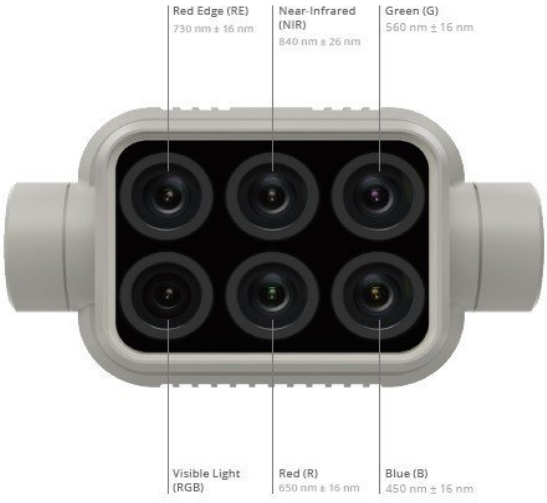

Figura 5.4 Camera multispettrale del Phantom 4 di DJI [34]

Lo UAV è dotato, inoltre, di un sensore di luce solare integrato che cattura l'irradiazione solare e permette di rielaborare i dati al variare delle condizioni di illuminazione in modo da ottenere informazioni più coerenti anche in momenti diversi della giornata.

Grazie al sistema *TimeSync* di DJI, possono essere ottenute misurazioni precise a livello centimetrico. Il sistema *TimeSync* regola costantemente l'assetto della centralina di volo, delle fotocamere RGB e NB e del modulo RTK, fissando i dati di posizionamento al centro del sensore CMOS e riportando su ogni immagine metadati accurati. I parametri di distorsione vengono acquisiti e salvati nei metadati di ogni immagine, per adeguare il software di post-produzione alle necessità dei singoli utenti.

5.2 Acquisizione dei dati

Le prime cose da fare sono la pianificazione del piano di volo e la scelta della posizione dei punti di controllo a terra, in funzione dell'area da rilevare.

Si pianificano le operazioni di volo, scegliendo i punti di decollo e atterraggio dello UAV, controllando la presenza di elementi che possono ostacolarne il volo. Solo dopo che è stato eseguito un controllo del sistema UAV, della batteria, dei sensori e del segnale, lo UAV può essere acceso e può essere eseguita l'acquisizione delle immagini.

L'altezza di volo dovrebbe rimanere costante, in modo da garantire che le immagini possano essere fuse senza soluzione di continuità. In questo caso, l'acquisizione è avvenuta a una quota di circa 45 m. Sono state ottenute un totale di 1082 foto, con risoluzione di circa 2 cm, tra immagini nadirali (485) e inclinate (597) per ognuna delle 5 bande più altre 1082 foto a colori reali.

Prima dell'esecuzione del volo e quindi dell'acquisizione delle fotografie aeree, sono stati posti al suolo 15 marker. Le loro coordinate acquisite con sistema GPS, sono poi state inserite nel software nella fase di elaborazione dei dati.

Questi punti rilevati sono i GCP (*Ground Control Points*) e sono quei punti a terra la cui posizione è nota con precisione.

I punti sono stati distribuiti in maniera uniforme sulla superficie del rilievo in modo da rendere più accurati i risultati. È importante che i target impiegati abbiano una buona visibilità e quindi una dimensione sufficiente, tale che si possano apprezzare senza difficoltà dalle fotografie ottenute dall'acquisizione. In particolare, deve essere facilmente individuabile il centro del marker, per determinare con la massima precisione possibile le coordinate rilevate.

Va inoltre precisato che i marker devono avere una serie di caratteristiche che li rendano maneggevoli e facilmente trasportabili. Devono essere abbastanza leggeri e flessibili in modo che si adattino al terreno e che possano essere rimossi con facilità una volta conclusa l'acquisizione.

5.3 Elaborazione delle immagini

Le immagini sono state elaborate al fine di ottenere un ortomosaico per ogni banda e un ortomosaico dell'immagine a colori reali da cui poter estrarre un *data set* per il training di una rete neurale per l'applicazione della super-risoluzione.

Questo processamento viene eseguito tramite il software *Agisoft Metashape Professional 1.6.3*. I dati di input a disposizione sono le immagini acquisite dallo UAV nelle diverse bande e le coordinate dei marker usati per la georeferenziazione del dato. Di seguito viene riportata la procedura adottata per l'elaborazione dei dati.

Il primo *step* consiste nell'importazione delle immagini, sia quelle nadirali che quelle inclinate, relative a una singola banda, sul software.

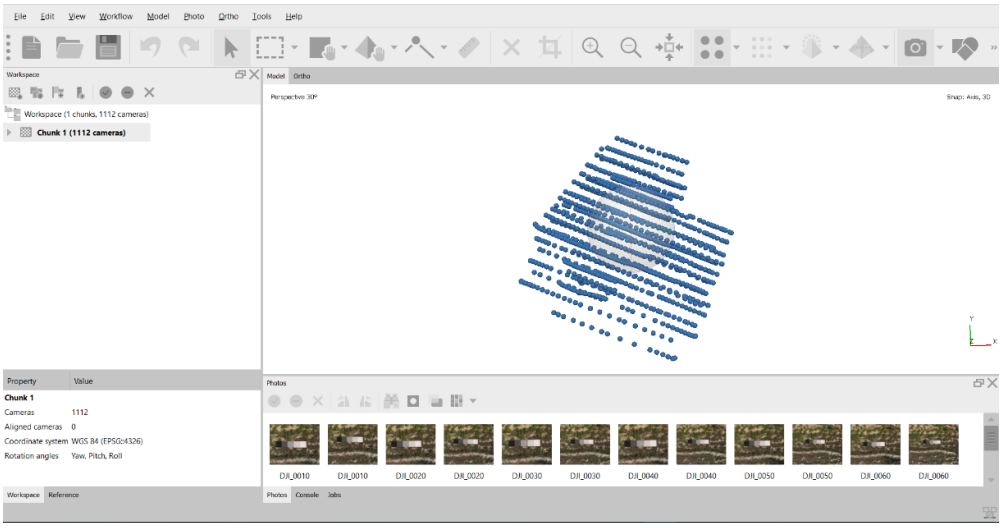

Figura 5.5 Schermata del caricamento delle immagini

Dopo aver definito il sistema di coordinate del progetto (WGS 84 / UTM zone 32N) è possibile eseguire l'allineamento delle foto in modo tale che venga creato un modello di nuvola di punti sparsa. L'allineamento ha richiesto circa 17 minuti mentre la generazione della nuvola sparsa circa 20 minuti.

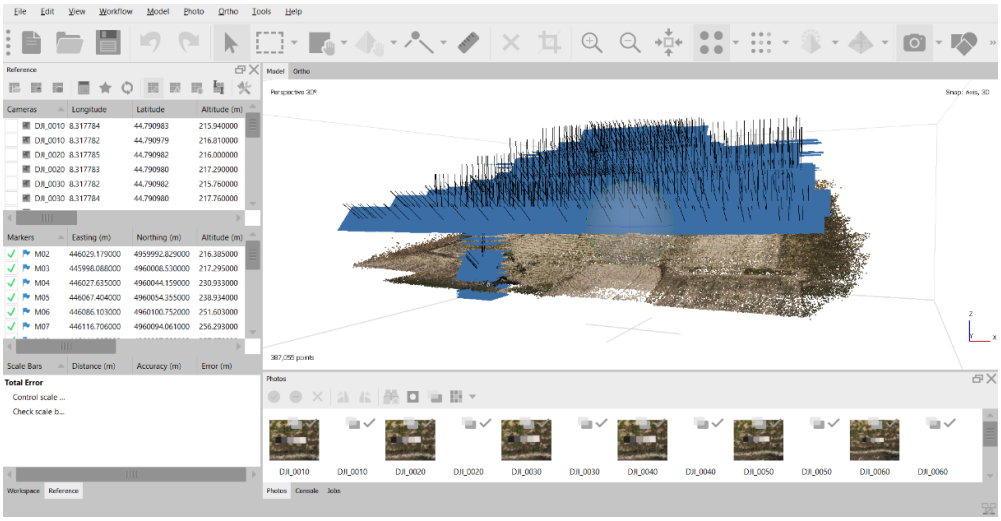

Figura 5.7 Schermata dell'allineamento delle immagini e della generazione della nuvola sparsa

Nel secondo passaggio vengono inserite le coordinate dei punti di appoggio (GCP) e viene eseguita manualmente la collimazione dei punti. Per fare ciò vengono visualizzate tutte le foto contenenti i marker che identificano i punti di appoggio e, per ogni marker vengono collimati almeno 15 punti. È importante eseguire la collimazione solo sulle immagini che inquadrano al meglio il marker in modo tale che la collimazione sia il più accurata possibile.

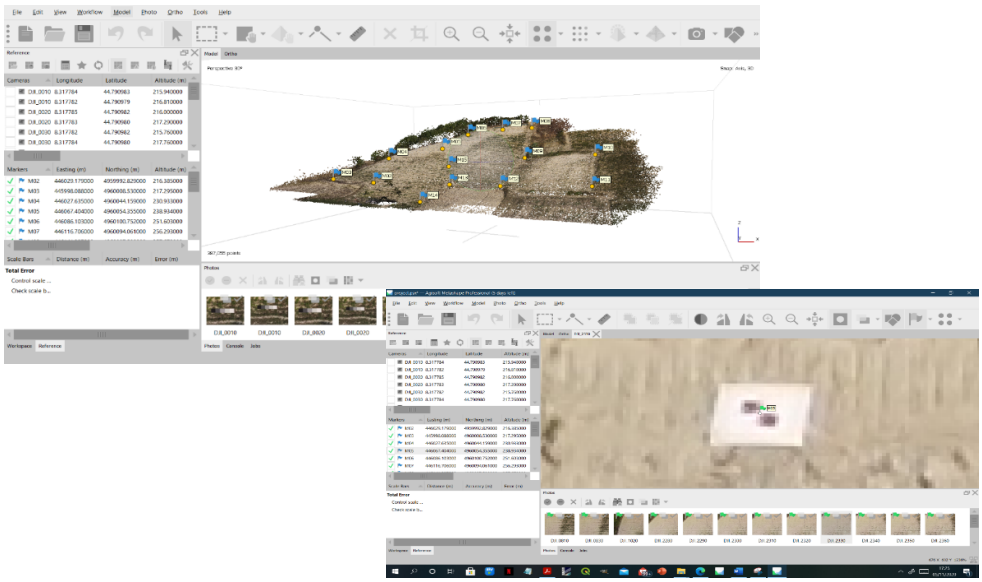

Figura 5.8 Schermate di importazione dei GCP e della fase di collimazione

La fase successiva è quella di ottimizzazione delle camere, durata circa 6 minuti, che permette di ottimizzare i parametri di orientamento della fotocamera in base alle coordinate di riferimento note minimizzando gli errori.

In seguito all'ottimizzazione delle camere bisogna eseguire un'operazione di verifica. Si riesegue l'ottimizzazione senza prendere in considerazione uno dei GPC che diventa in automatico un punto di verifica. Eseguita la verifica, è si è proceduto alla creazione della nuvola densa, operazione che ha richiesto circa 10 ore.

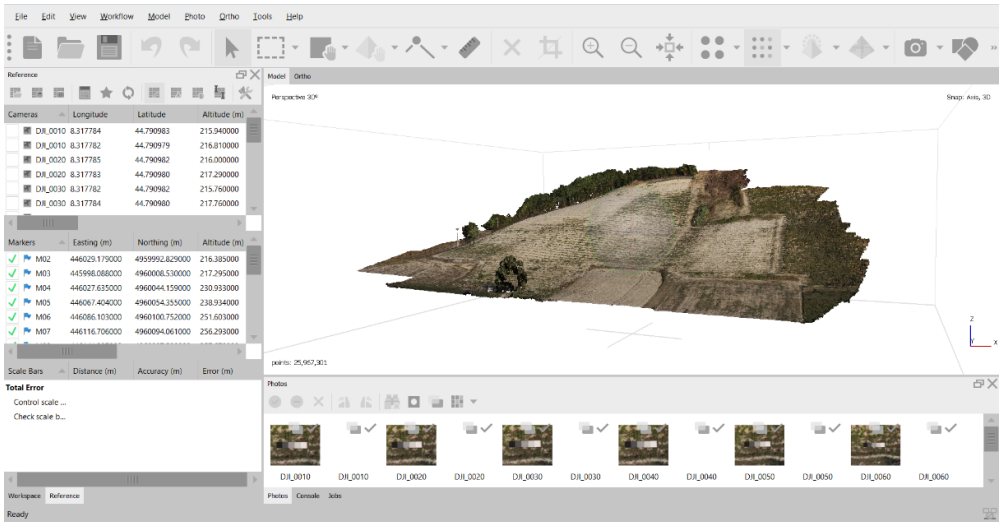

Figura 5.9 Schermata della fase di generazione della nuvola densa

I valori massimi di errore tollerati rispettivamente per i punti di appoggio e per i punti di verifica sono stati definiti pari a 2 cm e 4 cm, rispettivamente.

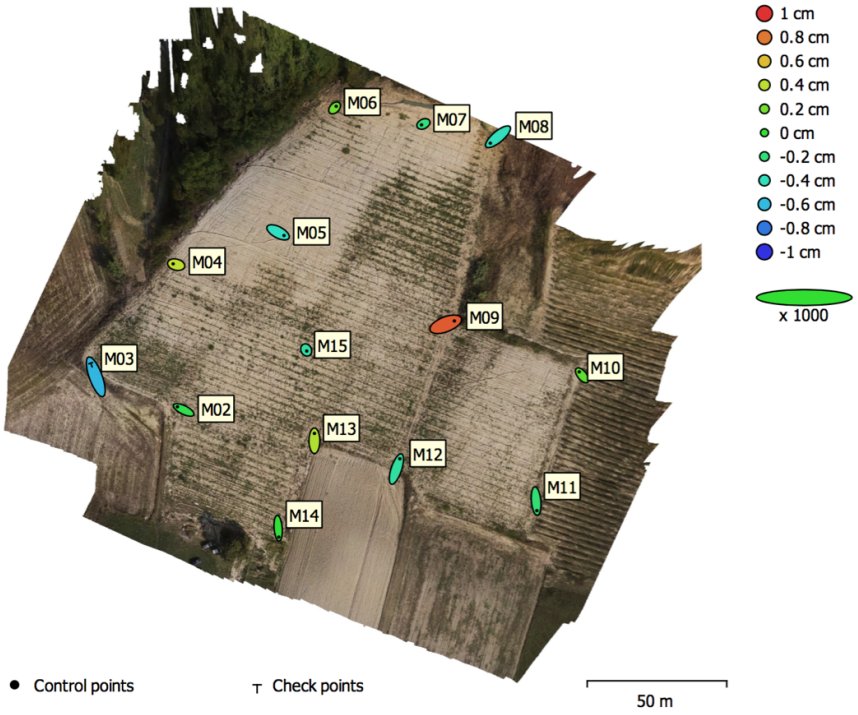

Figura 5.10 Posizione dei GCP ed errori stimati. I GCP stimati sono segnati da un punto o una croce, gli errori nelle direzioni x e y sono rappresentati dalla forma delle ellissi e gli errori nella direzione z sono rappresentati dal loro colore.

Nella seguente tabella sono riportati gli errori per ogni GCP. I valori di errore ottenuti sono buoni, mai superiori a 1,1 cm.

Tabella 3 Errori dei Control points (X - Easting, Y - Northing, Z – Altitude)

Label	X error (cm)	Y error (cm)	Z error (cm)	Total (cm)	Image (pix)
M02	-0.449667	0.222604	-0.0868864	0.509217	0.218 (20)
M04	-0.21804	0.0557678	0.41163	0.469138	0.207 (20)
M05	0.428074	-0.228479	-0.413516	0.637531	0.239 (20)
M06	0.114302	0.119696	0.175554	0.24127	0.211 (20)
M07	-0.134917	-0.0724274	-0.211167	0.260844	0.202 (20)
M08	-0.552899	-0.463411	-0.401823	0.825777	0.208 (21)
M10	-0.202767	0.249938	0.130674	0.34736	0.236 (20)
M11	0.0603508	-0.685476	-0.190984	0.714139	0.258 (20)
M12	0.247182	0.735455	-0.31902	0.838908	0.290 (20)
M14	0.0485057	-0.633137	-0.0215207	0.635357	0.209 (18)
M15	0.0379852	-0.0747291	-0.319754	0.33056	0.260 (20)
M09	0.622555	0.244382	0.880385	1.10561	0.238 (20)
M13	-0.00066270	0.52982	0.36643	0.644189	0.192 (20)
Total	**0.312211**	**0.407554**	**0.367134**	**0.63116**	**0.230**

A partire dalla nuvola densa è stato generato il DEM (*Digital Elevation Model*) in circa 2 minuti. Le quote ottenute per il modello digitale di elevazione sono espresse in coordinate ellissoidiche.

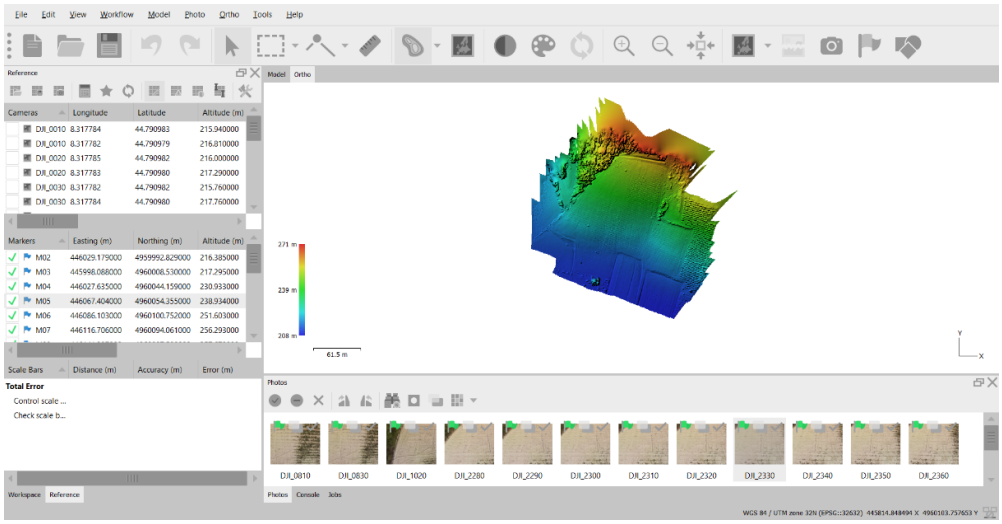

Figura 5.11 Schermata della fase di generazione del DEM

Successivamente è stato generato, in circa 17 minuti, l'ortomosaico. Tutti i passaggi sono stati eseguiti impostando un dato di output ad alta qualità, selezionando "*high*" al lancio della procedura.

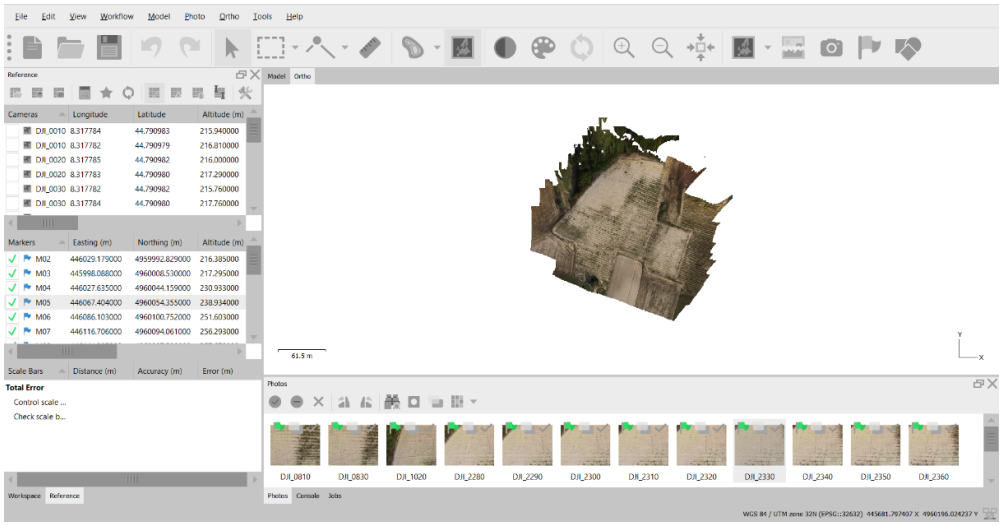

Figura 5.12 Schermata della fase di generazione dell'ortomosaico

Si esporta infine l'ortomosaico in formato *tif* per estrarre i dati ad alta risoluzione per il training della rete neurale. La procedura deve essere ripetuta per ogni banda, ma per velocizzare il processo è possibile, dopo aver ottenuto il primo ortomosaico,

importare direttamente il DEM ottenuto dalla prima elaborazione e calcolare direttamente l'ortomosaico per la banda in esame. Di seguito vengono riportati gli ortomosaici ottenuti per ogni banda e per la composizione RGB.

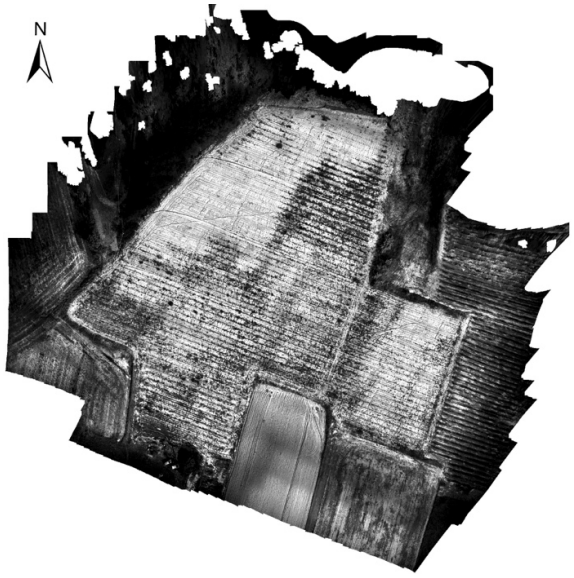

Figura 5.13 Ortomosaico Banda 1 (Blue)

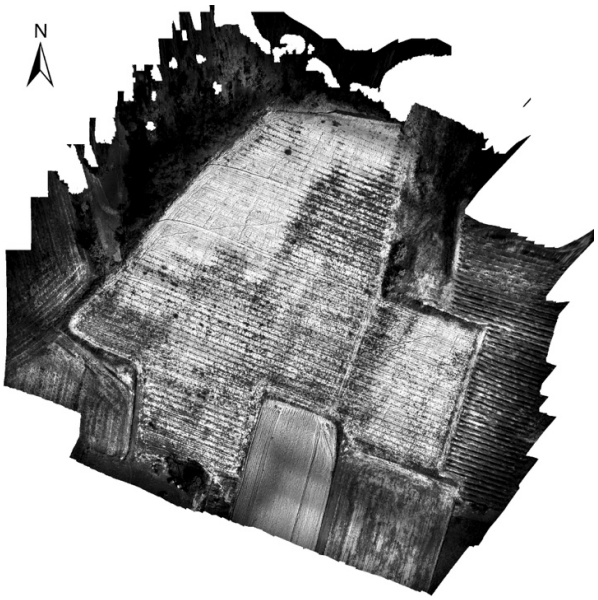

Figura 5.14 Ortomosaico Banda 2 (Green)

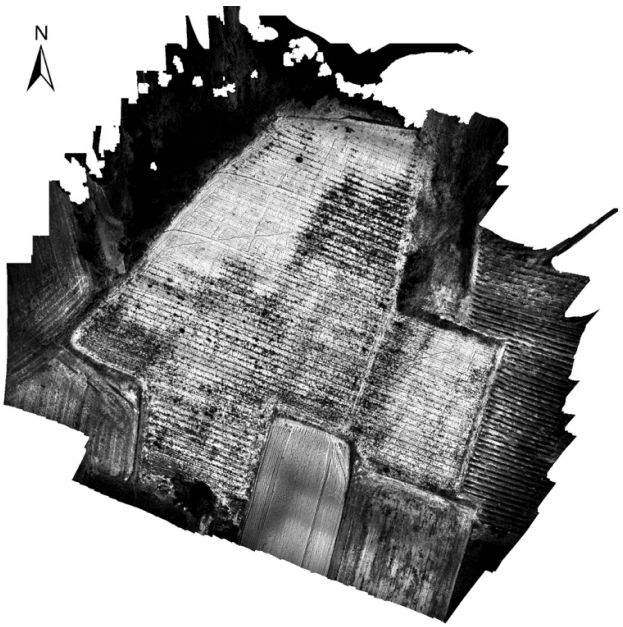

Figura 5.15 Ortomosaico Banda 3 (Red)

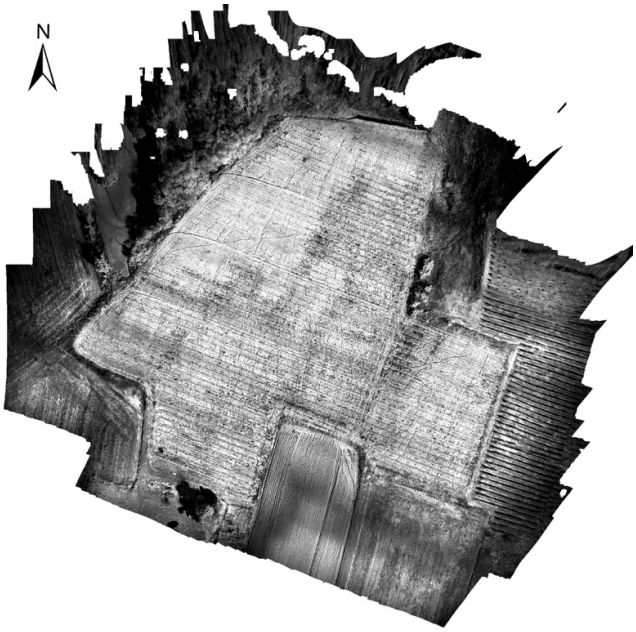

Figura 5.16 Ortomosaico Banda 4 (RE)

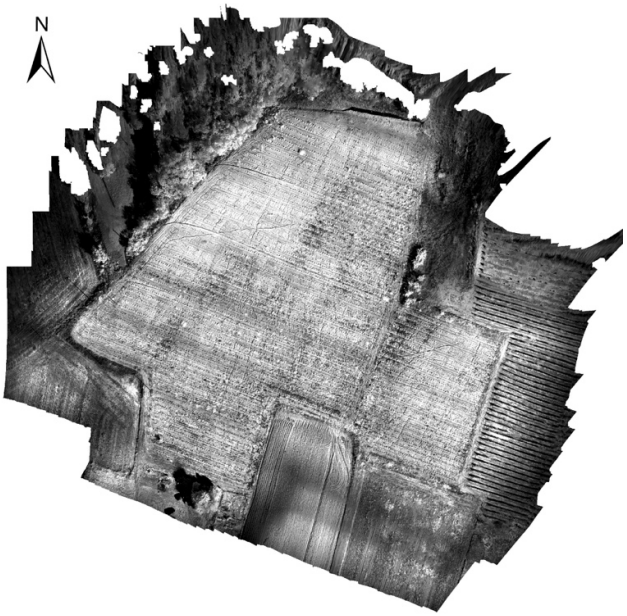

Figura 5.17 Ortomosaico B5 (NIR)

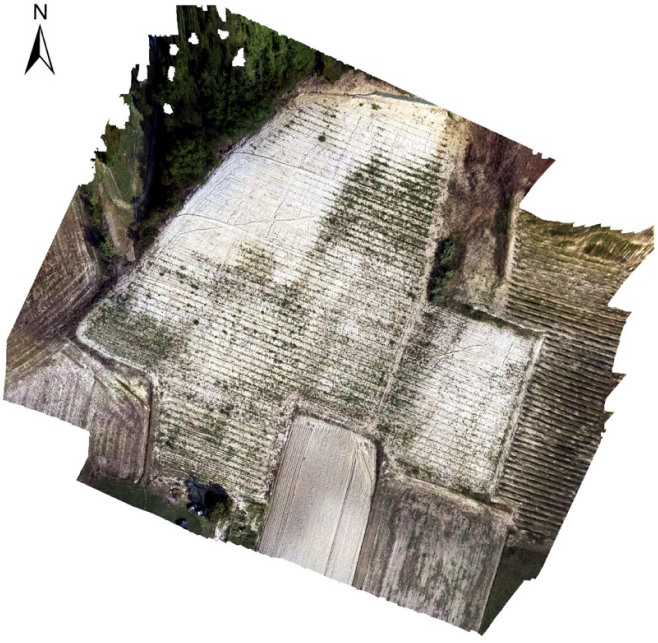

Figura 5.18 Ortomosaico RGB (Colori reali)

6 APPLICAZIONE DELLA RETE NEURALE

Per la ricostruzione delle immagini in super-risoluzione è stata impiegata la rete neurale convoluzionale VDSR adattando, al caso studio, il codice presente sul sito *Mathworks* [35] e già impiegato in altri lavori [36]. Il codice è stato costruito sul software *Matlab R2020a,* sul quale è stato necessario installare i *toolbox Image Processing Toolbox* e *Deep Learning Toolbox*

6.1 Creazione del data set di training

In generale, tutti i *deep model* riescono ad avere prestazioni migliori con un numero maggiore di immagini di training. Per ottenere un numero adeguato di dati di training, si è impiegato il software *ArcGis Pro*.

L'ortomosaico ad alta risoluzione, a sua volta ottenuto in seguito all'elaborazione eseguita sul software *Agisoft Metashape Professional 1.6.3* sulle immagini acquisite in campo, è stato importato su *ArcGis Pro* e , successivamente è stata generata una griglia formata da celle quadrate di venti metri per lato, con sovrapposizione di cinque metri. Dalla sovrapposizione tra la griglia e l'ortomosaico è stato estratto un campione di 131 immagini.

Il codice carica le 131 immagini e, attraverso la funzione *createVDSRTrainingSet,* ogni immagine viene convertita dallo spazio RGB allo spazio della luminanza e della crominanza YCrCb. Attraverso vari fattori di scala il canale della luminanza delle immagini subisce delle riduzioni di scala e mediante interpolazione bicubica viene riportato alle dimensioni originali.

Sempre sul canale della luminanza viene calcolata la differenza tra le immagini di partenza e quelle ricampionate e si ottengono così i residui delle immagini del *training set*. A questo punto vengono generati due archivi: l'archivio di immagini *upsampled,* che contiene le immagini riaumentate di scala, e l'archivio *residual,*

che contiene i residui calcolati come differenza tra le immagini originali e quelle *upsampled*.

6.2 Aumento del data set di training

Il numero di immagini che sono state estratte non è molto alto e per poter incrementarne la numerosità del data set di training, vengono impiegate in combinazione due funzioni. La *randomPatchExtractionDatastore* esegue l'estrazione casuale di 128 *patch* di dimensione 41 x 41 pixel dalle immagini degli archivi e la *imageDataAugmenter* (*Deep Learning Toolbox*), configura un set di opzioni di pre-elaborazione per l'aumento del numero delle immagini, come il ridimensionamento, la rotazione e la riflessione. Tramite quest'ultima funzione, alle immagini viene applicata una rotazione casuale di 20° e la riflessione nella direzione x. Questi passaggi aumentano notevolmente il *data set* di *training*.

6.3 Parametri del training

La rete neurale viene addestrata utilizzando lo *stochastic gradient descent with momentum* (SGDM). Per eseguire il *training* devono essere prima definite le impostazioni utilizzando la funzione *trainingOptions* (*Deep Learning Toolbox*). Il tasso di apprendimento è impostato inizialmente pari a 0,1 e diminuito di un fattore di 10 ogni 10 epoche. Il training viene impostato per 100 epoche.

Il processo di training richiede molto tempo (*Figura 6.1*), è possibile accelerare questa fase specificando tassi di apprendimento più elevati, tuttavia, ciò può causare una crescita incontrollata dei parametri della rete, impedendo che il training vada a buon fine [37].

6.4 Esecuzione della rete VDSR e miglioramento dell'output

Una volta concluso il training, l'immagine di input a bassa risoluzione viene convertita nello spazio della luminanza e della crominanza e il canale della luminanza viene imposto come input nella rete VDSR.

Il risultato di output della rete VDSR è sottoposto a un ulteriore processo iterativo per migliorarne la qualità. Viene ripetuta l'attivazione della rete neurale utilizzando come input a ogni passaggio l'immagine a risoluzione migliorata dello step precedente e aumentando il numero di pixel dell'immagine di output. mantenendo inalterate le proporzioni dell'immagine. Il processo prosegue sino ad arrivare a un valore limite determinato in base ai limiti di memoria del computer utilizzato per l'elaborazione.

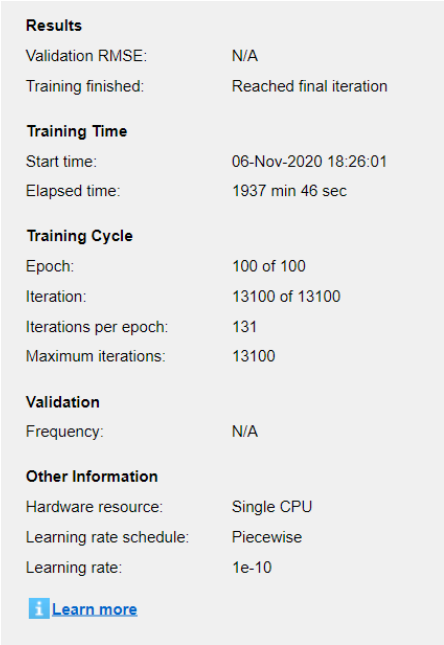

Figura 6.1 Dettagli conclusione del training

6.5 Descrizione del codice

Le prime righe del codice hanno la funzione di caricare il *dataset* di *training* per la rete neurale e riportare la sua numerosità:

```
trainImagesDir = ('F:\progetto_metashape\grid re-
sult\training_dataset');
exts = {'.tif'};
pristineImages = imageDatastore(trainImag-
esDir,'FileExtensions',exts);
numel(pristineImages.Files)
```

Una volta caricato il *data set* vengono generate le coppie di immagini *upsampled* e *residual*, e attraverso la *helper function* "*createVDSRTrainingSet*" vengono convertite le immagini nello spazio YCbCr. Per creare immagini a bassa risoluzione, la dimensione del canale della luminanza (Y) delle varie immagini viene ridotta attraverso dei fattori di scala, e poi riaumentata con interpolazione bicubica. La rete esegue poi il calcolo della differenza tra l'immagine originale e quella ridimensionata con l'interpolazione bicubica e salva le due immagini nei rispettivi archivi:

```
upsampledDirName = [trainImagesDir filesep 'upsam-
pledImages'];
residualDirName = [trainImagesDir filesep 'residual-
Images'];
scaleFactors = [2 3 4];
createVDSRTrainingSet(pristineImages,scaleFactors,up-
sampledDirName,residualDirName);
upsampledImages = imageDatastore(upsampledDir-
Name,'FileExtensions','.mat','ReadFcn',@matRead);
residualImages = imageDatastore(residualDir-
Name,'FileExtensions','.mat','ReadFcn',@matRead);
```

Per aumentare i dati di training vengono definiti i parametri relativi alla rotazione e alla riflessione e viene eseguita l'estrazione casuale di porzioni (*patch*) dai datastore delle immagini *upsampled* e dei residui:

```
ang_dir = -10;
ang_analisi = 20;
augmenter = imageDataAugmenter( ...
```

```
    'RandRotation',@() (rand-0.5)*ang_analisi+ang_dir,
...
    'RandXReflection',true);
patchSize = [41 41];
patchesPerImage = 128;
dsTrain = randomPatchExtractionDatastore(upsam-
pledImages,residualImages,patchSize, ...
    "DataAugmentation",augmenter,"PatchesPerIm-
age",patchesPerImage);
inputBatch = preview(dsTrain);
disp(inputBatch)
```

Successivamente viene definita l'architettura della rete. La struttura è divisa nei seguenti livelli: *first layer*, ossia *l'ImageInputLaye*r, *middle layers* costituiti da 18 ripetizioni della coppia di layer *Covnolution2Dlayer* e *ReLUlayer*, *e* i *final layers*, ossia la coppia formata da un *Convolutional2DLayer* e un *regressionlayer*, i quali ricostruiscono l'immagine e calcolano lo scarto quadratico medio tra l'immagine dei residui e la stima della rete.

```
networkDepth = 20;
firstLayer = imageInputLayer([41 41 1],'Name','Input-
Layer','Normalization','none');
convLayer = convolution2dLayer(3,128,'Padding',1, ...
    'WeightsInitializer','he','BiasInitializer','ze-
ros','Name','Conv1');
relLayer = reluLayer('Name','ReLU1');
middleLayers = [convLayer relLayer];
for layerNumber = 2:networkDepth-1
    convLayer = convolution2dLayer(3,128,'Padding',[1
1], ...
        'WeightsInitializer','he','BiasInitializ-
er','zeros', ...
        'Name',['Conv' num2str(layerNumber)]);
    relLayer = reluLayer('Name',['ReLU' num2str(lay-
erNumber)]);
    middleLayers = [middleLayers convLayer relLayer];
end
convLayer = convolution2dLayer(3,1,'Padding',[1 1],
...
    'WeightsInitializer','he','BiasInitializer','ze-
ros', ...
    'NumChannels',128,'Name',['Conv' num2str(network-
Depth)]);
finalLayers = [convLayer regressionLayer('Name','Fi-
nalRegressionLayer')];
layers = [firstLayer middleLayers finalLayers];
```

Vengono definite, attraverso la funzione "*trainingOptions*" le impostazioni iperparametriche del SGDM (Stochastic Gradient Descent with Momentum optimization):

```
maxEpochs = 100;
epochIntervals = 1;
initLearningRate = 0.1;
learningRateFactor = 0.1;
l2reg = 0.0001;
miniBatchSize = 128;
options = trainingOptions('sgdm', ...
    'Momentum',0.9, ...
    'InitialLearnRate',initLearningRate, ...
    'LearnRateSchedule','piecewise', ...
    'LearnRateDropPeriod',10, ...
    'LearnRateDropFactor',learningRateFactor, ...
    'L2Regularization',l2reg, ...
    'MaxEpochs',maxEpochs, ...
    'MiniBatchSize',miniBatchSize, ...
    'GradientThresholdMethod','l2norm', ...
    'GradientThreshold',0.01, ...
    'Plots','training-progress', ...
    'Verbose',false);
```

A questo punto viene eseguita la funzione "*trainNetwork*" per effettuare l'allenamento. Il comando "*do Train = false*" carica una rete già allenata mentre "*do Train = true*" allena una nuova rete:

```
doTraining = false;
if doTraining
    modelDateTime = datestr(now,'dd-mmm-yyyy-HH-MM-
SS');
    [net, info] = trainNetwork(dsTrain,layers,op-
tions);
    save(['trainedVDSR-' modelDateTime '-Epoch-'
num2str(maxEpochs*epochIntervals) '-ScaleFactors-'
num2str(234) '.mat'],'net','options');
else
    load('trainedVDSR-06-Nov-2020-18-25-15-Epoch-100-
ScaleFactors-234');
end
```

Conclusa la fase di *training* inizia la fase di esecuzione della *Single Image Super-Resolution* mediante la rete VDSR precedentemente allenata. Viene caricata l'immagine a bassa risoluzione di input e l'immagine ad alta risoluzione utilizzata per il confronto dei risultati della super-risoluzione:

```
exts = {'.tif'};
dir = 'F:\Dataset\highres\';
filename = [dir,'highres_fc.tif'];
Ireference = imread(filename);
Ireference = im2double(Ireference);
figure (5)
imshow(Ireference)
title('High-Resolution Reference Image')
exts = {'.tif'};
dir = 'F:\Dataset\lowres\';
filename = [dir,'lowres_satellite_rgb_prova_2.tif'];
Ilowres = imread(filename);
Ilowres = im2double(Ilowres);
figure (10)
imshow(Ilowres)
title('Low-Resolution Reference Image')
nrows_l,ncols_l,np_l] = size(Ilowres);
nrows = nrows_l;
ncols = ncols_l;
```

L'immagine di input viene convertita nel canale della luminanza e crominanza e viene eseguito, su ogni banda, il ricampionamento con interpolazione bicubica:

```
Iycbcr = rgb2ycbcr(Ilowres);
Iy = Iycbcr(:,:,1);
Icb = Iycbcr(:,:,2);
Icr = Iycbcr(:,:,3);
Iy_bicubic = imresize(Iy,[nrows ncols],'bicubic');
Icb_bicubic = imresize(Icb,[nrows ncols],'bicubic');
Icr_bicubic = imresize(Icr,[nrows ncols],'bicubic');
```

La rete VDSR viene attivata inserendo come input la componente della luminanza, così da ottenere l'immagine dei residui:

```
Iresidual = activations(net,Iy_bicubic,41);
Iresidual = double(Iresidual);
figure (30)
imshow(Iresidual,[])
```

```
title('Residual Image from VDSR')
```

Viene eseguita la somma del residuo stimato dalla rete al canale della luminanza per ottenere la componente di luminanza ad alta risoluzione e l'immagine viene riconvertita nel modello RGB:

```
Isr = Iy_bicubic + Iresidual;
Ivdsr = ycbcr2rgb(cat(3,Isr,Icb_bicubic,Icr_bicubic));
figure (40)
imshow(Ivdsr)
title('High-Resolution Image Obtained Using VDSR')
```

Per eseguire la comparazione quantitativa, vengono calcolate le metriche PSNR, SSIM e NIQE:

```
Ireference = imresize(Ireference, [nrows,ncols]);
vdsrPSNR = psnr(Ivdsr,Ireference)
vdsrSSIM = ssim(Ivdsr,Ireference)
vdsrNIQE = niqe(Ivdsr)
```

Infine viene eseguita l'iterazione per migliorare la qualità delle immagini:

```
n = 30;
k = 1;
for k = 1:5
    Ilowres = Ivdsr;
nrows = nrows*2;
ncols = ncols*2;
Iycbcr = rgb2ycbcr(Ilowres);
Iy = Iycbcr(:,:,1);
Icb = Iycbcr(:,:,2);
Icr = Iycbcr(:,:,3);
Iy_bicubic = imresize(Iy,[nrows ncols],'bicubic');
Icb_bicubic = imresize(Icb,[nrows ncols],'bicubic');
Icr_bicubic = imresize(Icr,[nrows ncols],'bicubic');
Iresidual = activations(net,Iy_bicubic,41);
Iresidual = double(Iresidual);
n = n+1;
figure (n)
imshow(Iresidual,[])
title('Residual Image from VDSR')
Isr = Iy_bicubic + Iresidual;
Ivdsr = ycbcr2rgb(cat(3,Isr,Icb_bicubic,Icr_bicubic));
```

```
Ireference = imresize(Ireference, [nrows,ncols]);
vdsrPSNR = psnr(Ivdsr,Ireference)
vdsrSSIM = ssim(Ivdsr,Ireference)
vdsrNIQE = niqe(Ivdsr)
end
figure (41)
imshow(Ivdsr)
```

7 RISULTATI

Nel presente studio sono state eseguite due analisi: la prima analisi riferita all'area su cui sono state effettuate le acquisizioni con lo UAV e la seconda relativa a un'area più ampia su cui non sono state eseguite indagini in sito.

7.1 Analisi su un'area di 1,5 ettari

Il primo test è stato effettuato su un'area di 1,5 ettari all'interno del vigneto su cui sono state eseguite le acquisizioni con UAV.

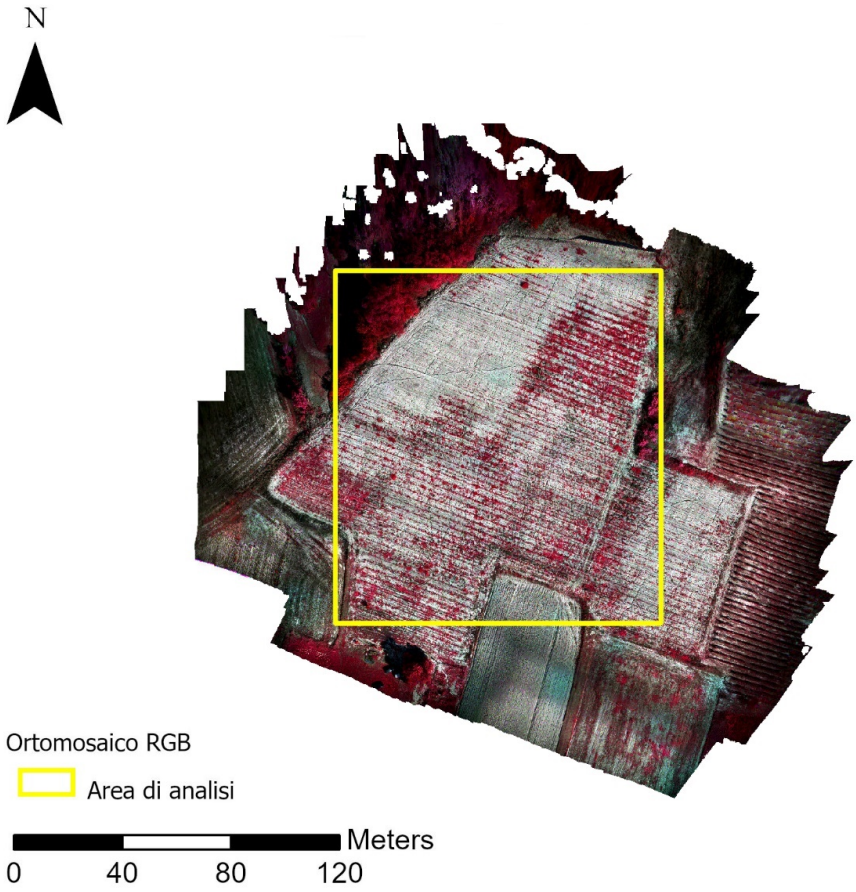

Figura 7.1 Inquadramento area di indagine

Come input della rete VDSR è stata impiegata una porzione di un'immagine satellitare, corrispondente all'area di analisi, acquisita dalla missione Sentinel-2.

L'immagine è a falsi colori, ed è data dalla composizione delle bande dell'infrarosso vicino, del rosso e del verde. La risoluzione spaziale di tutte e tre le bande che compongono l'immagine a falsi colori è di 10 m per cui non è stato necessario eseguire un ricampionamento. Tuttavia, l'informazione è espressa in 16 bit per cui i dati sono stati convertiti in 8 bit.

Per eseguire la composizione delle immagini a falsi colori a partire dalle singole bande e per eseguire la conversione delle immagini di input da 16 a 8 bit è stato utilizzato il software *Arcgis Pro*.

Figura 7.2 Confronto tra immagine satellitare (dx) e acquisita da UAV (sx)

Le due immagini inquadrano la stessa area di analisi e sono entrambe in falsi colori. Nonostante sia possibile riconoscere delle similitudini, è evidente che l'immagine satellitare ha una risoluzione di gran lunga inferiore rispetto a quella acquisita con UAV.

L'immagine satellitare è composta da un numero molto limitato di pixel (13 x 12 px). Si è eseguito un processo iterativo per il quale viene ripetuta la rete neurale. Il processo è limitato dalla capacità della memoria del computer utilizzato per l'elaborazione. L'immagine finale, ottenuta alla fine del processo iterativo ha dimensione 1664 x 1536 pixel.

Di seguito viene riportato un confronto tra l'immagine di riferimento estratta dall'ortomosaico, l'immagine di input (satellitare) a basa risoluzione e l'immagine di output della rete VDSR.

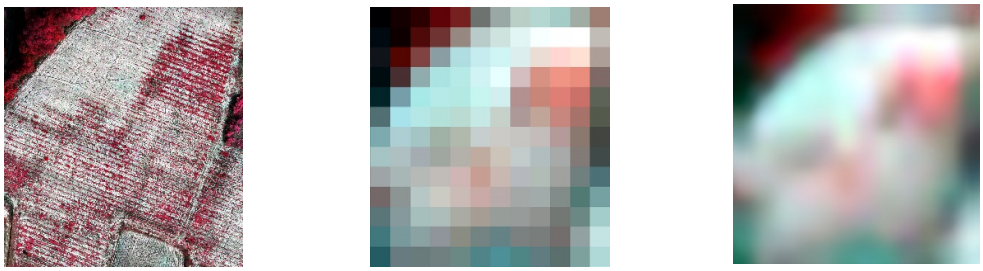

Figura 7.3 Immagine di riferimento ad alta risoluzione, immagine di input acquisita da satellite, immagine a risoluzione aumentata ottenuta dalla rete VDSR

Per quantificare il miglioramento dell'immagine è necessario stabilire misure oggettive [38]. I parametri più comunemente utilizzati per la stima della qualità in processi di ricostruzione delle immagini sono:

- PSNR (*Peak signal-to-noise ratio*);
- SSIM (*Structural Similarity index*);
- NIQE (*Naturalness Image Quality Avaluator*);

I primi due parametri necessitano di un'immagine di riferimento rispetto alla quale valutare la coerenza dell'immagine ottenuta come output.

Valori di PSNR, più elevati indicano una qualità migliore dell'immagine. Il parametro PSNR esprime il rapporto tra il valore massimo possibile di un segnale e la potenza del rumore di distorsione che influisce sulla qualità della sua rappresentazione.

Valori di SSIM tendenti al valore 1 indicano una maggior coerenza dell'immagine testata con quella di riferimento. L'indice SSIM è formulato per essere coerente con la percezione della visione umana ed è ideato modellando qualsiasi distorsione dell'immagine come una combinazione di tre fattori che sono la perdita di

correlazione, la distorsione della luminanza e la distorsione del contrasto. I valori dell'indice SSIM sono compresi tra 0 e 1. Un valore pari a 0 indica che le immagini non sono correlate e 1 indica che le due immagini solo la stessa.

Infine, è stato preso in considerazione anche il parametro NIQE che misura della qualità percettiva dell'immagine. Una qualità maggiore è associata a valori minori.

Di seguito vengono riportati i valori dei parametri sopra descritti a ogni iterazione:

Tabella 4 Valori delle metriche di valutazione per le varie iterazioni

Attivazione	PSNR	SSIM	NIQE
1	9.4773	0.1427	18.8691
2	9.515	0.15	18.8711
3	9.4615	0.1647	7.5331
4	9.4572	0.1858	6.5947
5	9.458	0.1958	6.6447
6	9.4613	0.1991	6.3002

Sebbene l'indice PSNR presenti dei valori pressoché costanti che quindi non indicano un significativo miglioramento della qualità dell'immagine, i valori di SSIM e NIQE hanno una tendenza rispettivamente decrescente e crescente che indica un miglioramento delle caratteristiche degli output alle varie iterazioni.

7.1.1 Calcolo NDVI

A partire dall'immagine di output si è eseguita sempre attraverso *matlab* la scomposizione nelle tre bande per poter calcolare l'NDVI.

Di seguito viene riportato un confronto tra la mappa dell'NDVI calcolato a partire dall'immagine di output della rete VDSR e la mappa dell'NDVI calcolato a partire dall'immagine di riferimento.

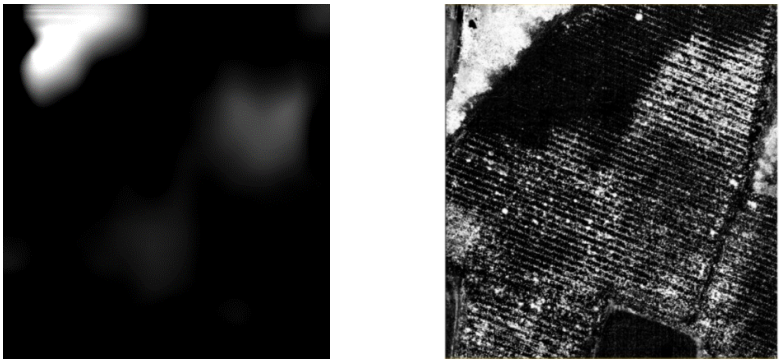

Figura 7.4 Confronto mappa dell'NDVI calcolato rispettivamente sull'immagine di output della rete VDSR e sull'immagine acquisita con UAV

Visivamente è possibile riscontrare delle similitudini tra le due immagini. In particolare, risulta particolarmente evidente l'area più chiara in alto a sinistra, coincidente con una zona di vegetazione più fitta.

7.1.2 Confronto con interpolazione bicubica

Di seguito viene riportato un confronto eseguito tra l'output della rete VDSR e il risultato di un'interpolazione di bicubica eseguita sull'immagine satellitare di partenza. Il confronto nasce dalla volontà di paragonare la rete VDSR con una tecnica più semplice e immediata come l'interpolazione bicubica.

Già da un primo raffronto visivo risulta evidente che le due tecniche hanno portato a dei risultati simili. Tuttavia, si può apprezzare una maggiore quantità di dettagli nell'immagine ottenuta dalla rete VDSR.

Figura 7.5 Confronto tra l'immagine ricavata dall'interpolazione bicubica (sx) e l'output della rete VDSR (dx)

A riconferma dei risultati riportati precedentemente sono state eseguite delle operazioni tra bande per mettere a confronto l'applicazione della rete VDSR con l'interpolazione bicubica,

L'operazione è stata eseguita prima per ognuna delle bande dell'immagine ottenute dalla procedura VDSR e le stesse bande estratte dall'immagine di riferimento ad alta risoluzione; e successivamente, la stessa operazione, è stata eseguita tra le bande dell'immagine satellitare migliorata attraverso l'applicazione dell'interpolazione bicubica e le bande dell'immagine di riferimento ad alta risoluzione.

Le operazioni sono state eseguite mediante *ArcGis PRO* attraverso lo strumento *raster calculator*. Dai *raster* risultanti sono stati generati dei grafici dei valori dei pixel che li compongono e ne è stata calcolata la media e la deviazione standard. Valori medi più vicini allo zero indicano una maggiore somiglianza delle bande su cui è stata eseguita l'operazione.

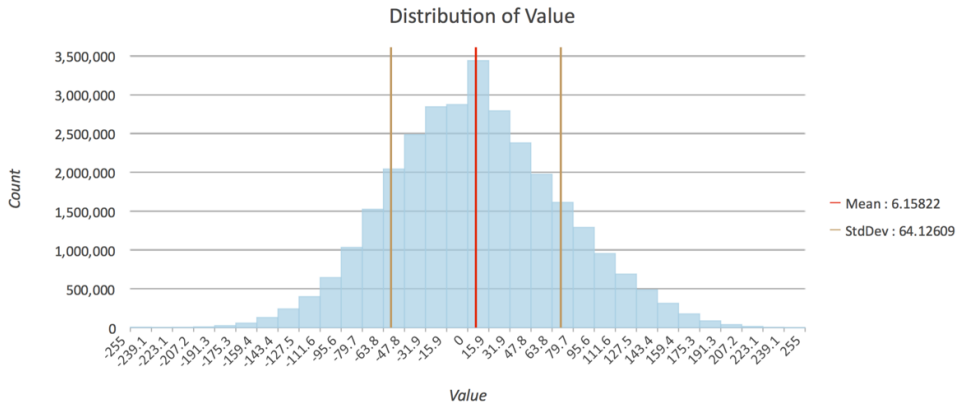

Figura 7.6 Istogramma di distribuzione dei valori dei pixel del raster risultante dalla sottrazione tra banda NIR dell'immagine ricavata dall'interpolazione bicubica e dell'immagine di riferimento acquisita da UAV

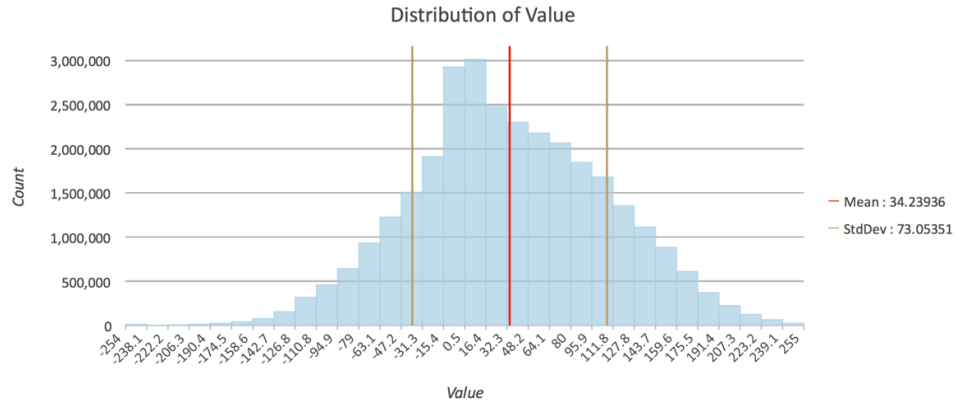

Figura 7.7 Istogramma di distribuzione dei valori dei pixel del raster risultante dalla sottrazione tra la banda RED dell'immagine ricavata dall'interpolazione bicubica e dell'immagine di riferimento acquisita da UAV

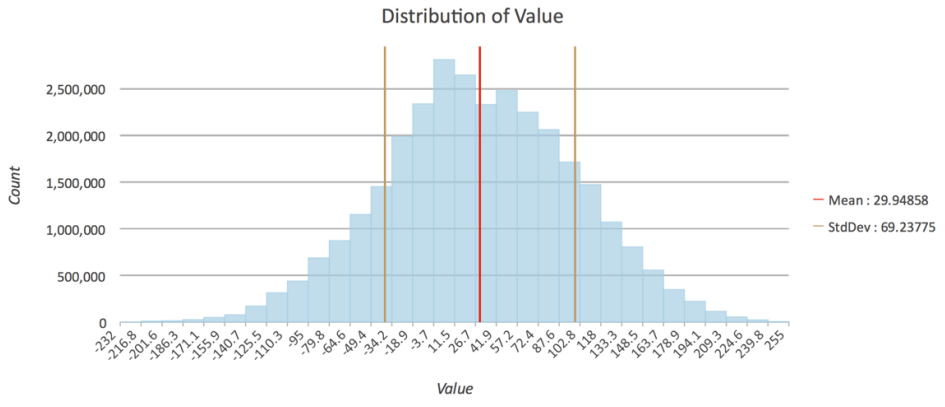

Figura 7.8 Istogramma di distribuzione dei valori dei pixel del raster risultante dalla sottrazione tra banda GREEN dell'immagine ricavata dall'interpolazione bicubica e dell'immagine di riferimento acquisita da UAV

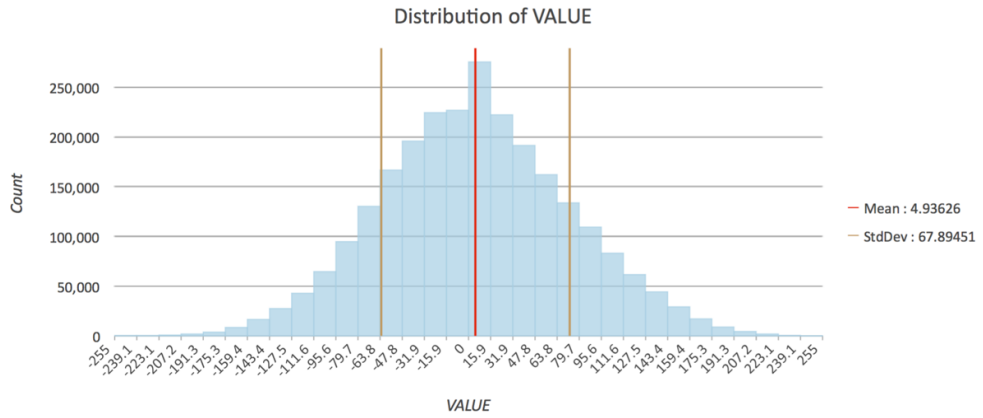

Figura 7.9 Istogramma di distribuzione dei valori dei pixel del raster risultante dalla sottrazione tra la banda NIR dell'immagine di output della rete VDSR e dell'immagine di riferimento acquisita da UAV

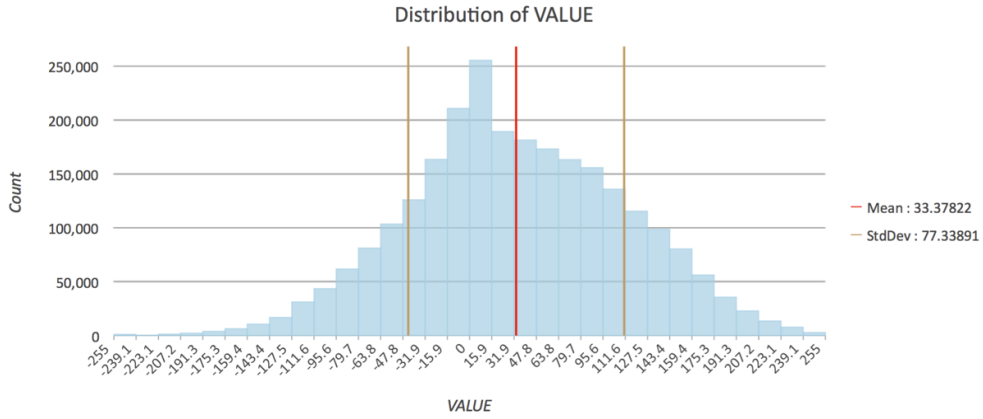

Figura 7.10 Istogramma di distribuzione dei valori dei pixel del raster risultante dalla sottrazione tra la banda RED dell'immagine di output della rete VDSR e dell'immagine di riferimento acquisita da UAV

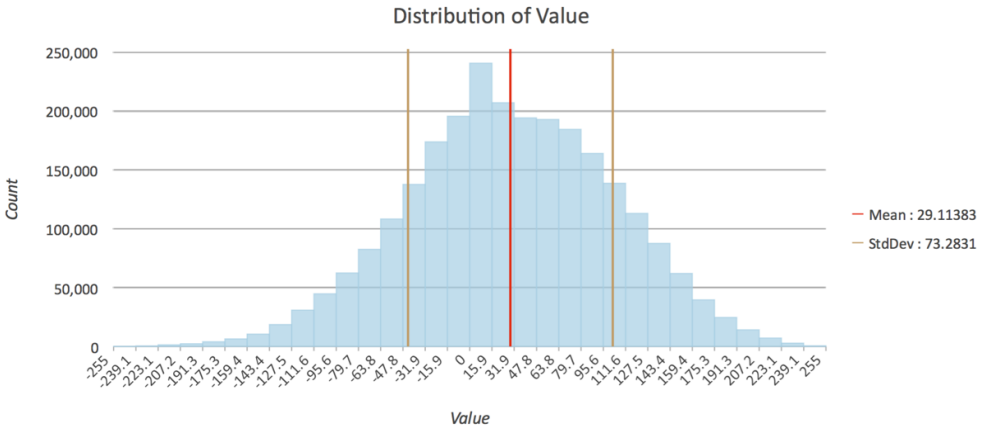

Figura 7.11 Istogramma di distribuzione dei valori dei pixel del raster risultante dalla sottrazione tra la banda GREEN dell'immagine di output della rete VDSR e dell'immagine di riferimento acquisita da UAV

I risultati mostrati nei grafici ottenuti confermano quanto già evidenziato dal confronto visivo. La rete VDSR ottiene risultati migliori rispetto a quelli ottenuti con interpolazione bicubica, ma, essendo i valori dello stesso ordine di grandezza, si può concludere che l'efficacia dei due metodi sia comparabile.

7.2 Analisi su un'area di 26 ettari

La rete VDSR è stata applicata a una seconda immagine, estratta dalla stessa immagine satellitare da cui è stata estratta l'immagine dell'analisi precedente. Tuttavia, l'area inquadrata in questa indagine (*Figura 7.12*), è maggiore, misura circa 26 ettari. Inoltre, l'immagine è a colori reali.

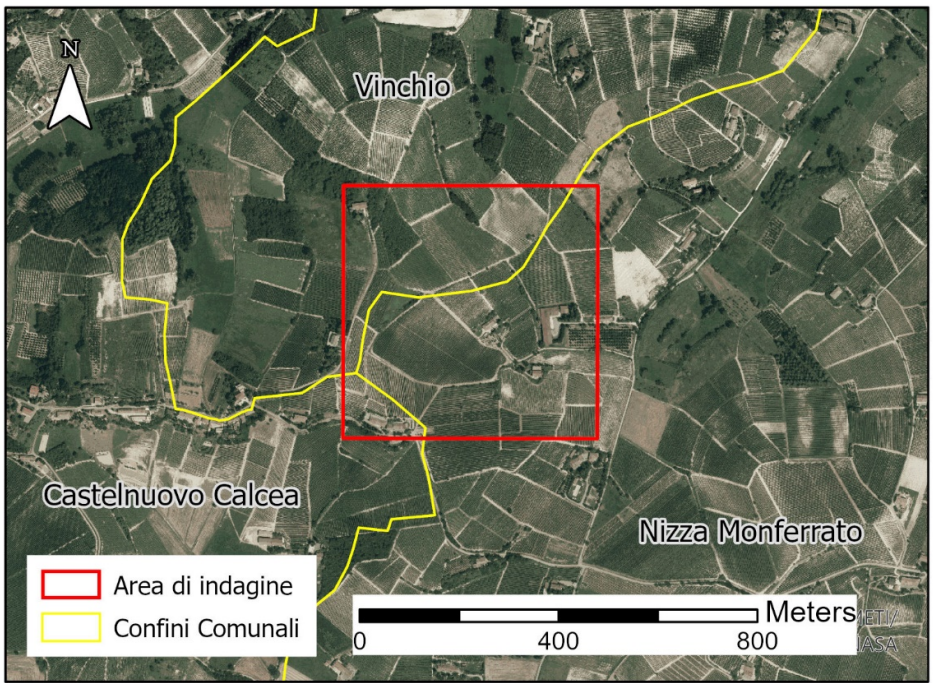

Figura 7.12 Inquadramento area di indagine

L'immagine ha dimensioni pari a 51 x 51 pixel, viene inserita nella rete VDSR e dopo il processo iterativo di riattivazione della rete neurale si ottiene un'immagine di output di dimensioni pari a 1632 x 1632 pixel.

Non avendo a disposizione l'immagine di riferimento per questa seconda esecuzione della rete non è possibile calcolare gli indici di qualità calcolati per la prova precedente.

Dal confronto tra l'immagine di input e quella di output (*Figura 7.13*) è evidente che, nonostante non siano stati ricreati i dettagli che caratterizzano i filari dei vigneti inquadrati, i vari appezzamenti risultano più definiti così come le strade e gli edifici.

Considerando il fatto che il data set di training è composto esclusivamente da foto di un vigneto ancora giovane e che l'area da cui le immagini sono estratte è differente da quella inquadrata Il risultato si può ritenere soddisfacente.

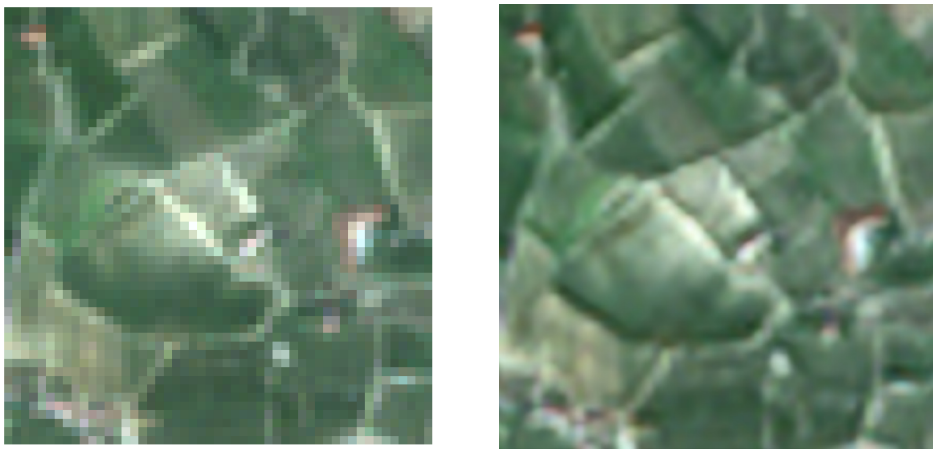

Figura 7.13 Confronto immagine di input e immagine di output della rete VDSR

Per cercare di quantificare il miglioramento dell'immagine attraverso la rete VDSR, è stata eseguita una sovrapposizione delle strade delineate sulle foto aeree messe a disposizione sotto forma di WMS dall'Agenzia per l'Erogazione in Agricoltura (AGEA) a integrazione dei dati scaricati da BDTRE [39] disponibili sul portale della regione Piemonte [40] e i tratti di strada tracciati manualmente a partire dall'immagine a risoluzione aumentata.

Sono stati creati due *shapefile* poligonali cercando di delineare in maniera più accurata possibile il percorso riconosciuto su entrambe le immagini.

Figura 7.14 Confronto tra la superficie delle strade tracciate sulle ortofoto AGEA (sx) e la superficie delle strade tracciata sull'immagine di output della rete VDSR

Dalla sovrapposizione dei due *shapefile* è risultato che circa l'80% della superficie delle strade delineate sulle ortofoto AGEA è stata correttamente tracciata sull'immagine aumentata attraverso la super-risoluzione.

Tabella 5 Area di sovrapposizione delle strade tracciate sulle ortofoto AGEA e delle strade tracciate sull'immagine di output della rete VDSR

AREA DI SOVRAPPOSIZIONE		
	px	m^2
Area strade BDTRE	238106	23506
Area strade VDSR	516634	49941
Area strade sovrapposte	191436	18899

Tuttavia, va tenuto in conto che le strade tracciate sull'immagine di output della rete neurale ricoprono una superficie superiore rispetto a quelle, più precise, tracciate sulle ortofoto AGEA. Da questa analisi si può trarre la conclusione che le strade risultano visivamente più definite e più facilmente distinguibili a seguito dell'applicazione della rete VDSR.

8 CONCLUSIONI

Questo studio nasce con la finalità di valutare l'applicabilità della rete neurale convoluzionale VDRS all'ambito dell'agricoltura di precisione e, in generale, del monitoraggio della vegetazione. Per questo motivo la rete è stata addestrata mediante immagini acquisite da UAV e impiegata per ottenere, a partire da un'immagine satellitare a bassa risoluzione e ad accesso libero, un'immagine a risoluzione migliorata.

I risultati ottenuti, descritti nel capitolo precedente, mostrano la variabilità della risposta della rete VDSR in funzione dell'estensione dell'immagine di input. Per un'area di indagine di circa 1,5 ettari, come quella della prima analisi, i risultati ottenuti con interpolazione bicubica e con rete neurale VDSR sono comparabili.

Questo evidenzia che per aree di estensione simile l'applicazione della rete VDSR non offre risultati superiori rispetto a quelli che si ottengono da altre tecniche più semplici come appunto l'interpolazione bicubica.

D'altro canto, va tenuto in conto che impiegando una rete neurale convoluzionale è possibile migliorare il dato di input sfruttando informazioni ricavate da un numero di dati molto elevato mentre l'interpolazione opera nell'intorno dei singoli pixel dell'immagine.

La seconda analisi, effettuata sull'area di circa 26 ettari, evidenzia come l'applicazione della rete VDSR ad aree di tale ordine di grandezza enfatizzi i dettagli dell'immagine consentendo di individuare in maniera più accurata i contorni degli elementi inquadrati, come le strade, che risultano visivamente più nitide.

I risultati ottenuti si prestano a essere il punto di partenza per ulteriori studi, atti a determinare come poter migliorarne le caratteristiche della rete VDSR nell'ambito dell'agricoltura di precisione.

Possibili sviluppi futuri, potrebbero essere raggiunti modificando la rete neurale per poter accettare come immagini di input le singole bande così da non dover necessariamente operare con immagini composte da tre bande.

Inoltre, le immagini che nel presente studio sono state utilizzate come dati di input della rete VDSR, sono immagini a bassa risoluzione, acquisite da Sentinel-2, messe a disposizione in forma gratuita dall'Agenzia spaziale europea. In studi futuri si potrebbero impiegare come dati di input immagini satellitari ad alta risoluzione.

Si vuole precisare, infine, che il lavoro eseguito presenta delle limitazioni dovute alla scarsa potenza di calcolo a disposizione e al numero ridotto delle immagini utilizzate per il *training*. Inoltre, il *data set* per l'addestramento della rete è composto esclusivamente da immagini di un vigneto ancora molto giovane. Integrare questi aspetti sarebbe opportuno per valutare con più accuratezza l'efficacia della rete VDSR nell'ambito dell'agricoltura di precisione.

9 RINGRAZIAMENTI

Un sentito ringraziamento a tutte le persone che mi sono state vicine questi anni e che mi hanno aiutato a portare a termine questo lavoro di tesi.

Il ringraziamento più grande di tutti va ai miei genitori che da sempre mi sostengono nella realizzazione dei miei progetti. Un grazie enorme ai miei fratelli che mi hanno ascoltato, supportato e aiutato nei momenti di difficoltà.

Grazie ai miei amici e alla mia ragazza, Sara, per essere stati sempre presenti e per aver ascoltato i miei sfoghi. Ringrazio il mio collega Alessandro per aver condiviso con me questa ultima fase del mio percorso di studi e la mia collega Marina per i suoi preziosi consigli.

Grazie a Stefano Angeli che ci ha affiancato sul campo e si è occupato delle acquisizioni delle immagini da UAV. Grazie all'azienda agricola Brevi Pendii, a Piero e Ilenia per la loro disponibilità, gentilezza e generosità.

Infine ringrazio il mio computer, che il giorno prima della consegna della tesi ha smesso di funzionare ed è stato formattato.

10 BIBLIOGRAFIA

[1] E. Chuvieco, Fundamentals of Satellite Remote Sensing an Environmental Approach, Second Edition, Boca Raton, FL: CRC Press, 2016.

[2] K. N. Tiwari, C. Chatterjee, N. K. Gontia e S. K. Jena, Remote Sensing & Gis Applications https://agrimoon.com/remote-sensing-and-gis-application-pdf-book/.

[3] A. S. Chauhan, R. Sharma, A. Kumar, K. Malik e H. Dagar, Applications of Remote Sensing in Agriculture, 2018.

[4] E. Imam, «Remote Sensing Platforms and Sensors» 2019.

[5] M. Arjomandi, Classification of Unmanned Aerial Vehicles, 2017.

[6] A. Matese, P. Toscano, S. F. D. Gennaro, L. Genesio, F. P. Vaccari, J. Primicerio, C. Belli, A. Zaldei, R. Bianconi e B. Gioli, «Intercomparison of UAV, Aircraft and Satellite Remote Sensing Platforms for Precision Viticulture,» *Remote sensing,* 2015.

[7] E. M. Zareb e Y. Bouzid, «Air quality monitoring by using UAV flight system: A review» 2019.

[8] «MAPIR» [Online]. Available: https://www.mapir.camera/pages/survey3-cameras#specs.

[9] «PARROT» [Online]. Available: https://support.parrot.com/it/support/prodotti/parrot-bluegrass/sequoia.

[10] «EOPTIS SRL» [Online]. Available: https://www.eoptis.com/it/prodotti/standard/camera-multispettrale.

[11] J. W. RouseJr., R. Haas, J. Schell e D. Deering, «Monitoring vegetation systems in the great plains with erts," NASA Special Publication 351, 309» 1974.

[12] V. Kafira, K. Albanakis e D. Oikonomidis, «Flood Susceptibility Assessment using G.I.S. An example from Kassandra Peninsula, Halkidiki, Greece» 2015.

[13] P. Cinat, S. F. D. Gennaro, A. Berton e A. Matese, «Comparison of Unsupervised Algorithms for Vineyard Canopy Segmentation from UAV Multispectral Images» *Remote sensing,* 2019.

[14] D. C. Tsouros, S. Bibi e P. Sarigiannidis, A Review on UAV-Based Applications for Precision Agriculture, 2019.

[15] E. R. Hunt e C. S. T. Daughtry, «What good are unmanned aircraft systems for agricultural remote sensing and precision agriculture?» *International Journal of Remote Sensing,* 2017.

[16] M. Weiss, F. Jacob e B. Duveiller, «Remote sensing for agricultural applications: A meta-review» *Remote Sensing of Environment,* vol. 236, 2020.

[17] M. Robertson, P. Carberry e L. Brennan, «The economic benefits of precision agriculture: case studies from Australian grain farms» 2007.

[18] C. B. Silva, S. M. L. R. d. Vale, F. A. C. Pinto, C. A. S. Müller e A. D. Moura, «The economic feasibility of precision agriculture in Mato Grosso do Sul State, Brazil: a case study,» 2007.

[19] A. Mittal, R. Soundararajan e A. C. Bovik, Making a "Completely Blind" Image Quality Analyzer, 2013.

[20] M. Kawulok, P. Benecki, S. Piechaczek, K. Hrynczenko e D. Kostrzewa, Deep Learning for Multiple-Image Super-Resolution, 2019.

[21] A. Ducournau e R. Fablet, «Deep Learning for Ocean Remote Sensing: An Application of Convolutional Neural Networks for Super-Resolution on Satellite-Derived SST Data» 2016.

[22] S. Hijazi, R. Kumar e C. Rowen, «Using Convolutional Neural Networks».

[23] K. Simonyan, A. Vedaldi e A. Zisserman, «Deep inside convolutional networks: visualising image classification models and saliency maps. 1–8.,» 2014.

[24] J. Dai, Y. Li, K. He e J. Sun, «Object Detection via Region-based Fully Convolutional Networks» in *Advances in Neural Information Processing Systems*, 2016.

[25] C. Dong, C. C. Loy, K. He e X. Tang, Learning a Deep Convolutional Network for Image Super-Resolution, Fleet, David and Pajdla, Tomas and Schiele, Bernt and Tuytelaars, Tinne, 2014.

[26] «AIgeekprogrammer, Convolutional neural network 2: architecture» 2019. [Online]. Available: https://aigeekprogrammer.com/convolutional-neural-network-image-recognition-part-2/.

[27] L. B. Y. B. P. H. Yann LeCun, «Gradient-Based Learning APplied to Document Recognition» 1998.

[28] «ESA Sentinel Online» [Online]. Available: https://sentinel.esa.int/web/sentinel/home.

[29] E. Zioga, A. Panagiotopoulou, M. Stefouli, E. Charou, L. Grammatikopoulos, E. Bratsolis e N. Madamopoulos, Spatial Resolution Enhancement of Remote Sensing Mine Images using Deep Learning Techniques, 2020.

[30] «D. Glasner, S. Bagon and M. Irani, "Super-resolution from a single image," 2009 IEEE 12th International Conference on Computer Vision, Kyoto, 2009, pp. 349-356, doi: 10.1109/ICCV.2009.5459271.».

[31] X. Z. Y. T. W. W. J. X. a. Q. L. W. Yang, «Deep Learning for Single Image Super-Resolution: A Brief Review» *IEEE Transactions on Multimedia, vol. 21, no. 12, pp. 3106-3121,* 2019.

[32] Y. Zhang, K. Li, K. Li, L. Wang, B. Zhong e Y. Fu, «Image Super-Resolution Using Very Deep Residual Channel Attention Networks. In: Ferrari V., Hebert M., Sminchisescu C., Weis» 2018.

[33] «D. Kim, J. Kim, J. Kwon and T. Kim, "Depth-Controllable Very Deep Super-Resolution Network," 2019 International Joint Conference on Neural

Networks (IJCNN), Budapest, Hungary, 2019, pp. 1-8, doi: 10.1109/IJCNN.2019.8851874.».

[34] DJI. [Online]. Available: https://www.dji.com/it/p4-multispectral.

[35] «MathWorks» [Online]. Available: https://it.mathworks.com/help/images/single-image-super-resolution-using-deep-learning.html.

[36] M. Casabona, «Deep learning basato su immagini da drone per la super risoluzione di scene multispettrali acquisite da satellite,» 2020.

[37] L. Zhu, J. Suomalainen, J. Liu, J. Hyyppä, H. Kaartinen e H. Haggren, A Review: Remote Sensing Sensors, Multi-purposeful Application of Geospatial Data, Rustam B. Rustamov, Sabina Hasanova and Mahfuza H. Zeynalova, IntechOpen, DOI: 10.5772/intechopen.71049. Available from: https://www.intechopen.com/books/multi-purposeful-a, December 20th 2017.

[38] A. Horé e D. Ziou, Image quality metrics: PSNR vs. SSIM, 2010.

[39] «BDTRE 2019 - Database GeoTopografico (dataset vettoriale),» [Online]. Available: http://www.geoportale.piemonte.it/geocatalogorp/index.jsp.

[40] «Geoportale Regione Piemonte» [Online]. Available: https://www.geoportale.piemonte.it/cms/.

11 ALLEGATI

11.1 Specifiche tecniche Phantom 4 di DJI

Specifications	
Aircraft	
Weight (Battery & Propellers Included)	1380 g
Max Ascent Speed	6 m/s (Sport mode)
Max Descent Speed	4 m/s (Sport mode)
Max Speed	20 m/s (Sport mode)
Max Service Ceiling Above Sea Level	19685 feet (6000 m) (Software altitude limit: 400 feet above takeoff point)
Max Flight Time	Approx. 28 minutes
Operating Temperature Range	32° to 104° F (0° to 40° C)
Satellite Systems	GPS/GLONASS
Gimbal	
Controllable Range	Pitch: - 90° to + 30°
Obstacle Sensing System	
Obstacle Sensory Range	2 - 49 feet (0.7 - 15 m)
Operating Environment	Surface with clear pattern and adequate lighting (lux > 15)
Vision Positioning System	
Velocity Range	≤10 m/s (2 m above ground)
Altitude Range	0 - 33 feet (0 - 10 m)
Operating Range	0 - 33 feet (0 - 10 m)
Operating Environment	Surfaces with a clear pattern and adequate lighting (lux > 15)
Camera	
Sensor	1/2.3” Effective pixels:12 M
Lens	FOV (Field Of View) 94° 20 mm (35 mm format equivalent) f/2.8 focus at ∞
ISO Range	100-3200(video) 100-1600(photo)
Electronic Shutter Speed	8 s to 1/8000 s
Max Image Size	4000 x 3000
Still Photography Modes	Single shot Burst shooting: 3/5/7 frames Auto Exposure Bracketing (AEB): 3/5 Bracketed frames at 0.7EV Bias Time-lapse HDR
Video Recording Modes	UHD: 4096×2160 (4K) 24 / 25p 3840×2160 (4K) 24 / 25 / 30p 2704×1520 (2.7K) 24 / 25 / 30p FHD: 1920×1080 24 / 25 / 30 / 48 / 50 / 60 / 120p HD: 1280×720 24 / 25 / 30 / 48 / 50 / 60p
Max. Bitrate Of Video Storage	60 Mbps

Supported File Systems	FAT32 (≤ 32 GB); exFAT (> 32 GB)
Photo	JPEG, DNG (RAW)
Video	MP4 / MOV (MPEG – 4 AVC / H.264)
Supported SD Cards	Micro SD, Max capacity: 64GB. Class 10 or UHS-1 rating required
Operating Temperature	32° to 104° F (0° to 40° C)

Remote Controller	
Operating Frequency	2.400 GHz to 2.483 GHz
Max Transmission Distance	FCC Compliant: 3.1 mi (5 km); CE Compliant: 2.2 mi (3.5 km) (Unobstructed, free of interference)
Operating Temperature	32° to 104° F (0° to 40° C)
Battery	6000 mAh LiPo 2S
Mobile Device Holder	Tablets and smartphones
Transmitter Power (EIRP)	FCC: 23 dBm; CE: 17 dBm
Operating Voltage	7.4V @ 1.2A
Charger	
Voltage	17.4 V
Rated Power	100 W
Intelligent Flight Battery (PH4 - 5350 mAh -15.2 V)	
Capacity	5350 mAh
Voltage	15.2 V
Battery Type	LiPo 4S
Energy	81.3 Wh
Net Weight	462 g
Operating Temperature	14° to 104° F (-10° to 40° C)
Max. Charging Power	100 W

11.2 Codice rete VDSR

```
%% VDSR (Very-Deep Super-Resolution)
clc
clear all
close all
%% LOADING TRAINING DATA %%
trainImagesDir = ('F:\progetto_metashape\grid result\train-
ing_dataset');
exts = {'.tif'};
pristineImages = imageDatastore(trainImagesDir,'FileExten-
sions',exts);
% Numerosità del training dataset
numel(pristineImages.Files)

%% PREPARE TRAINING DATA %%
% generazione di coppie di immagini: upsampled image e cor-
rispondente immagine dei residui
upsampledDirName = [trainImagesDir filesep 'upsam-
pledImages'];
residualDirName = [trainImagesDir filesep 'residualImages'];
% createVDSRTrainingSet helper function per:
% - convertire l'immagine nello spazio YCbCr;
% - ridurre la dimensione del canale della luminanza Y
% attraverso diversi fattori di scala per creare
% immagini a bassa risoluzione, quindi riportare
% l'immagine alla dimensione originale con
% interpolazione bicubica;
% - calcolare la differenza tra l'immagine incontaminata e
% quella ridimensionata;
% - salvare le due immagini su disco;
scaleFactors = [2 3 4];
createVDSRTrainingSet(pristineImages,scaleFactors,upsam-
pledDirName,residualDirName);

%% DEFINE PREPROCESSING PIPELINE FOR TRAINING SET %%
% creazione di un datastore di immagini upsampled e residui
% calcolati; Per essere lette necessitano di un helper
% function(matRead)
upsampledImages = imageDatastore(upsampledDirName,'FileEx-
tensions','.mat','ReadFcn',@matRead);
residualImages = imageDatastore(residualDirName,'FileExten-
sions','.mat','ReadFcn',@matRead);
% specificazione dei parametri per aumentare i dati di trai-
ning (rotazione, riflessione in direzione x)
ang_dir = -10;
ang_analisi = 20;
augmenter = imageDataAugmenter( ...
    'RandRotation',@() (rand-0.5)*ang_analisi+ang_dir, ...
    'RandXReflection',true);
```

```
% estrazione casuale di porzioni (patch) dai datastore
% delle immagini upsampled e dei residui;
% Per una rete con D layers convoluzionali, il
% campo ricettivo ha dimensione (2D+1)-by-(2D+1)
% VDSR ha 20 levels convoluzionali, quindi il % campo ricet-
tivo ha dim 41x41.
patchSize = [41 41];
patchesPerImage = 128;
dsTrain = randomPatchExtractionDatastore(upsampledImages,re-
sidualImages,patchSize, ...
    "DataAugmentation",augmenter,"PatchesPerImage",patches-
PerImage);
% preview delle letture dal datastore
inputBatch = preview(dsTrain);
disp(inputBatch)

%% SET UP VSDR LAYERS %%
% Image Input Layer
networkDepth = 20;
firstLayer = imageInputLayer([41 41 1],'Name','InputLay-
er','Normalization','none');
% 2D Convolutional Layer
% ReLU Layer: introduce non linearità nella rete.
convLayer = convolution2dLayer(3,128,'Padding',1, ...
    'WeightsInitializer','he','BiasInitializer','ze-
ros','Name','Conv1');
relLayer = reluLayer('Name','ReLU1');
% Middle Layer, contiene 18 layer in cui si alternano
% lineari convoluzionali e ReLU che introduco la non
% linearità nella rete
middleLayers = [convLayer relLayer];
for layerNumber = 2:networkDepth-1
    convLayer = convolution2dLayer(3,128,'Padding',[1 1],
...
        'WeightsInitializer','he','BiasInitializer','zeros',
...
        'Name',['Conv' num2str(layerNumber)]);
    relLayer = reluLayer('Name',['ReLU' num2str(lay-
erNumber)]);
    middleLayers = [middleLayers convLayer relLayer];
end
% Convolutional Layer, singolo filtro 3x3x64 che ricostru-
isce l'immagine
convLayer = convolution2dLayer(3,1,'Padding',[1 1], ...
    'WeightsInitializer','he','BiasInitializer','zeros', ...
    'NumChannels',128,'Name',['Conv' num2str(network-
Depth)]);
% Ultimo leyer, layer di regressione che calcola
% lo scarto quadratico medio tra l'immagine dei residui % e
la stima della rete
```

```
finalLayers = [convLayer regressionLayer('Name','Fi-
nalRegressionLayer')];
% Concatenazione dei layer per formare la rete VDSR
layers = [firstLayer middleLayers finalLayers];
% Helper function: alternativa per creare la rete VDSR
layers = vdsrLayers;

%% SPECIFY TRAINING OPTIONS %%
% La funzione 'trainingOptions' permette di specificare % le
impostazioni iperparametriche del SGDM (Stochastic % Gra-
dient Descent with Momentum optimization)
maxEpochs = 100;
epochIntervals = 1;
initLearningRate = 0.1;
learningRateFactor = 0.1;
l2reg = 0.0001;
miniBatchSize = 128;
options = trainingOptions('sgdm', ...
    'Momentum',0.9, ...
    'InitialLearnRate',initLearningRate, ...
    'LearnRateSchedule','piecewise', ...
    'LearnRateDropPeriod',10, ...
    'LearnRateDropFactor',learningRateFactor, ...
    'L2Regularization',l2reg, ...
    'MaxEpochs',maxEpochs, ...
    'MiniBatchSize',miniBatchSize, ...
    'GradientThresholdMethod','l2norm', ...
    'GradientThreshold',0.01, ...
    'Plots','training-progress', ...
    'Verbose',false);

%% TRAIN THE NETWORK %%
% funzione 'trainNetwork' per effettuare l'allenamento
% do Train = false carica una rete già allenata
% do Train = true allena una nuova rete
doTraining = false;
if doTraining
    modelDateTime = datestr(now,'dd-mmm-yyyy-HH-MM-SS');
    [net, info] = trainNetwork(dsTrain,layers,options);
    save(['trainedVDSR-' modelDateTime '-Epoch-'
num2str(maxEpochs*epochIntervals) '-ScaleFactors-'
num2str(234) '.mat'],'net','options');
else
    load('trainedVDSR-06-Nov-2020-18-25-15-Epoch-100-Scale-
Factors-234');
end

%% PERFORM SINGLE IMAGE SUPER-RESOLUTION USING VDSR NETWORK
%%
% step per eseguire SIRS utilizzando la rete VDSR
%% LOADING HIGH-RESOLUTION REFERENCE IMAGE %%
```

```
% questa immagine verrà utilizzata per il confronto dei
% risultati della super-risoluzione con quelli ottenuti %
con interpolazione bicubica
exts = {'.tif'};
dir = 'F:\Dataset\highres\';
filename = [dir,'highres_fc.tif'];
Ireference = imread(filename);
Ireference = im2double(Ireference);
figure (5)
imshow(Ireference)
title('High-Resolution Reference Image')
exts = {'.tif'};
dir = 'F:\Dataset\lowres\';
filename = [dir,'lowres_satellite_rgb_prova_2.tif'];
Ilowres = imread(filename);
Ilowres = im2double(Ilowres);
figure (10)
imshow(Ilowres)
title('Low-Resolution Reference Image')

%% DEFINITION OF IMAGE DIMENSIONS
% si pongono le dimensioni di partenza pari a quelle
% dell'immagine  a bassa risoluzione di input
[nrows_l,ncols_l,np_l] = size(Ilowres);
nrows = nrows_l;
ncols = ncols_l;

%% IMPROVE IMAGE RESOLUTION USING PRETRAINED VDSR NETWORK
% Conversione dell'immagine RGB nel canale della luminanza e
crominanza
Iycbcr = rgb2ycbcr(Ilowres);
Iy = Iycbcr(:,:,1);
Icb = Iycbcr(:,:,2);
Icr = Iycbcr(:,:,3);
% Ricampionamento con interpolazione bicubica
Iy_bicubic = imresize(Iy,[nrows ncols],'bicubic');
Icb_bicubic = imresize(Icb,[nrows ncols],'bicubic');
Icr_bicubic = imresize(Icr,[nrows ncols],'bicubic');
% Passaggio della componente ottenuta all'interno della %
rete VDSR per ottenere l'immagine dei residui
Iresidual = activations(net,Iy_bicubic,41);
Iresidual = double(Iresidual);
figure (30)
imshow(Iresidual,[])
title('Residual Image from VDSR')
% Somma dei residui all'immagine ingrandita per ottenere la
componente di luminanza ad alta risoluzione
Isr = Iy_bicubic + Iresidual;
% Conversione dell'immagine in RGB
Ivdsr = ycbcr2rgb(cat(3,Isr,Icb_bicubic,Icr_bicubic));
figure (40)
```

```
imshow(Ivdsr)
title('High-Resolution Image Obtained Using VDSR')

%% VISUAL AND QUANTITATIVE COMPARISON
% Calcolo delle seguenti metriche:
% PSNR = peak signal-to-noise ratio
% SSIM = structural similarity index
% NIQE = naturalness image quality avaluator

Ireference = imresize(Ireference, [nrows,ncols]);
vdsrPSNR = psnr(Ivdsr,Ireference)
vdsrSSIM = ssim(Ivdsr,Ireference)
vdsrNIQE = niqe(Ivdsr)

%% ITERAZIONE PER MIGLIORARE LA QUALITà
n = 30;
k = 1;
for k = 1:5
    Ilowres = Ivdsr;
nrows = nrows*2;
ncols = ncols*2;
Iycbcr = rgb2ycbcr(Ilowres);
Iy = Iycbcr(:,:,1);
Icb = Iycbcr(:,:,2);
Icr = Iycbcr(:,:,3);
Iy_bicubic = imresize(Iy,[nrows ncols],'bicubic');
Icb_bicubic = imresize(Icb,[nrows ncols],'bicubic');
Icr_bicubic = imresize(Icr,[nrows ncols],'bicubic');
Iresidual = activations(net,Iy_bicubic,41);
Iresidual = double(Iresidual);
n = n+1;
figure (n)
imshow(Iresidual,[])
title('Residual Image from VDSR')
Isr = Iy_bicubic + Iresidual;
Ivdsr = ycbcr2rgb(cat(3,Isr,Icb_bicubic,Icr_bicubic));
% Ireference = imresize(Ireference, [nrows,ncols]);
% vdsrPSNR = psnr(Ivdsr,Ireference)
% vdsrSSIM = ssim(Ivdsr,Ireference)
vdsrNIQE = niqe(Ivdsr)
end
%%
figure (41)
imshow(Ivdsr)
```

11.3 Elaborati grafici

TAVOLA 1: Inquadramento
Area 1,5 ettari

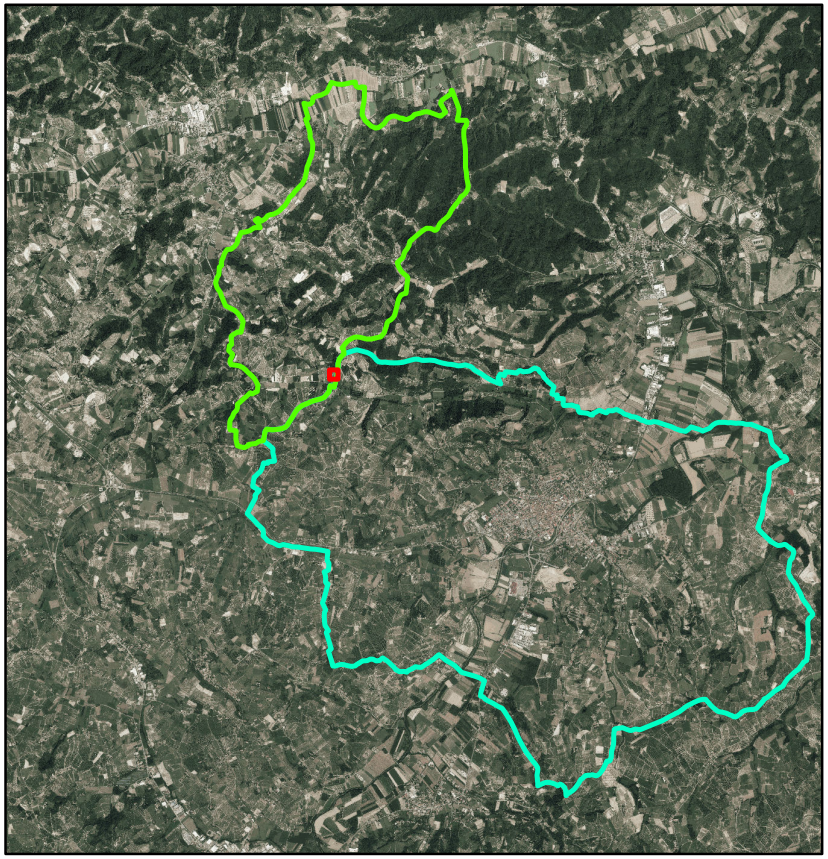

Area di analisi 2 ettari
Comune di Vinchio
Comune di Nizza Monferrato

Kilometers
0 1 2 4

N

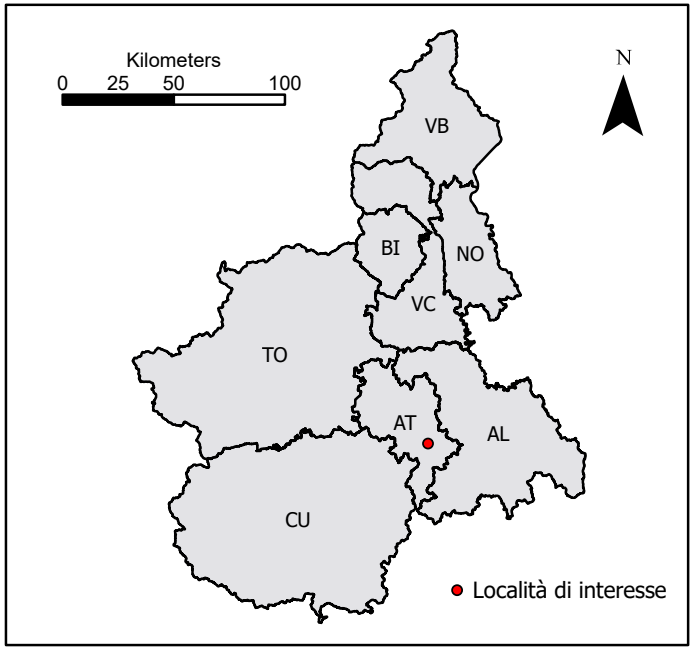

Area di analisi
Confini Comunali

Immagine UAV	Immagine satellite	Immagine VDSR	TAVOLA 2: risultato VDSR
N	N	N	Area di analisi di 1,5 ettari
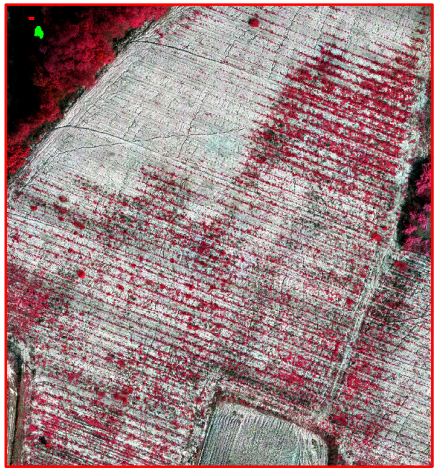	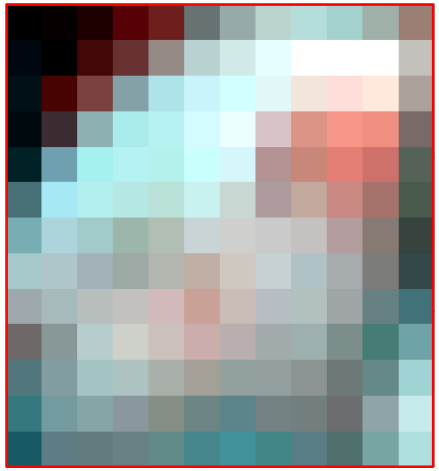	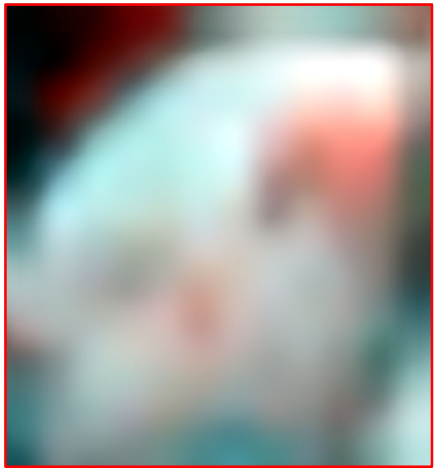	scala 1 : 2000
Meters 0 50 100	Meters 0 50 100	Meters 0 50 100	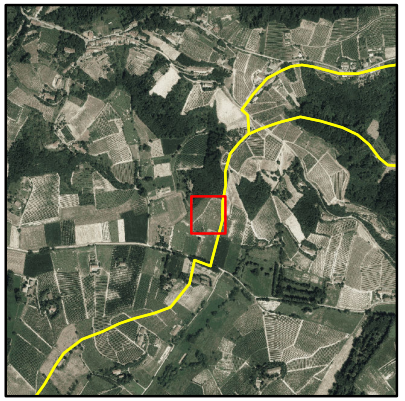 Kilometers 0 0.5 1 Area di analisi Confini Comunali

NDVI UAV

Meters
0 50 100

N

Area di analisi

NDVI_highresolution

Value

1

0

NDVI VDSR

Meters
0 50 100

N

Area di analisi

NDVI_VDSR

Value

1

0

TAVOLA 3: Confronto NDVI

scala 1 : 2000

Kilometers
0 0.5 1

N

Area di analisi

Confini Comunali

TAVOLA 4: Inquadramento
Area 26 ettari

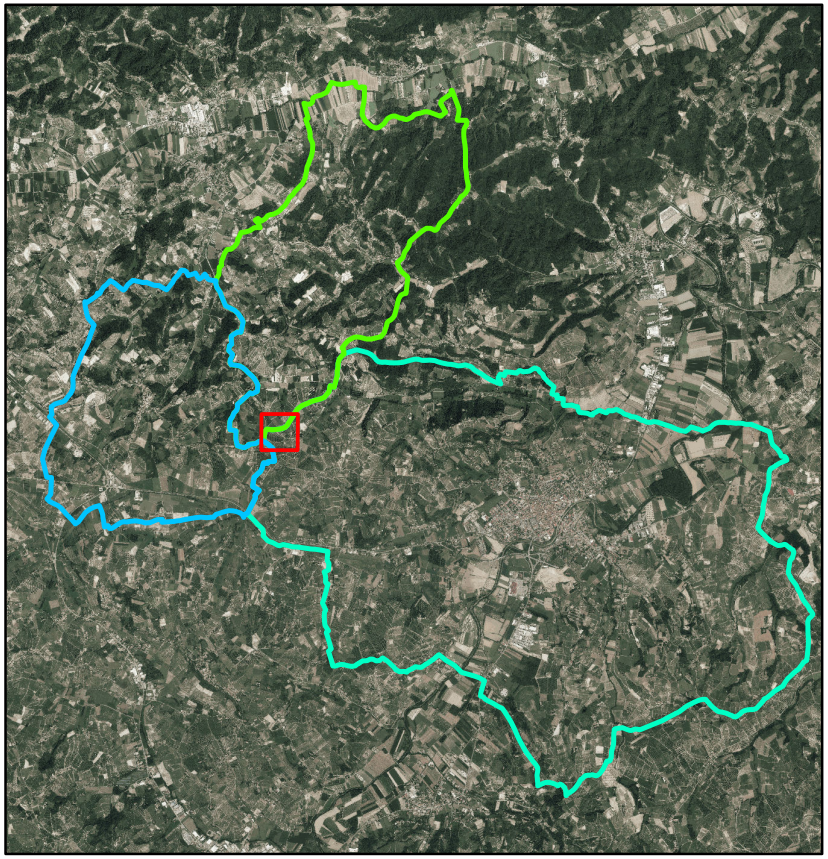

Comune di Castelnuovo Calcea
Comune di Vinchio
Comune di Nizza Monferrato
Area di analisi

Kilometers
0 1 2 4

N

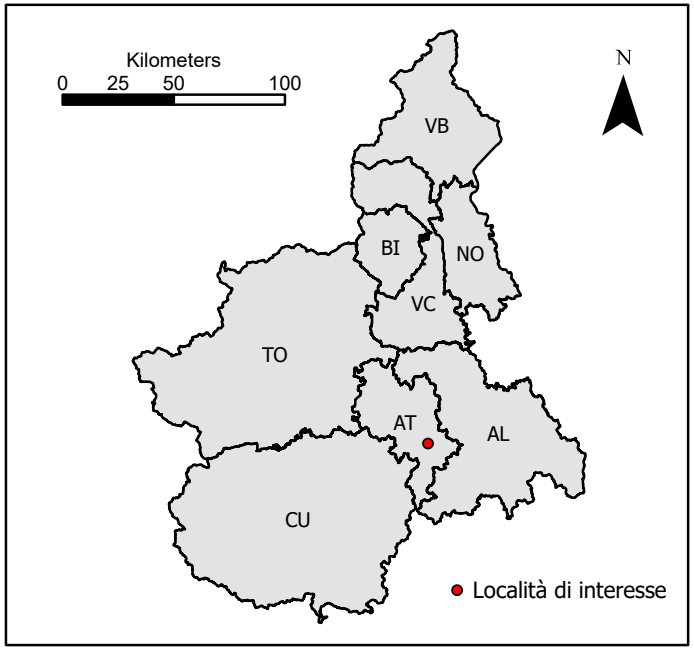

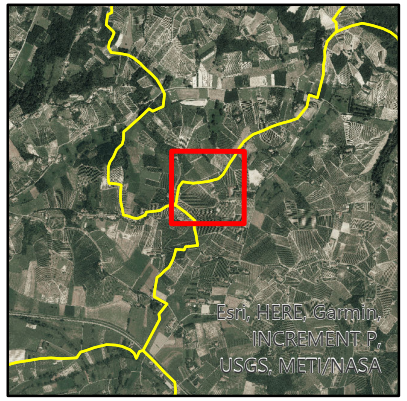

Kilometers
0 0.5 1

N

Area di analisi
Confini Comunali

IMMAGINE SATELLITE

Meters

0 50 100 200 300 400

IMMAGINE VDSR

Meters

0 50 100 200 300 400

TAVOLA 5: Risultato VDSR

Scala 1:5000

Area di analisi di 26 ettari

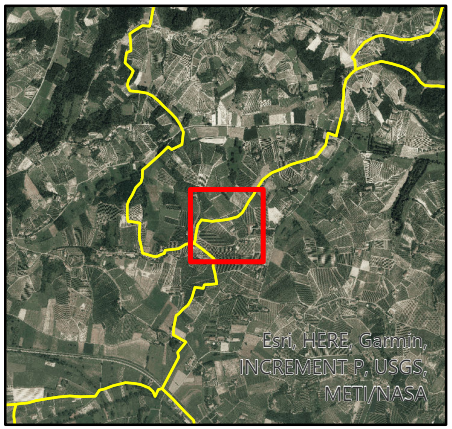

Kilometers

0 0.5 1

Area di analisi

Confini Comunali

IMMAGINE VDSR

IMMAGINE SATELLITE

TAVOLA 6: Risultato VDSR

Scala 1:5000

Area di analisi
Strade VDSR
Strade BDTRE

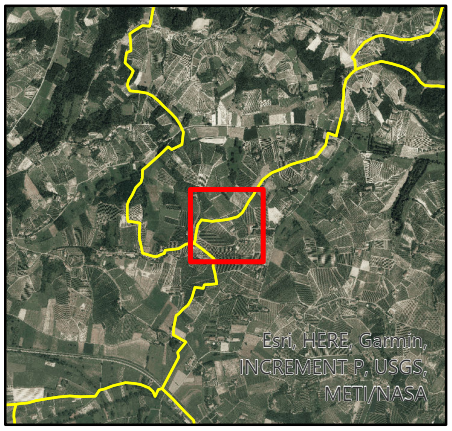

Area di analisi
Confini Comunali

IMMAGINE SATELLITE

TAVOLA 7: Sovrapposizione strade

N

Esri, HERE, Garmin, INCREMENT P, USGS

Meters

0 50 100 200 300 400

Scala 1:5000

- Area di analisi
- Strade tracciate correttamente
- Strade non tracciate

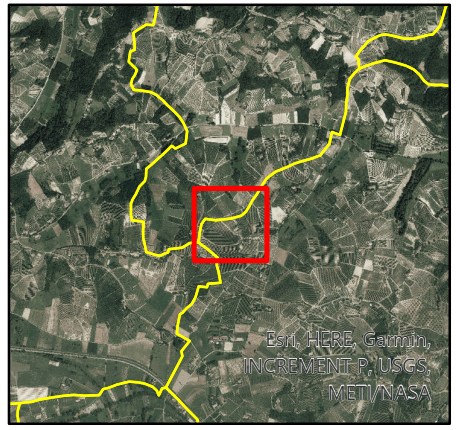

Kilometers

0 0.5 1

N

- Area di analisi
- Confini Comunali