

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

Anno accademico 2019 – 2020



Tesi di Laurea Magistrale

Deep learning basato su immagini da drone per la super
risoluzione di scene multispettrali acquisite da satellite

Relatori
Prof. Lingua Andrea Maria
Ing. Grasso Nives

Candidata
Casabona Marina

Introduzione

La tecnologia legata all'utilizzo dei droni ha subito nell'ultimo decennio un forte sviluppo migliorando la stabilità del mezzo, alleggerendo la struttura, perfezionando precisione e accuratezza dell'acquisizione e ottimizzando i software per l'elaborazione dei dati.

Questa tecnologia trova applicazione in svariati ambiti tra cui quello del monitoraggio ambientale, permettendo di congiungere l'acquisizione di dati su una area vasta con una risoluzione elevata e con informazioni multispettrali. Tuttavia, è necessario effettuare un'analisi dei costi in funzione della scala di applicazione e delle specifiche condizioni dell'area di interesse per valutare quando il rilevamento con UAV (Unmanned Aerial Vehicle) risulti più conveniente rispetto all'utilizzo di dati satellitari e tecniche di Remote Sensing.

In questo contesto si inserisce l'utilizzo del machine learning, e in particolare della Super-Risoluzione, che può trovare un'interessante applicazione in casi in cui sia necessario valutare attentamente diversi aspetti legati alla campagna di acquisizione, quali ad esempio aspetti economici o di tempo. I dati satellitari sono forniti in modalità open source, per quanto riguarda le missioni Sentinel del programma Copernicus, e questo è un notevole vantaggio che riduce i costi associati alle analisi; tuttavia la risoluzione di questi dati può risultare troppo bassa per gli studi che si vogliono effettuare. Si rende quindi necessario intervenire con metodi di processamento per migliorare la qualità del dato. Un altro aspetto che incentiva l'utilizzo dei dati satellitari, seppur sottoponendoli a metodi di miglioramento, è la tempistica di acquisizione; una campagna di rilievo con drone e la conseguente elaborazione dei dati richiedono diversi giorni di lavoro e questo va a incidere negativamente sia sull'immediata disponibilità del dato, sia sul fattore economico. Il dato satellitare, invece, è direttamente utilizzabile dopo averlo scaricato e viene fornito dai distributori già corretto in termini di riflettanza Top-Of-Atmosfere (Level-1C) o di riflettanza Bottom-Of-Atmosfere (Level-2A).

Con il presente lavoro si studia un procedimento che, attraverso l'utilizzo di una rete neurale convoluzione, utilizzi come dato di base le immagini satellitari e permetta di ottenere un prodotto a maggior risoluzione. Per raggiungere questo obiettivo si implementa la rete neurale VDSR (Very Deep Super Resolution), utilizzando per l'addestramento della rete le immagini acquisite da drone.

L'obiettivo di questo lavoro è lo studio dell'applicabilità della rete neurale VDSR (Very Deep Super Resolution) nel contesto del telerilevamento, utilizzando le immagini da drone come dati

di base per allenare la rete e le immagini satellitari come immagini di input su cui migliorare la risoluzione. L'obiettivo finale è la valutazione della validità del metodo per applicazioni di monitoraggio ambientale e per agricoltura di precisione, in particolare sulla possibilità di identificare porzioni di territori agricoli con diversa attività vegetativa sulla base di indici multispettrali, dunque in riferimento al comportamento spettrale. Per effettuare queste analisi i dati utilizzati contengono infatti informazioni nel campo delle lunghezze d'onda del visibile e dell'infrarosso vicino.

Nel primo capitolo si presentano le diverse tecnologie di Remote Sensing, ciascuna con i relativi vantaggi e svantaggi. Successivamente si esaminano nel dettaglio alcune camere multispettrali e iperspettrali utilizzabili per le acquisizioni con drone e si relazionano con le caratteristiche del sensore multispettrale della missione satellitare selezionata come più adatta per questo studio, la missione Copernicus Sentinel-2. Dopo questa prima parte sulle generalità delle due tecnologie utilizzate, si definisce l'algoritmo utilizzato per l'elaborazione dei dati, ossia la rete neurale convoluzionale VDSR. Si giunge dunque al centro dell'analisi, in cui si determinano i dati da utilizzare, i processamenti da effettuare per renderli idonei all'utilizzo, si definiscono le scelte per effettuare i test e gli strumenti con cui analizzare i risultati e valutarne l'accuratezza. Nel capitolo successivo sono riportati i risultati ottenuti. I test sono organizzati in due fasi: nella prima fase si eseguono le analisi su immagini RGB a colori reali al fine di consolidare il metodo; nella seconda fase si introducono le immagini multispettrali da cui sviluppare le specifiche analisi. Nella parte finale si commentano i risultati ottenuti, traendo le conclusioni relative all'utilizzo della rete VDSR per l'applicazione di monitoraggio ambientale studiata. Infine, nel capitolo degli allegati, si riportano le schede tecniche dei sensori, il codice per definire e utilizzare l'algoritmo della rete VDSR e gli elaborati grafici dei risultati ottenuti.

Grazie a questo studio è stato possibile testare la fattibilità dell'utilizzo della rete VDSR con un dataset innovativo e per un'applicazione ancora poco studiata in relazione alla tecnica di elaborazione del dato.

Ringraziamenti

Ringrazio i miei relatori, Prof. Lingua e Nives, per l'impegno, l'interesse e la disponibilità mostrate in questo lavoro di tesi. Mi avete dato la possibilità di avvicinarmi a questo campo di studio per me molto affascinante, fornendomi gli strumenti necessari e condividendo esperienza e consigli.

Sono grata ai docenti che mi hanno formata non solo per quanto riguarda le competenze tecniche, ma che mi hanno insegnato a ragionare e ad affrontare le problematiche in modo costruttivo.

Desidero ringraziare i miei genitori, che mi hanno permesso di portare a termine questo percorso sostenendomi negli studi e assecondando le mie scelte. Grazie anche a Silvia, solido punto di riferimento, che ha svolto a dovere il suo ruolo di sorella maggiore!

Un ringraziamento a tutti gli amici, la mia inseparabile amica Martina e i compagni di università, con i quali ho condiviso questi cinque anni di vita, non solo di intensissimo studio! Con loro mi sono potuta confrontare, disperare, entusiasmare e divertire.

Un grazie speciale ad Amedeo, sempre al mio fianco, mio sostegno. Grazie per ascoltarmi, per aiutarmi ad affrontare ciò che mi spaventa, per parlare di qualunque tematica insieme. E grazie per avermi concesso l'utilizzo del tuo computer potentissimo per velocizzare il training della rete!

Infine, un pensiero al mio computer che, nonostante i limiti computazionali, ha lavorato giorno e notte per esaudire le mie ardite richieste!

Torino,

ottobre 2020

Sommario

Introduzione	3
Ringraziamenti	6
Sommario	8
Elenco delle figure	10
Elenco delle tabelle	13
1. Tecnologie di Remote Sensing	16
1.1. Piattaforme di Remote Sensing	16
1.2. Sensori per il monitoraggio della vegetazione	21
2. Sensori per satellite	23
3. Camere multispettrali per drone	26
3.1. SlantRange 4P	26
3.2. MAPIR Survey3	28
3.3. Parrot SEQUOIA+	30
3.4. MAIA	31
3.5. Dji Phantom 4 Multispectral	34
3.6. Sensori a confronto	35
4. Camere iperspettrali per drone	37
4.1. Senop HSC-2	37
5. Calibrazione radiometrica	39
6. Single Image Super-Resolution (SISR) Using Deep Learning	41
6.1. Very-Deep Super-Resolution (VDSR)	42
7. Dati e pre-processing	48
7.1. Casi studio	48
7.2. Elaborazione immagini da drone	50

7.3.	Estrazione del dataset per il training	54
7.4.	Estrazione del dato per il test	55
8.	Metodologia	56
8.1.	Scelte operative per il training della rete VDSR	56
8.2.	Valutazione dell'accuratezza.....	58
8.2.1.	Metriche di qualità dell'immagine	58
8.2.2.	Confronto con BDTR	59
8.2.3.	Classificazione	60
8.3.	Analisi multispettrale	63
9.	Risultati.....	65
9.1.	Test 01: area studio di 2 ettari	66
9.2.	Test 02: area studio di 25 ettari	69
9.3.	Test 03: area studio di 400 ettari	75
10.	Conclusioni e commenti.....	80
11.	Allegati.....	83
11.1.	Schede tecniche camere multispettrali per drone.....	84
11.1.1.	Slant Range.....	84
11.1.2.	Mapir Survey 3	86
11.1.3.	Parrot Sequoia.....	88
11.1.4.	Maia WV.....	90
11.1.5.	Dji Phantom 4 Multispectral	92
11.2.	Scheda tecnica camera iperspettrale per drone	93
11.3.	Codice Matlab rete VDSR	94
11.4.	Elaborati grafici	100
12.	Bibliografia	109

Elenco delle figure

Figura 1: Variabilità delle caratteristiche al variare della tecnologia di Remote Sensing	16
Figura 2: andamento dei costi all'aumentare dell'estensione dell'area di analisi per le diverse tecnologie di Remote Sensing [1].....	20
Figura 3: satellite Sentinel-2 [6]	23
Figura 4: sensore multispettrale SlantRange 4P+ integrato con sensore di illuminazione e sistema di navigazione [10].....	26
Figura 5: sensore multispettrale SlantRange 4P+ [10].....	26
Figura 6: camera multispettrale MAPIR Survey 3 [11].....	28
Figura 7: ampiezza dell'inquadratura in base al tipo di lente utilizzata [11]	28
Figura 8: camera Parrot SEQUOIA+, sensore multispettrale e sensore di luminosità [12].....	30
Figura 9: sensore multispettrale con indicazione della posizione delle diverse bande [12]	30
Figura 10: sensore multispettrale MAIA WV [13]	31
Figura 11: spettro con indicazione degli intervalli di lunghezza d'onda che è possibile acquisire con i vari filtri passa-banda per la camera MAIA WV [13]	31
Figura 12: spettro con indicazione degli intervalli di lunghezza d'onda che è possibile acquisire con i vari filtri passa-banda per la camera MAIA S2 [13]	32
Figura 13: drone dji Phantom 4 Multispectral [14].....	34
Figura 14: camera multispettrale integrata dji Phantom 4 Multispectral [14]	34
Figura 15: camera iperspettrale Senop HSC-2 [16].....	37
Figura 16: firme spettrali di pannelli di calibrazione MAPIR [27]	40
Figura 17: schema di funzionamento del layer convoluzionale [25].....	44
Figura 18: struttura della rete neurale VDSR	46
Figura 19: definizione delle opzioni di training dell'algoritmo.....	47
Figura 20: ubicazione delle aree di studio.....	49
Figura 21: finestra relativa al caricamento delle immagini in Agisoft Metashape.....	50

Figura 22: impostazione dei sistemi di riferimento del progetto, delle camere e dei punti di appoggio.....	51
Figura 23: finestra relativa all'allineamento delle immagini e alla generazione della nuvola sparsa in Agisoft Metashape	51
Figura 24: finestra relativa al caricamento dei markers in Agisoft Metashape	52
Figura 25: finestra relativa alla collimazione dei punti di appoggio in Agisoft Metashape	52
Figura 26: finestra relativa alla generazione della nuvola densa in Agisoft Metashape.....	53
Figura 27: finestra relativa alla generazione del DEM in Agisoft Metashape	53
Figura 28: finestra relativa alla generazione dell'ortomosaico in Agisoft Metashape	54
Figura 29: schema logico e iterativo per la definizione delle impostazioni per il training della rete neurale	56
Figura 30: processo iterativo di attivazione della rete neurale VDSR; in figura sono mostrati i residui ottenuti come output di ogni step al crescere della dimensione dell'immagine.....	57
Figura 31: esempio di firme spettrali per le classi urbanizzato, vegetazione e suolo estratte da un'immagine RGB; sulle ascisse sono riportati i numeri di banda (1 = Red, 2 = Green, 3 = Blue), sulle ordinate i valori di DN	61
Figura 32: firma spettrale della vegetazione estratta da un'immagine satellitare Sentinel-2....	64
Figura 33: dati relativi al completamento del processo di training della rete neurale VDSR	65
Figura 34: finestra Matlab del training della rete neurale VDSR	66
Figura 35: Inquadramento area test 01	67
Figura 36: applicazione della rete neurale VDSR all'area test 01; si riportano i valori delle metriche PSNR, SSIM e NIQE per le immagini all'inizio e alla fine del processo iterativo	68
Figura 37: zoom relativo al confronto con BDTR dell'area studio Test 01	68
Figura 38: zoom relativo alle mappe dell'indice NDVI dell'area studio Test 01.....	69
Figura 39: inquadramento area test 02	70
Figura 40: zoom relativo al confronto con BDTR dell'area studio Test 02.....	71
Figura 41: zoom relativo alle mappe dell'indice NDVI dell'area studio Test 02.....	71
Figura 42: zoom relativo alla classificazione SVM dell'area studio Test 02	72

Figura 43: inquadramento area test 03	75
Figura 44: zoom relativo alle mappe dell'indice NDVI dell'area studio Test 03.....	76
Figura 45: zoom relativo alla classificazione SVM dell'area studio Test 03	77
Figura 46: Confronto tra interpolazione bicubica e rete neurale VDSR per il Test 01	82

Elenco delle tabelle

Tabella 1: confronto tra le principali caratteristiche delle tecnologie di Remote Sensing, evidenziandone vantaggi e svantaggi [1]	19
Tabella 2: panoramica sulle missioni Sentinel [6]	24
Tabella 3: lunghezze d'onda e ampiezza delle bande con rispettiva risoluzione spaziale per i satelliti Sentinel-2.....	25
Tabella 4: intervalli di lunghezza d'onda su cui si basano i filtri passa-banda per la camera MAIA WV [13].....	32
Tabella 5: intervalli di lunghezza d'onda su cui si basano i filtri passa-banda per la camera MAIA S2 [13]	33
Tabella 6: Confronto delle caratteristiche spettrali delle camere multispettrali per drone e del sensore MSI del satellite Sentinel-2	36
Tabella 7: Confronto delle caratteristiche geometriche ed economiche delle camere multispettrali per drone; la conversione da dollaro a euro è posta pari a 0.85	36
Tabella 8: caratteristiche spettrali, geometriche ed economiche della camera iperspettrale Senop HSC-2.....	38
Tabella 9: dettagli delle acquisizioni con drone a disposizione per i test	49
Tabella 10: dettagli delle acquisizioni satellitari a disposizione per i test	49
Tabella 11: specifiche tecniche computazionali del calcolatore utilizzato per l'elaborazione ...	65
Tabella 12: caratteristiche dimensionali delle immagini utilizzate per il test 01.....	67
Tabella 13: caratteristiche dimensionali delle immagini utilizzate per il test 02.....	70
Tabella 14: matrice di errore relativa alla classificazione SVM basata sull'immagine satellitare Sentinel-2 per l'area test 02; i valori di area sono espressi in m ² . SE = standard error; CI = confidence interval; PA = producer's accuracy; UA = user's accuracy.....	73
Tabella 15: matrice di errore relativa alla classificazione SVM basata sull'elaborazione della rete neurale VDSR per l'area test 02; i valori di area sono espressi in m ² . SE = standard error; CI = confidence interval; PA = producer's accuracy; UA = user's accuracy.....	74
Tabella 16: caratteristiche dimensionali delle immagini utilizzate per il test 03.....	75

Tabella 17: matrice di errore relativa alla classificazione SVM basata sull'immagine satellitare Sentinel-2 per l'area test 03; i valori di area sono espressi in m². SE = standard error; CI = confidence interval; PA = producer's accuracy; UA = user's accuracy..... 78

Tabella 18: matrice di errore relativa alla classificazione SVM basata sull'elaborazione della rete neurale VDSR per l'area test 03; i valori di area sono espressi in m². SE = standard error; CI = confidence interval; PA = producer's accuracy; UA = user's accuracy..... 79

1. Tecnologie di Remote Sensing

Le tecnologie di Remote Sensing trovano applicazione negli studi in cui è necessario ampliare le informazioni del risultato locale acquisibile a terra, permettendo di indagare una zona più ampia e contenendo l'impiego di tempo e risorse. Inoltre, attraverso l'utilizzo delle tecnologie di Remote Sensing è possibile acquisire dati relativi a zone caratterizzate da ambienti pericolosi, non raggiungibili da terra.

Ogni tecnologia di Remote Sensing ha vantaggi e svantaggi che interessano aspetti tecnologici, operativi ed economici. La determinazione della scelta ottimale non è universale, ma va valutata in base ai costi in funzione della scala di applicazione e alle specifiche caratteristiche dello studio.[1]

1.1. Piattaforme di Remote Sensing

La scelta della piattaforma più adeguata per studiare un determinato fenomeno dipende dalla risoluzione dei dati che permettono di descrivere i cambiamenti associati a quel processo, rendendo così possibile l'identificazione, la misura e la previsione dei cambiamenti.[2] La selezione è dunque strettamente dipendente dalla scala spaziale e dalle finalità dello studio.

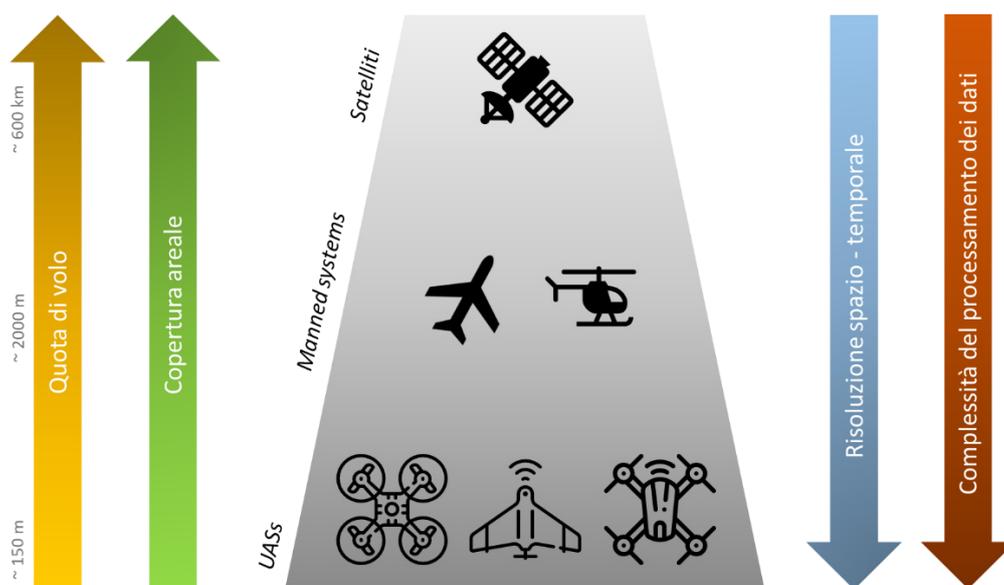


Figura 1: Variabilità delle caratteristiche al variare della tecnologia di Remote Sensing

Le acquisizioni satellitari permettono di ottenere mappe di elevata estensione areale allo stesso istante, ma con risoluzione bassa, compresa tra 10 m e 60 m per quanto riguarda le immagini acquisite dal satellite Sentinel-2, insufficiente per alcune applicazioni di dettaglio. Inoltre, sono inutilizzabili in presenza di fitta copertura nuvolosa e la data di acquisizione è fissa, rendendo questo dato non adeguato al monitoraggio nel tempo di specifiche fasi fenologiche molto ravvicinate.[1] Un aspetto di notevole importanza per il monitoraggio della vegetazione è la disponibilità di dati in diverse lunghezze d'onda, acquisiti tramite sensori multispettrali; per esempio, il sensore MSI montato sul satellite Sentinel-2 misura la radiazione riflessa dalle superfici con lunghezze d'onda compresa tra il visibile e l'infrarosso a onda corta (SWIR). Questo permette di osservare comportamenti non visibili tramite le immagini RGB a colori reali.

I rilevamenti aerei possono essere pianificati con maggiori flessibilità, ma l'organizzazione del rilievo è più complicata e ha un costo più elevato.[1]

Gli UAVs (Unmanned Aerial Vehicles), o droni, hanno le potenzialità di competere o affiancare le altre tipologie di Remote Sensing, come le acquisizioni da satellite o quelle da aircraft con pilota.

Un UAS (Unmanned Aerial System) è costituito da diversi componenti [2]:

- L'aircraft o UAV
- Un sistema di controllo a terra
- L'operatore che dirige il volo da terra, assistito da altri operatori che controllano l'area

Le informazioni riguardanti la posizione sono fornite dal sistema GNSS (Global Navigation and Satellite System) che trasmette regolarmente le misure di posizione campionate nelle tre dimensioni.

L'assetto del drone viene controllato attraverso l'unità IMU (Inertial Measurement Unit).

Le informazioni di posizione e assetto vengono utilizzate dall'autopilota per apportare gli aggiustamenti necessari per mantenere il veicolo lungo la traiettoria preimpostata dal piano di volo, contenente le specifiche riguardanti altitudine, distanza focale, orientazione della camera, overlap tra le immagini, velocità e direzione di volo.

La limitata altitudine di volo imposta dai regolamenti permette di acquisire immagini a risoluzione molto elevata, a scala centimetrica, ma richiede di acquisire un numero ingente di immagini al fine di coprire interamente l'area di interesse.

Alcuni vantaggi dell'utilizzo di UAV sono [1], [3], [4]:

- Costo ridotto, soprattutto per la categoria *small* (< 25 kg)
- Assenza di pilota a bordo
- Possibilità di cambiare l'altitudine di volo o di regolare la distanza focale
- Manovrabilità
- Possibilità di volare in condizioni di nuvolosità
- Flessibilità di integrazione di diversi sensori
- Elevata risoluzione spaziale

Questi aspetti permettono di ridurre i costi legati al veicolo e ai sensori, di acquisire immagini a risoluzione molto elevata, di migliorare e ottimizzare i tempi di acquisizione e programmare i voli di acquisizione in modo da analizzare le specifiche fasi del ciclo fenologico della vegetazione. [3]

Tra gli svantaggi e aspetti da migliorare è bene ricordare [1], [2], [4]:

- Payload limitato.
- Autonomia di volo ridotta.
- Elevata richiesta di data storage e di capacità di elaborazione dovuta al notevole numero di immagini acquisite.
- Vincoli meteorologici; gli UAVs risultano vulnerabili in presenza di forte pioggia o vento e questo può alterare la qualità del rilevamento. Anche le temperature elevate possono influire negativamente condizionando il funzionamento dei sensori.
- Limitazioni geometriche e radiometriche imposte dalle caratteristiche tecniche delle camere di consumo; sensore più sofisticati tendono ad essere troppo ingombranti o pesanti.
- Calibrazione inaffidabile per le camere di consumo; le ridotte dimensioni del sensore e distanza focale amplificano gli effetti di errori microscopici o di non allineamento. Tuttavia, è da considerare che esistono numerosi metodi per migliorare la qualità del prodotto finale.
- Distorsione dovuta ai rilievi; i voli a bassa quota sono maggiormente soggetti a questo genere di distorsione e la rimozione dell'errore locale risulta più complicata in presenza di alberi e costruzioni che nascondono alcune aree con conseguente mancanza di dati.
- Orario dell'acquisizione; si deve tenere in considerazione che le acquisizioni andrebbero effettuate con condizioni di tempo costanti e il più vicino possibile a mezzogiorno. Il rapido passaggio di nuvole e l'alternanza di zone in ombra e zone illuminate possono

portare a un errato esito della triangolazione aerea e a errori nella generazione del modello digitale di elevazione. Si possono avere anche altri problemi legati all'illuminazione come ad esempio la presenza di hotspots nelle immagini, effetto dovuto alla riflettanza bidirezionale che dipende dalla posizione relativa tra il sensore e il sole.

Tabella 1: confronto tra le principali caratteristiche delle tecnologie di Remote Sensing, evidenziandone vantaggi e svantaggi [1]

		UAV	Aircraft	Satellite
Acquisizione	Copertura areale	-	+	++
	Flessibilità	++	+	-
	Autonomia di volo	-	+	++
	Dipendenza dalla copertura nuvolosa	++	+	-
Processamento del dato grezzo	Payload	-	+	++
	Risoluzione	++	+	o
	Semplicità di realizzazione di mosaicatura e georeferenziazione	-	o	++
	Velocità di processamento	-	+	+

++ ottimo, + buono, o medio, - scarso

Matese et al. [1] nell'articolo "Intercomparison of UAV, Aircraft and Satellite Remote Sensing Platforms for Precision Viticulture" propongono una struttura logica con lo scopo di guidare nella scelta della piattaforma più adeguata in funzione della scala di analisi in applicazioni di agricoltura di precisione e in particolare di viticoltura di precisione. Il confronto viene effettuato sull'indice NDVI calcolato dalle immagini multispettrali. Lo studio utilizza strumenti statistici affiancati all'analisi dei costi; quest'ultima viene articolata analizzando differenti categorie in modo da tenere in considerazione tutte le spese legate all'utilizzo di una determinata piattaforma: costi di acquisizione, costi per la georeferenziazione e orto rettificazione, costi per il processamento delle immagini. I risultati mettono in evidenza la variabilità in funzione della scala: il costo per il satellite rimane costante poiché l'area coperta dall'acquisizione ha un'ampia estensione, mentre il costo per l'UAV aumenta notevolmente all'aumentare dell'area di studio

a causa del maggior numero di immagini necessario per coprire la zona, con conseguente maggior impiego di risorse per il processamento. L'aircraft riveste una situazione intermedia.

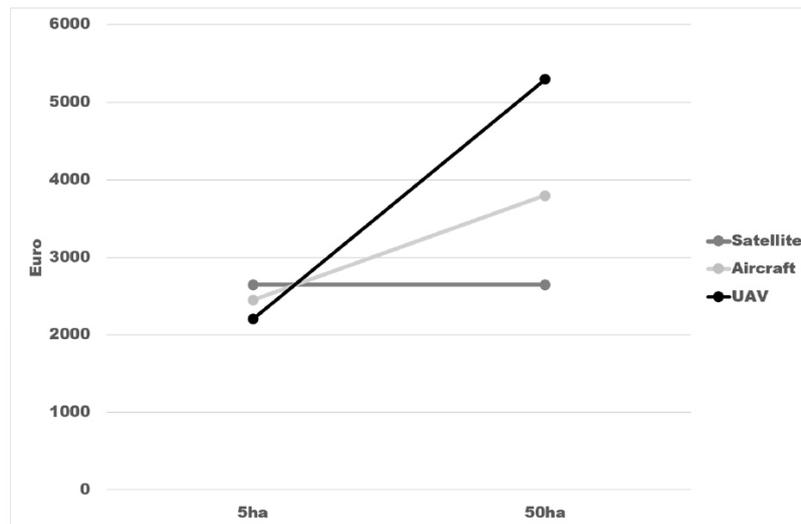


Figura 2: andamento dei costi all'aumentare dell'estensione dell'area di analisi per le diverse tecnologie di Remote Sensing [1]

Non è possibile definire una soglia universale di distinzione della convenienza tra le diverse tecnologie, ma in letteratura si ritrova una coerenza nell'identificare tale limite tra i 10 e i 20 ettari [4]. Per aree di estensione maggiore i costi di acquisizione, georeferenziazione e orto rettificazione hanno un impatto negativo sull'utilizzo dell'UAV.

Tuttavia, è necessario tenere in considerazione nella scelta della piattaforma da utilizzare non solo l'aspetto economico, ma anche il dettaglio dell'informazione spaziotemporale che si desidera raggiungere.

Un esempio è il caso in cui sia necessario monitorare un sistema naturale di notevole estensione, influenzato dalla forzante climatica, dalle caratteristiche fisiche, dalle pratiche di gestione e con stati della vegetazione che cambiano in un limitato intervallo temporale; per analizzare i cambiamenti di un tale sistema si rende necessario acquisire dati con una buona risoluzione spaziale e temporale.

In questo contesto si studiano metodi di elaborazione delle immagini per ottenere risultati intermedi a quelli delle diverse tecnologie di Remote Sensing, contenendo le spese in termini economici.

1.2. Sensori per il monitoraggio della vegetazione

Oltre alla scelta della piattaforma da utilizzare, è necessario valutare la tipologia di sensore da montare sul mezzo, sia esso drone, aereo o satellite. Esistono differenti tipologie di camere con le quali equipaggiare un satellite o un drone, quali ad esempio fotocamere, sensori radar, camere termiche, sensori multispettrali. Per lo scopo di monitoraggio della vegetazione risulta molto efficace l'analisi di immagini relative al comportamento delle superfici in diverse regioni dello spettro elettromagnetico; attraverso l'utilizzo di dati acquisiti in diverse lunghezze d'onda è possibile cogliere fenomeni e caratteristiche invisibili o poco rilevabili tramite immagini RGB a colori reali. Questi dati possono essere acquisiti tramite sensori multispettrali o sensori iperspettrali; entrambi acquisiscono immagini misurando la radiazione relativa a differenti lunghezze d'onda dello spettro elettromagnetico, ma cambia l'ampiezza dell'intervallo che delimita le diverse bande spettrali. Un sensore multispettrale acquisisce in genere un numero di bande compreso tra tre e dieci, mentre un sensore iperspettrale può acquisire centinaia di bande a intervalli molto più fitti.

La scelta è condizionata dallo scopo dell'analisi da compiere; nel caso del monitoraggio della vegetazione tramite il calcolo di indici multispettrali, la suddivisione in bande fornita dai sensori multispettrali risulta sufficiente e più adeguata. La suddivisione più ravvicinata delle bande ottenibile con i sensori iperspettrali può aiutare, invece, nel distinguere diverse specie vegetali in base al loro comportamento spettrale.

Le immagini ottenute e loro successive elaborazioni forniscono informazioni utili per valutare lo stato di attività della vegetazione, la presenza di malattie, la carenza di nutrienti, la variabilità del contenuto di umidità nel suolo... Queste informazioni possono aiutare nella previsione della produttività e del rendimento di una coltivazione, supportando la fase di dosaggio di fertilizzanti o altre sostanze. Le caratteristiche spettrali possono inoltre essere utilizzate per riconoscere determinate specie di vegetazione.

Questa tecnologia permette di acquisire immagini aggiornate delle aree monitorate, fornendo supporto nell'individuazione del cambiamento dello stato di salute della vegetazione in base all'evoluzione stagionale.[7]

Altri campi di applicazione dei sensori multispettrali sono: la geologia, per il riconoscimento delle tipologie di suolo e la caratterizzazione del materiale nel caso di frane o alluvioni; il campo industriale, per il monitoraggio o l'identificazione di impianti, discariche e scarichi; il

monitoraggio ambientale, per l'individuazione del rilascio di inquinanti o la caratterizzazione chimico-fisica dei terreni.

Poiché i sensori multispettrali sono disponibili, sebbene con alcune differenze, sia per essere attrezzati su drone, sia per essere montati su satellite, le analogie dei sensori consentono di disporre di immagini confrontabili in modo da integrare le immagini satellitari con mappe a risoluzione più elevata così come avere dati che offrono un'ampia copertura con frequenza costante da confrontare per validare o estendere il dato acquisito da terra. Questa corrispondenza viene sfruttata nel presente studio per applicare la rete neurale VDSR non solo a immagini RGB a colori reali, ma anche a composizioni multispettrali.

Nei successivi capitoli si presentano perciò i sensori multispettrali sia per satellite, sia per drone; il campo di applicazione principale delle camere multispettrali per drone presentate è l'agricoltura, scenario su cui si basano i test dello studio. Si mostra in seguito un esempio di camera iperspettrale per drone per rendere più chiaro il confronto tra le due tipologie.

2. Sensori per satellite

Oggi giorno sono numerosi i programmi che si occupano di acquisizione di dati tramite satellite, ognuno con uno specifico obiettivo e conseguentemente con diverse caratteristiche in termini di sensori montati a bordo, tempo di rivoluzione, risoluzione spaziale, formato del dato scaricabile, disponibilità del dato per utenti esterni al programma.

Un dato particolarmente accessibile è fornito dai satelliti Sentinel, poichè distribuito ad accesso libero sul portale ESA – Copernicus Open Access Hub [5]. La gratuità del dato rende le immagini acquisite dai satelliti Sentinel un buon punto di partenza dal quale sviluppare le analisi.

Le missioni Sentinel fanno parte del progetto europeo Copernicus dell’Agenzia Spaziale Europea (ESA). [6] La Tabella 2 di seguito riassume il quadro generale in cui si inseriscono i diversi programmi, associando ad ognuno l’obiettivo della missione, il sensore montato, la copertura spaziale e il tempo di rivoluzione, la risoluzione spaziale e i principali finanziatori della missione.

Ai fini del monitoraggio della vegetazione e del confronto con i dati acquisiti da sensori multispettrali montati su drone, la missione più adatta è la Sentinel-2, equipaggiata anch’essa con sensore multispettrale.

Il satellite è attrezzato con un sensore multispettrale MSI che segue la modalità push-broom e acquisisce in 13 bande spettrali con differenti risoluzioni spaziali. La risoluzione radiometrica è di 12 bit e permette dunque di percepire tra 0 e 4095 valori differenti di intensità di luce.

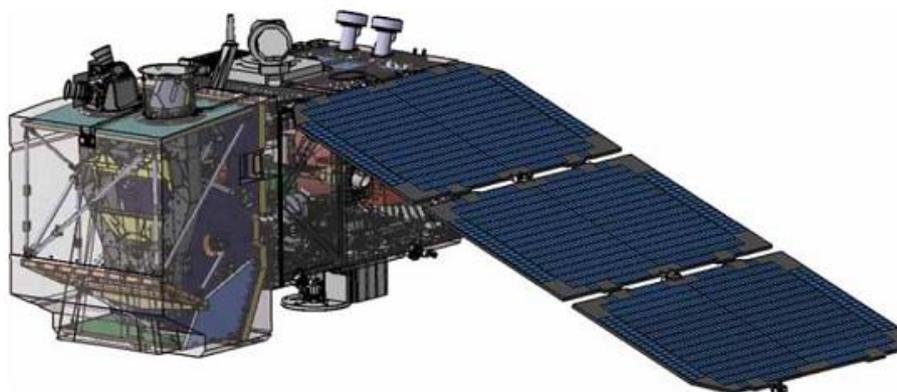


Figura 3: satellite Sentinel-2 [6]

Tabella 2: panoramica sulle missioni Sentinel [6]

SATELLITE	OBIETTIVO	SENSORE	COPERTURA E TEMPO DI RIVOLUZIONE	RISOLUZIONE SPAZIALE	FINANZIATORI
Sentinel-1	Osservazione della Terra	SAR (Synthetic Aperture Radar) in banda C	Copertura globale, frequenza di 6 giorni	Tra 5 e 40 m in base alla modalità di acquisizione	ESA
Sentinel-2	Monitoraggio della variabilità delle condizioni della superficie della Terra	Multispettrale (MSI)	Copertura globale, frequenza di 5 giorni	10 m, 20 m, 60 m in base alla banda analizzata	ESA
Sentinel-3	Misura della topografia della superficie del mare, della temperatura del mare e della terra in supporto dei sistemi di monitoraggio e di previsione dell'ambiente e dell'oceano	Spettrometro (OLCI), radiometro per la temperatura (SLSTR), altimetro SAR (SRAL)	Copertura globale, frequenza inferiore a 1 giorno (SLSTR) o a 2 giorni (OLCI).	500 m o 1 km in base allo strumento utilizzato	ESA + EUMETSAT
Sentinel-4		Spettrometro (UVN)	Copertura europea, frequenza di 1 ora	8 km	ESA
Sentinel-5	Monitoraggio di gas e aerosol traccianti della qualità dell'aria	Spettrometro Low Earth Orbiting (LEO)	Copertura globale, frequenza di 1 giorno	50 km o 7.5 km in base alla banda utilizzata	+ CAMS (Copernicus Atmospheric Monitoring Service)
Sentinel-5P (precursor)				7 km	

La Tabella 3 mostra le bande acquisite, associate alla risoluzione spaziale, per entrambi i satelliti della missione Sentinel-2; il satellite Sentinel-2A è stato il primo ad essere lanciato in orbita nel giugno 2015, mentre il Sentinel-2B ha completato la costellazione nel marzo 2017.

Tabella 3: lunghezze d'onda e ampiezza delle bande con rispettiva risoluzione spaziale per i satelliti Sentinel-2

Spatial Resolution (m)	Band Number	S2A		S2B	
		Central Wavelength (nm)	Bandwidth (nm)	Central Wavelength (nm)	Bandwidth (nm)
10	2 - Blue	492.4	66	492.1	66
	3 - Green	559.8	36	559.0	36
	4 - Red	664.6	31	664.9	31
	8 - NIR	832.8	106	832.9	106
20	5 - Vegetation Red Edge	704.1	15	703.8	16
	6- Vegetation Red Edge	740.5	15	739.1	15
	7- Vegetation Red Edge	782.8	20	779.7	20
	8a- Vegetation Red Edge	864.7	21	864.0	22
	11- SWIR	1613.7	91	1610.4	94
	12 - SWIR	2202.4	175	2185.7	185
60	1 - Coastal aerosol	442.7	21	442.2	21
	9 - Water vapour	945.1	20	943.2	21
	10 - Swir - Cirrus	1373.5	31	1376.9	30

3. Camere multispettrali per drone

Un sensore montato su drone permette di ottenere approfondite informazioni sull'ambiente sottostante in base al contrasto spaziale e alla distribuzione spettrale della luce che lo colpisce.[8] Tuttavia è necessario riuscire a combinare la qualità del dato che si può acquisire con i requisiti di dimensione e peso adeguati per poter montare il sensore su un UAV. Il problema del peso e dell'ingombro interessa maggiormente i sensori multispettrali e termici, ma oggi sono disponibili diverse soluzioni commerciali. [9]

Di seguito vengono presentate diverse soluzioni attualmente presenti sul mercato, che si differenziano per risoluzione, numero di bande acquisite, intervallo spettrale, peso e prezzo.

3.1. SlantRange 4P



Figura 4: sensore multispettrale SlantRange 4P+ integrato con sensore di illuminazione e sistema di navigazione [10]

Figura 5: sensore multispettrale SlantRange 4P+ [10]

La camera SlantRange 4P è una tecnologia per digitalizzare il fenotipo di coltivazioni o specie vegetali tramite acquisizione di dati per via aerea.

Il sensore combina risoluzione spaziale e risoluzione spettrale diversificata in varie bande. In questo modo è possibile indagare le forzanti principali che influiscono sulla crescita e sulla salute della vegetazione oltre a disporre di immagini a colori reali RGB.

Il sensore multispettrale è accompagnato da un sensore di illuminazione ambientale in modo da garantire l'accuratezza dell'acquisizione e delle successive elaborazioni al variare delle condizioni di illuminazione della superficie in esame, permettendo così di calibrare il segnale misurato.

Lo strumento dispone di un sistema di navigazione integrato composto da GPS dual-antenna RTK, distanziometro LIDAR e filtro Kalman esteso EKF che misura la posizione del sensore rispetto al campo, permettendo di avere una scala di misura precisa.

Per poter utilizzare i dati grezzi è necessario un pre-processamento, realizzabile tramite il pacchetto *SlantView*, che permette di isolare il segnale proveniente dalla coltivazione da quello di background di suolo, erba o di altri rumori residui, in modo da ottenere risultati più accurati. Inoltre, è possibile elaborare misure caratteristiche dello stato di sviluppo della vegetazione nella stagione di crescita.

SlantView dispone di diversi layers che permettono di costruire un quadro completo dell'evoluzione della vegetazione analizzata:

- Vegetation Fraction
Suddivisione della chioma della vegetazione dal suolo nudo o da altri residui, in modo da individuare le differenze di copertura sull'area di interesse;
- Quad-Band Vegetation Stress
Combinazione di quattro bande spettrali comprese tra il visibile e l'infrarosso vicino; permette di ottenere una misura più accurata e anticipata dello stress della vegetazione rispetto all'indice NDVI che considera solo due bande;
- Yield Potential
Combinazione di diversi fattori per definire potenziali prestazioni future;
- Chlorophyll Index
Stima del contenuto relativo di clorofilla in una coltivazione;
- Multiple NDVI
Indice NDVI standard, normalizzato per le bande verde, rosso, rosso esterno.

Gli algoritmi integrati in *SlantView* permettono di personalizzare ulteriori layers attraverso il signal training e le classificazioni per analisi specifiche.

Inoltre, sono messe a disposizione le seguenti immagini senza compressione:

- Full color imagery
- Quad-band vegetation stress
- Green, Red or Red Edge NDVI
- Reflectance (per ogni separata banda spettrale)

I dati acquisiti sono processabili direttamente in campo e in tempi rapidi, senza bisogno di connessione. Le immagini sono esportabili con i relativi metadati nei formati GeoTIFF (.tiff), Shapefile (.shp), Google Earth (.kml, .kmz).

Per maggiori approfondimenti riguardo alle specifiche tecniche si rimanda alla scheda tecnica in allegato "Schede tecniche camere multispettrali per drone".

3.2. MAPIR Survey3



Figura 6: camera multispettrale MAPIR Survey 3 [11]

Figura 7: ampiezza dell'inquadratura in base al tipo di lente utilizzata [11]

Survey3 è una camera multispettrale compatta ed economica, acquisisce su tre bande, associate in diverse composizioni.

Esistono due versioni: la versione Survey3W dispone di una lente grandangolare, mentre la versione Survey 3N monta una lente ad angolo stretto e permette di ottenere una risoluzione al suolo due volte superiore. Entrambe le lenti garantiscono una ridotta distorsione.

Le camere Survey3 sono accompagnate da un ricevitore GPS esterno che fornisce istantaneamente la posizione di ogni immagine acquisita.

Inoltre, è possibile inviare un segnale PWM, modulazione di impulso, per acquisire l'immagine, ma anche per inserire la modalità USB Media Transfer. Questo permette di avere la camera sempre connessa a un computer e di inserire e disinserire la scheda SD.

Le camere vengono attrezzate con uno dei seguenti filtri spettrali:

- Filtro multispettrale OCN: Orange + Cyan + NIR
- Filtro multispettrale RGN: Red + Green + NIR
- Filtro multispettrale NGB: NIR + Green + Blue
- Filtro multispettrale RGB: visibile a colori reali
- Filtro RE: RedEdge
- Filtro NIR: Near Infrared

La combinazione più indicata ai fini di indagare lo stato di salute della vegetazione risulta essere l'utilizzo della versione Survey3W con il filtro OCN che permette di calcolare indici multispettrali di vegetazione come l'indice NDVI. Utilizzando il filtro OCN viene incrementato il contrasto all'interno della vegetazione e viene ridotto il rumore proveniente dal suolo. In presenza di una vegetazione folta, con ridotta superficie di suolo nudo, è consigliato l'utilizzo del filtro RGN.

Le immagini acquisite possono poi essere trattate attraverso il software *MAPIR Camera Control (MCC)* o su altri software analoghi come *Pix4D*, *Agisoft Metashape*, *Drone Deploy*, *Agribotix*, *MapsMadeEasy*, *Simactive*. Queste applicazioni permettono di eseguire calcoli sulle immagini raster, elaborando indici rappresentativi di specifiche proprietà della vegetazione.

Per maggiori approfondimenti riguardo alle specifiche tecniche si rimanda alla scheda tecnica in allegato "Schede tecniche camere multispettrali per drone".

3.3. Parrot SEQUOIA+



Figura 8: camera Parrot SEQUOIA+, sensore multispettrale e sensore di luminosità [12]



Figura 9: sensore multispettrale con indicazione della posizione delle diverse bande [12]

Parrot SEQUOIA+ è una camera dotata di sensore multispettrale e sensore di luminosità con l'obiettivo di studiare lo stato di vitalità della vegetazione misurando la quantità di luce assorbita dalle piante e poi riflessa. Il sensore multispettrale acquisisce in quattro bande: verde, rosso e due bande dell'infrarosso. Il sensore di luminosità è attrezzato con le stesse quattro bande.

Inoltre, la camera è integrata con un sensore GPS che permette di conoscere altitudine, velocità di volo e posizione in modo da rendere ottimale la fase di acquisizione delle immagini e il successivo trattamento.

Le dimensioni e il peso sono ridotti, questo rende la camera adatta all'utilizzo su un'ampia varietà di droni.

I dati vengono trasmessi tramite connessione WiFi o USB. Il trattamento dei dati acquisiti si può effettuare attraverso il software *Pix4D*, integrato con Sequoia, che effettua una calibrazione radiometrica completa consentendo di ottenere misure precise di riflettanza senza l'utilizzo di pannelli di calibrazione ed elabora mappe relative a indici spettrali e ortomosaici.

Per maggiori approfondimenti riguardo alle specifiche tecniche si rimanda alla scheda tecnica in allegato "Schede tecniche camere multispettrali per drone".

3.4. MAIA



Figura 10: sensore multispettrale MAIA WV [13]

MAIA è una camera multispettrale che consente l'acquisizione simultanea di immagini ad alta risoluzione in diverse lunghezze d'onda tra il visibile e l'infrarosso vicino.

La versione MAIA WV permette di acquisire negli stessi intervalli di lunghezza d'onda del satellite DigitalGlobe WorldView-2. La camera è composta da 1 sensore RGB e 8 sensori monocromatici dotati di filtro passa-banda per un totale di 9 sensori che acquisiscono lunghezze d'onda tra i 390 nm (VIS) e i 950 nm (NIR).

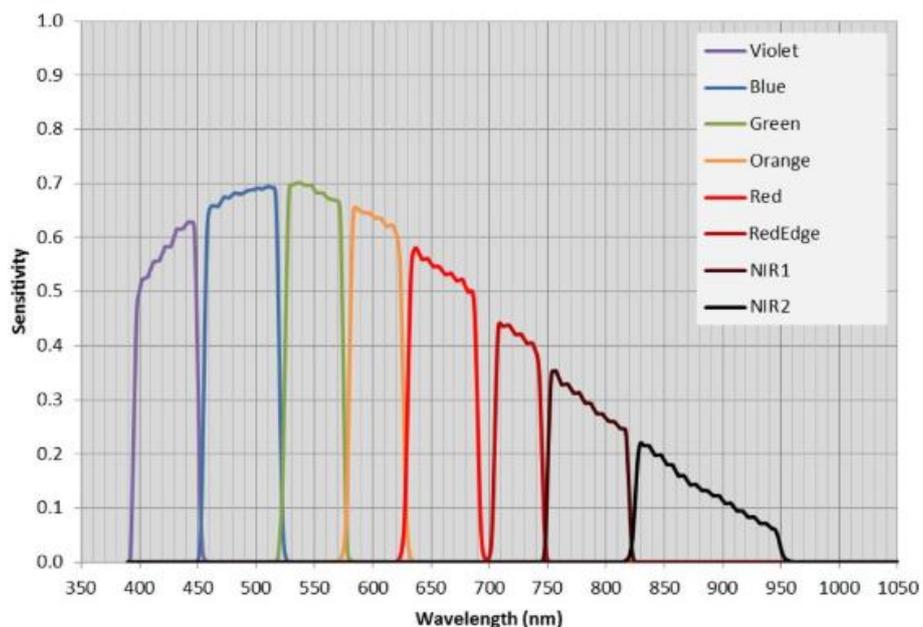


Figura 11: spettro con indicazione degli intervalli di lunghezza d'onda che è possibile acquisire con i vari filtri passa-banda per la camera MAIA WV [13]

Tabella 4: intervalli di lunghezza d'onda su cui si basano i filtri passa-banda per la camera MAIA WV [13]

Sensor	Start WL (nm)	Stop WL (nm)	CWL (nm)	FWHM (nm)	Color
S1	395	450	422.5	55	PURPLE
S2	455	520	487.5	65	BLUE
S3	525	575	550	50	GREEN
S4	580	625	602.5	45	ORANGE
S5	630	690	660	60	RED
S6	705	745	725	40	RED EDGE
S7	750	820	785	70	NIR 1
S8	825	950	887.5	125	NIR 2
S9	-	-	-	-	RGB

La versione MAIA S2 è allestita con gli stessi intervalli di lunghezze d'onda del satellite Sentinel-2, missione europea facente parte del programma Copernicus dell'ESA per l'osservazione della Terra. I nove sensori monocromatici ricevono segnali in lunghezze d'onda tra i 433 nm (VIS) e i 875 nm (NIR).

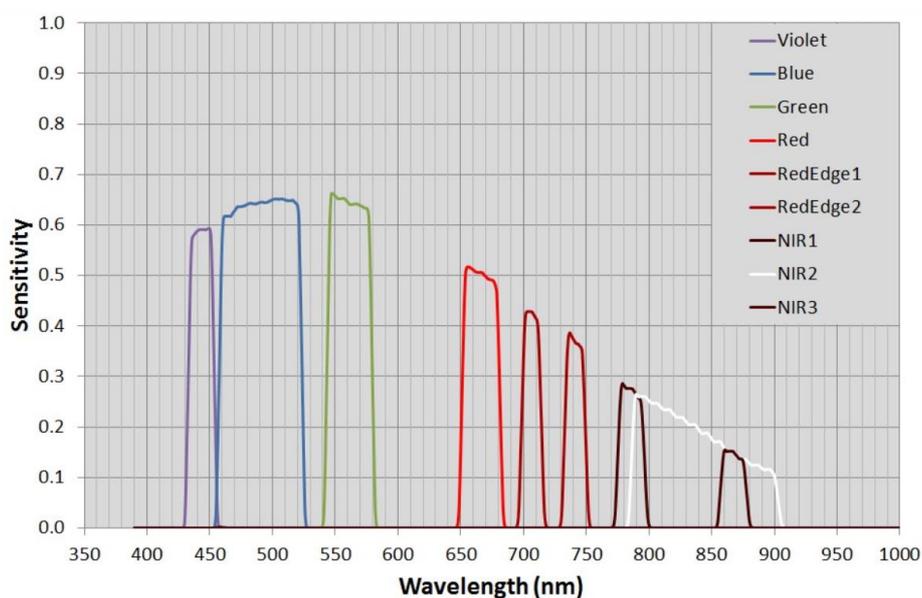


Figura 12: spettro con indicazione degli intervalli di lunghezza d'onda che è possibile acquisire con i vari filtri passa-banda per la camera MAIA S2 [13]

Tabella 5: intervalli di lunghezza d'onda su cui si basano i filtri passa-banda per la camera MAIA S2 [13]

Sensor	Start WL (nm)	Stop WL (nm)	CWL (nm)	FWHM (nm)	Color
S1	433	453	443	20	VIOLET
S2	457.5	522.5	490	65	BLUE
S3	542.5	577.5	560	35	GREEN
S4	650	680	665	30	RED
S5	697.5	712.5	705	15	RED EDGE 1
S6	732.5	747.5	740	15	RED EDGE 2
S7	773	793	783	20	NIR 1
S8	784.5	899.5	842	115	NIR 2
S9	855	875	865	20	NIR 3

L'interfaccia tra la camera e l'operatore è possibile via WiFi o via porta GigaEthernet.

Inoltre, la camera MAIA può essere collegata con altri dispositivi (ricevitore GNSS, trasmettitore e ricevitore radio, sensore di illuminazione) in modo da integrare i dati acquisiti con informazioni utili al loro corretto trattamento.

La camera è associata a un proprio software, *MAIA – MultiCamStitcher Pro*, che permette di effettuare la correzione geometrica, la coregistrazione e la correzione radiometrica dei dati grezzi. Inoltre, questa applicazione consente di effettuare elaborazioni come il calcolo di indici spettrali e combinazioni di bande.

Per maggiori approfondimenti riguardo alle specifiche tecniche si rimanda alla scheda tecnica in allegato "Schede tecniche camere multispettrali per drone".

3.5. Dji Phantom 4 Multispectral



Figura 13: drone dji Phantom 4 Multispectral [14]



Figura 14: camera multispettrale integrata dji Phantom 4 Multispectral [14]

Dji Phantom 4 Multispectral è un drone progettato per scopi di agricoltura e monitoraggio ambientale ad alta precisione, a scala centimetrica, integrato con camera multispettrale che acquisisce immagini RGB e in cinque bande multispettrali: blu, verde, rosso, Red-Edge e infrarosso vicino:

- Blu (B): 450 nm ± 16 nm
- Verde (G): 560 nm ± 16 nm
- Rosso (R): 650 nm ± 16 nm
- Red-Edge (RE): 730 nm ± 16 nm
- Vicino infrarosso (NIR): 840 nm ± 26 nm

Presenta inoltre un sensore di luce integrato che permette di rielaborare i dati al variare delle condizioni di illuminazione in modo da ottenere informazioni più accurate. L'accuratezza del volo è migliorata con il sistema integrato RTK e le posizioni delle immagini vengono compensate calibrando le posizioni relative al centro di ognuno dei sei sensori CMOS delle fotocamere e al centro di fase dell'antenna D-RTK integrata. Il posizionamento è effettuato tramite modulo GNSS ad alta sensibilità e a frequenza singola oppure con RTK GNSS ad alta precisione multisistema e multifrequenza. L'area massima operativa risulta di circa 0,63 km² per un volo singolo a un'altitudine di 180 m, tenendo conto dell'autonomia di volo di circa 27 minuti.

Per maggiori approfondimenti riguardo alle specifiche tecniche si rimanda alla scheda tecnica in allegato "Schede tecniche camere multispettrali per drone".

3.6. Sensori a confronto

Di seguito si riporta il confronto tra le principali caratteristiche spettrali di alcuni sensori multispettrali per drone e quelle del sensore multispettrale del satellite Sentinel-2. Inoltre, si paragonano le caratteristiche geometriche ed economiche dei sensori per drone precedentemente presentati.

Tabella 6: Confronto delle caratteristiche spettrali delle camere multispettrali per drone e del sensore MSI del satellite Sentinel-2

	SlantRange 4P+	MAPIR Survey3W	Parrot SEQUOIA+	MAIA	Dji Phantom 4 Multispectral	Sentinel 2
Intervallo spettrale (nm)	410 – 950	375 – 850	550 – 790	390 – 950 (WV) 433 – 875 (S2)	450 – 840	459.4 – 2289.9
Numero di bande spettrali	6	3 (6 diverse combinazioni)	4	9	5	13
Sensore di luminosità	si	no	si	si	si	si
Risoluzione spaziale (GSD)	2.2 cm/px at 100 m AGL	5.5 cm/px at 120 m AGL	13 cm/px at 120 m AGL	3 cm/px at 75 m AGL	5.29 cm/px at 100 m AGL	10, 20, 60 m/px
Risoluzione radiometrica (bit)	8 – 12			8 – 12		12

Tabella 7: Confronto delle caratteristiche geometriche ed economiche delle camere multispettrali per drone; la conversione da dollaro a euro è posta pari a 0.85

	SlantRange 4P+	MAPIR Survey3	Parrot SEQUOIA+	MAIA	Dji Phantom 4 Multispectral (drone)
Dimensioni	146 x 69 x 57 mm	59 x 41.5 x 36mm	59 x 41 x 28 mm	129 x 99 x 47 mm	289.5 x 289.5 x 196 mm
Peso	350 g	76 g	72 g (camera) + 35 g (sensore luminosità)	420 g	1 487 g
Costo	4 870 €	340 €	3 840 €	13 500 € (VW) 15 200 € (S2)	5 500 €

4. Camere iperspettrali per drone

I sensori iperspettrali trovano applicazione in numerosi campi grazie alla disponibilità di numerose bande spettrali a intervalli ristretti. Alcuni esempi sono l'agricoltura, la silvicoltura, la ricerca d'acqua, la medicina, il campo industriale. Individuate le bande caratteristiche dell'oggetto di studio, è possibile identificare le aree con caratteristiche spettrali differenti da quelle attese. Grazie alla più fitta separazione delle bande, queste camere permettono una più accurata differenziazione delle tipologie e specie di vegetazione rispetto alle camere che acquisiscono in bande spettrali più ampie.[15]

Di seguito si riporta un esempio di camera iperspettrale presente in commercio, in modo da poter effettuare un paragone concreto con le camere multispettrali precedentemente presentate.

4.1. Senop HSC-2



Figura 15: camera iperspettrale Senop HSC-2 [16]

Senop HSC-2 è una camera iperspettrale istantanea basata su frame, sensibile all'intervallo spettrale tra i 400 nm e i 1000 nm, che permette all'utente di acquisire sino a 1000 bande. Tutti i pixel sono associati a valori reali misurati, senza l'utilizzo di interpolazione, con risoluzione di 1 Mpixels.

Il sensore iperspettrale è integrato con sensore di posizione e IMU per una corretta elaborazione delle immagini ad alta risoluzione. Inoltre, è possibile connettere un sensore di illuminazione in modo da registrare i cambiamenti delle condizioni di luce e utilizzare questa informazione per il processamento delle immagini.

I dati acquisiti con questa camera vengono trattati con il software *Senop Hyperspectral Imaging PC*; tuttavia sono disponibili anche librerie apposite per l'elaborazione di questi dati con altri software.

In Tabella 8 si riportano le principali caratteristiche spettrali, geometriche ed economiche precedentemente illustrate per i sensori multispettrali.

Per maggiori approfondimenti riguardo alle specifiche tecniche si rimanda alla scheda tecnica in allegato "Scheda tecnica camera iperspettrale per drone".

Tabella 8: caratteristiche spettrali, geometriche ed economiche della camera iperspettrale Senop HSC-2

Intervallo spettrale (nm)	400-1000 nm
Numero di bande spettrali	Sino a 1000
Sensore di luminosità	Disponibile a parte
Risoluzione spaziale (GSD)	o.d.g. cm
Risoluzione radiometrica (bit)	10 – 12 bit
Dimensioni	199.5 x 130.9 x 97.2 mm
Peso	986 g
Costo	40 000 €

5. Calibrazione radiometrica

Affinché il dato acquisito sia attendibile e non ci siano letture interpretate erroneamente a causa di differenti condizioni di illuminazione, è necessario calibrare il segnale in modo da allineare a un valore standard i valori dei pixel ottenuti in differenti momenti di acquisizione in modo che siano paragonabili.

Per rendere le acquisizioni multispettrali comparabili in modo quantitativo e fedeli al dato reale di riflettività delle superfici, è necessario convertire i valori di Digital Number (DN) in valori di riflettività attraverso la calibrazione radiometrica e le correzioni atmosferiche. [4]

Per quanto riguarda le immagini satellitari, diversi software sono implementati con procedure standard di calibrazione radiometrica. I satelliti sono attrezzati con sistemi avanzati in grado di registrare informazioni relative alle condizioni meteorologiche e di illuminazione e memorizzarle nel metadato relativo a ciascuna immagine che viene poi utilizzato per la calibrazione. [26]

Nell'ambito dei rilievi con drone, invece, la calibrazione radiometrica risulta più complicata da implementare poiché ogni singola immagine richiede specifiche correzioni dovute al ridotto campo di vista e alle non uniformi condizioni di luce durante la campagna di acquisizione. [26] Anche in questo caso l'obiettivo della campagna di misura è l'acquisizione della percentuale di riflettanza proveniente da una superficie; è dunque importante regolare le impostazioni della camera in modo che non si raggiunga il valore massimo per evitare la saturazione dell'immagine e la conseguente perdita di informazioni. Per rendere univoca la lettura della percentuale registrata si utilizzano i pannelli di calibrazione e alcune camere più avanzate sono dotate di sensore di illuminazione. I pannelli di calibrazione sono superfici con proprietà lambertiane con valori di riflettanza noti che vengono inquadrati al momento della campagna di misura, da usare come riferimento in quelle determinate condizioni ambientali; altrimenti si possono effettuare per ogni campagna di misura rilevamenti in campo con spettrometro della riflettanza di alcuni elementi target. Queste informazioni permettono di costruire una relazione lineare tra i valori di DN dell'immagine e i valori di riflettanza delle superfici, utilizzabile per calibrare l'immagine [26], [27].

In Figura 16 si riporta un esempio delle firme spettrali relative a quattro diversi targets.

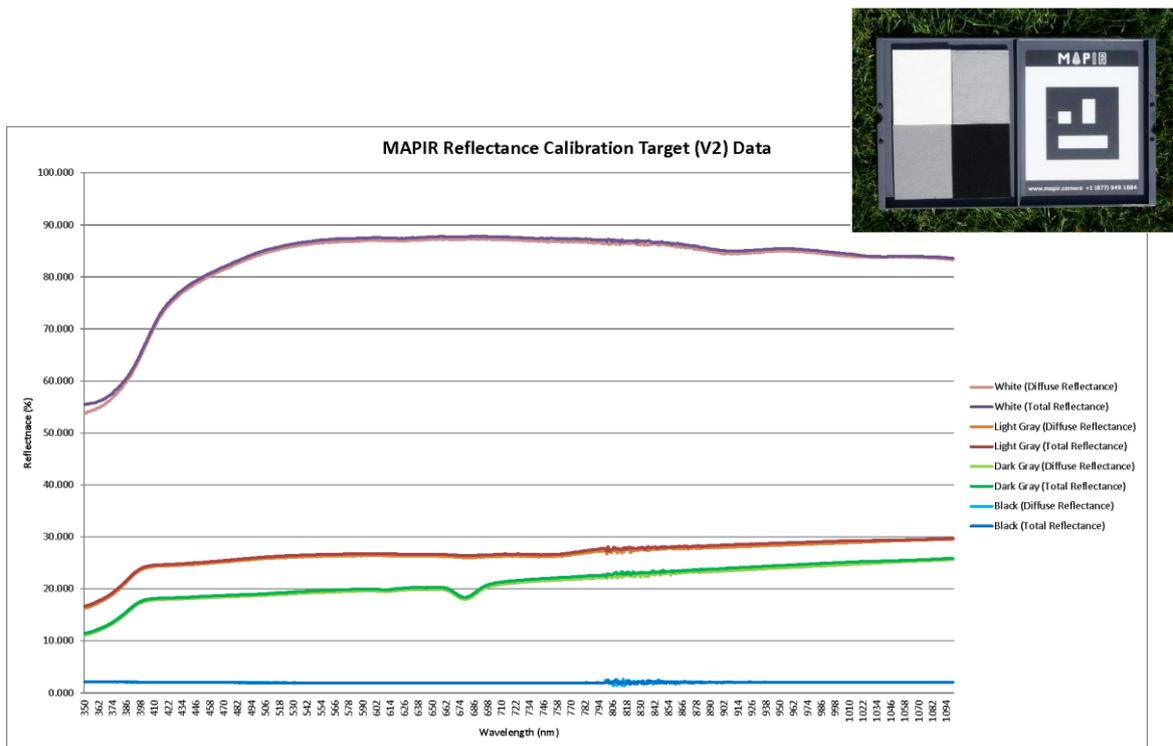


Figura 16: firme spettrali di pannelli di calibrazione MAPIR [27]

Al fine di studiare l'applicabilità della rete neurale VDSR, illustrata nel capitolo successivo, alle immagini satellitari utilizzando come base per il training le immagini da drone, non viene effettuato questo processamento. In questa fase dello studio si concentra l'attenzione sulla fattibilità del metodo, cercando comunque di utilizzare immagini satellitari e da drone acquisite in condizioni meteorologiche analoghe, il più possibile relative allo stesso momento di acquisizione.

6. Single Image Super-Resolution (SISR) Using Deep Learning

La super-risoluzione è un processo per ottenere immagini ad alta risoluzione a partire da immagini a bassa risoluzione. Questa ricostruzione dell'immagine risulta di notevole interesse nel campo del Remote Sensing per compensare i limiti dovuti a una risoluzione spaziale non sempre adeguatamente dettagliata.

La Single Image Super-Resolution (SIRS), in particolare, mira a costruire un'immagine ad alta risoluzione a partire da una singola immagine a bassa risoluzione. Gli aspetti più problematici di questa procedura risiedono nella mancanza di componente ad alta frequenza nelle immagini a bassa risoluzione, limitando così la qualità dell'immagine ad alta risoluzione, e nella possibilità di ottenere diverse possibili immagini a partire da una singola immagine a bassa risoluzione in ingresso. [17]

Un approccio base per ottenere il miglioramento della risoluzione di un'immagine è l'interpolazione, ma esistono altre strategie più articolate che si pongono lo stesso obiettivo. In questo studio si analizza l'efficacia dell'utilizzo del Deep Learning per lo scopo della Single Image Super-Resolution.

Il Deep Learning è un ramo del Machine Learning con lo scopo di insegnare al computer il processo di conoscenza a partire dall'esperienza; gli algoritmi mirano all'estrazione di informazioni direttamente dai dati a disposizione, senza basarsi su equazioni o modelli. Alcune delle applicazioni più diffuse sono legate al riconoscimento e classificazione di immagini, per esempio per il riconoscimento facciale o per le tecnologie di assistenza alla guida. Per fare questo vengono utilizzate le reti neurali che, attraverso diversi elementi che agiscono in parallelo, combinano più livelli di elaborazione non lineari. [18]

In letteratura sono diffusi gli studi riguardanti l'utilizzo di reti neurali per il processamento al fine del miglioramento della risoluzione di fotografie a colori, ossia con i tre canali RGB, ma poche ricerche sono state compiute concentrandosi su immagini con un numero maggiore di bande oppure immagini satellitari. Gli algoritmi infatti sono generalmente testati su immagini RGB con profondità di colore pari a 8 bit/pixel, acquisite con una distanza tra la camera e il soggetto di alcuni metri. L'applicazione di questi metodi con immagini satellitari necessita di particolari attenzioni da tenere in considerazione: range di acquisizione in un intervallo di lunghezze d'onda

più ampio corrispondente a un maggior numero di bande; variazione delle caratteristiche della copertura del suolo per immagini di interesse globale; notevole quantità di dati raccolti per ogni acquisizione dovuta alla notevole distanza tra il sensore e la scena ripresa; profondità di campionamento delle immagini di 12 bit/pixel (Sentinel-2). [19]

6.1. Very-Deep Super-Resolution (VDSR)

L'algoritmo di deep learning VDSR (Very-Deep Super-Resolution) è una delle possibili tecniche utilizzabili per effettuare il processo SISR. Inizialmente è necessario il training della rete neurale per poi utilizzare la rete VDSR per ottenere un'immagine ad alta risoluzione a partire da una singola immagine a bassa risoluzione.

VDSR è una rete neurale convoluzionale CNN (Convolutional Neural Network) con lo scopo di relazionare immagini ad alta e bassa risoluzione che differiscono prevalentemente per il dettaglio nelle alte frequenze. La procedura si basa sulla determinazione dei residui tra le due immagini, ossia un'immagine di riferimento ad alta risoluzione e una a bassa risoluzione scalata per portarla alla stessa dimensione dell'immagine di riferimento tramite interpolazione bicubica. L'immagine dei residui contiene le informazioni relative alla componente in alta frequenza.

Nella rete VDSR i residui sono determinati sulla luminanza (Y):

$$Y_{residual} = Y_{High Res} - Y_{Low Res} \quad (eq 1)$$

Una volta che la rete VDSR impara a calcolare l'immagine dei residui, è possibile ricostruire un'immagine ad alta risoluzione sommando i residui stimati all'immagine scalata a bassa risoluzione. [17] L'algoritmo viene perciò applicato solo al canale della luminanza (Y), mentre i canali della cromaticità (Cb e Cr) sono aumentati di scala tramite interpolazione bicubica. C. Dong et al. hanno sperimentato che l'approccio con trasformazione nello spazio YCbCr e applicazione della rete neurale al solo canale della luminanza e l'approccio che interessa i tre canali nello spazio RGB permettono di ottenere risultati migliori rispetto ad allenare la rete con tutti e tre i canali YCbCr o con un pre-training su uno di questi canali. [20]

J. Kim et al. hanno dimostrato un miglioramento dell'accuratezza e una più efficace estrazione delle informazioni da ampie regioni dell'immagine aumentando la profondità della rete neurale convoluzionale, ossia incrementando il numero di layers, e applicando filtri di ridotte dimensioni

in sequenza molte volte. Una rete più profonda consente di ottenere un campo ricettivo più ampio, essendo quest'ultimo proporzionale al numero di livelli convoluzionali e calcolabile come $(2D + 1) \times (2D + 1)$, e quindi di sfruttare una maggior quantità di informazioni per dedurre le componenti di alta frequenza. [21]

L'aumento della profondità della rete influenza negativamente la velocità di convergenza; per compensare questo aspetto si preferisce allenare la rete sui soli residui e si utilizza un valore del tasso di apprendimento più elevato rispetto ad altre CNN. [21]

Per i test presentati nei capitoli seguenti, è stata utilizzata la rete VDSR disponibile sul portale del software Matlab e supportata da diversi studi. [17], [21], [22], [23]

I tre componenti necessari per definire una rete neurale sono:

- Layers della rete
- Dati di training
- Opzioni di training dell'algoritmo

L'architettura della rete è determinata in base a tipologia, dimensione e ordine dei layers. Ogni layer possiede differenti parametri chiamati pesi, determinati dal training della rete con dati noti, che definiscono il comportamento di quello strato al passaggio dei dati.

Il corpo centrale della rete neurale convoluzionale VDSR è composto da due tipologie di layers: layers convoluzionali e layers ReLU (Rectified Linear Unit).

I livelli convoluzionali sono caratterizzati da filtri, chiamati kernel, costituiti da matrici numeriche di dimensioni ridotte, per esempio 3×3 , con lo scopo di identificare una determinata caratteristica dell'immagine con complessità crescente all'aumentare del numero di filtri. Il risultato della convoluzione, chiamato 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 (stride) assegnato. Questa operazione restituisce un output di dimensione inferiore a quella in ingresso; per evitare di perdere informazioni si definisce il riempimento zero, o zero-padding, impostato al valore pari a zero per un determinato spessore che permetta di mantenere invariate le dimensioni dell'immagine. [24]

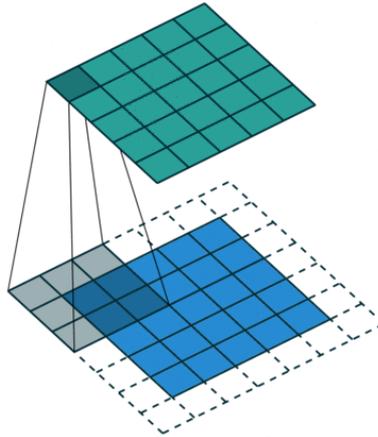


Figura 17: schema di funzionamento del layer convoluzionale [25]

L'output del livello convoluzionale costituisce l'input del livello ReLU, livello che introduce non linearità nel sistema imponendo una soglia che azzerà tutti i valori negativi e consente di accelerare i tempi di training della rete. L'operazione effettuata è la seguente:

$$f(x) = \begin{cases} x, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (\text{eq 2})$$

Per il corretto funzionamento della rete neurale, oltre alla ripetizione dei livelli convoluzionali e ReLU, sono necessari altri layers per preparare il dato in ingresso e per rendere il dato in uscita accessibile alle successive elaborazioni.

La struttura della rete è perciò articolata nelle seguenti quattro parti principali:

- **Image Input layer**

È il primo layer e ha la funzione di suddividere il dato di input in porzioni con dimensione dipendente dal campo ricettivo della rete, ossia la regione dello spazio dell'immagine che condiziona la risposta del layer più superficiale della rete. Per una rete con D layers convoluzionali, il campo ricettivo è di dimensione $(2D+1)$ -by- $(2D+1)$. VDSR ha 20 livelli convoluzionali, quindi il campo ricettivo ha dimensione 41×41 . Il layer di input accetta immagini con un solo canale, quello della luminanza.

- **Convolution 2D Layer + ReLU Layer**

La combinazione di questi due layers viene ripetuta 19 volte.

2D Convolutional Layer: contiene 64 filtri di dimensione 3×3 . Al fine di mantenere la dimensione delle mappe dopo ogni convoluzione uguale a quella di input si definisce un

bordo dell'immagine in ingresso al layer costituito da zeri. Il metodo di He inizializza i pesi a valori casuali in modo da introdurre l'asimmetria nell'insegnamento neurale.

ReLU Layer: introduce la non linearità nella rete.

- **Convolution 2D Layer**

Convolutional Layer con singolo filtro 3x3x64 che ricostruisce l'immagine.

- **Regression Output Layer**

È l'ultimo layer, layer di regressione che calcola lo scarto quadratico medio tra l'immagine dei residui e la stima della rete.

La Figura 18 raffigura la struttura della rete articolata nelle quattro parti principali; sulla destra si trova lo schema a blocchi, affiancato sulla sinistra da uno schema analogo in cui vengono esplicitati i parametri di ciascun layer.

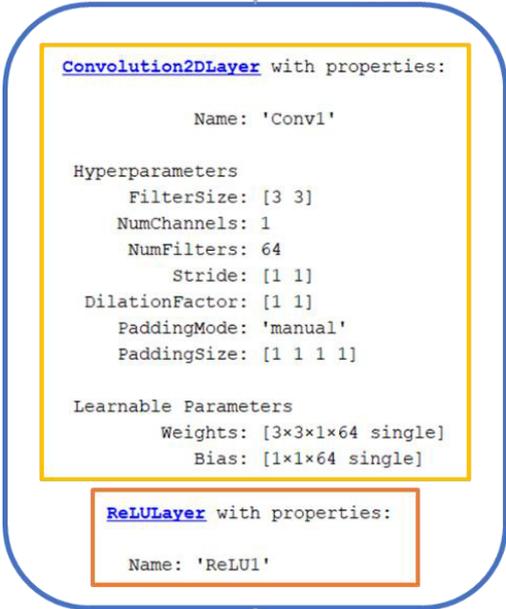
```

ImageInputLayer with properties:
    Name: 'InputLayer'
    InputSize: [41 41 1]

Hyperparameters
    DataAugmentation: 'none'
    Normalization: 'none'
    NormalizationDimension: 'auto'

```

x 19



```

Convolution2DLayer with properties:
    Name: 'Conv20'

Hyperparameters
    FilterSize: [3 3]
    NumChannels: 64
    NumFilters: 1
    Stride: [1 1]
    DilationFactor: [1 1]
    PaddingMode: 'manual'
    PaddingSize: [1 1 1]

Learnable Parameters
    Weights: [3x3x64 single]

```

```

RegressionOutputLayer with properties:
    Name: 'FinalRegressionLayer'
    ResponseNames: {'ResponseImage'}

Hyperparameters
    LossFunction: 'mean-squared-error'

```

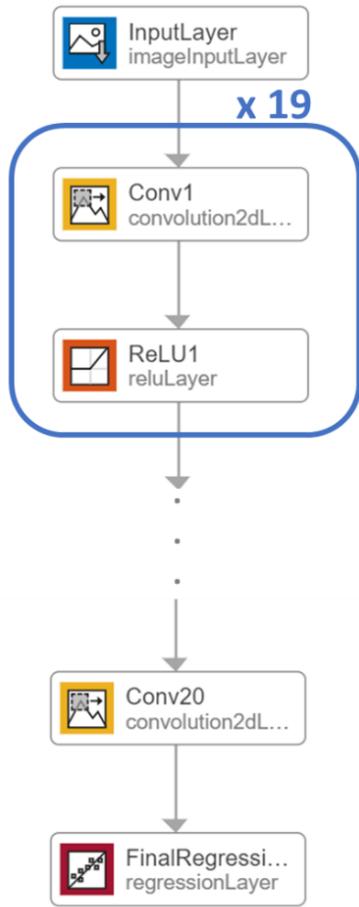


Figura 18: struttura della rete neurale VDSR

Il data store con i dati di input viene rielaborato per essere correttamente analizzato dalla rete.

In particolare, le immagini subiscono le seguenti trasformazioni:

- Ridimensionamento, in modo da corrispondere alle dimensioni attese dalla rete;
- Rotazione, riflessione in direzione x e variazione di scala per aumentare la variabilità dei dati di training a disposizione.

La Figura 19 riporta le opzioni di training suggerite per questa rete. [17] Il tasso di apprendimento (learning rate) è impostato a un valore iniziale di 0.1, elevato rispetto ad altre CNN, al fine di velocizzare il training.

Property ^	Value
Momentum	0.9000
InitialLearnRate	0.1000
LearnRateSchedule	'piecewise'
LearnRateDropFactor	0.1000
LearnRateDropPeriod	10
L2Regularization	1.0000e-04
GradientThresholdMethod	'l2norm'
GradientThreshold	0.0100
MaxEpochs	100
MiniBatchSize	64
<input checked="" type="checkbox"/> Verbose	0
VerboseFrequency	50
ValidationData	[]
ValidationFrequency	50
ValidationPatience	Inf
Shuffle	'once'
CheckpointPath	''
ExecutionEnvironment	'auto'
WorkerLoad	[]
OutputFcn	[]
Plots	'training-progress'
SequenceLength	'longest'
SequencePaddingValue	0
SequencePaddingDirection	'right'
<input checked="" type="checkbox"/> DispatchInBackground	0
<input checked="" type="checkbox"/> ResetInputNormalization	1

Figura 19: definizione delle opzioni di training dell' algoritmo

Il training consente di stimare, attraverso la minimizzazione dello scarto quadratico medio tra l'immagine ricostruita e la corrispondente immagine ad alta risoluzione, i parametri della rete che definiscono i calcoli effettuati tramite ciascun livello. [20]

7. Dati e pre-processing

I test vengono effettuati inizialmente per le immagini RGB al fine di ottenere una configurazione della rete adatta all'applicazione specifica e valutare l'efficacia di diverse strutture. In una seconda fase le sperimentazioni vengono ampliate per includere anche i dati multispettrali e utilizzarli come base per successive elaborazioni di indici per il monitoraggio della vegetazione.

7.1. Casi studio

Si dispone di immagini acquisite con drone in differenti località, inquadrare in Figura 20, e in diversi giorni. I dettagli sono riportati nella Tabella 9. A partire da questi dati si costruisce il dataset di immagini ad alta risoluzione per il training della rete neurale, come illustrato nel paragrafo 7.3 "Estrazione del dataset per il training".

Tutte le aree di studio ricadono in territorio piemontese e inquadrano vegetazione, con caratteristiche differenti. Tutte le immagini sono state acquisite nei mesi di giugno e luglio, dunque in una fase attività del ciclo vegetativo.

Il sito di Rivoira, frazione del comune di Boves in provincia di Cuneo, riguarda un'area agricola con campi coltivati con diverse colture come fagioli e patate. Le acquisizioni fanno riferimento a due anni diversi e sono effettuate con differenti sensori multispettrali.

La porzione di Grugliasco, in prossimità di Torino, è di estensione inferiore rispetto alla precedente e inquadra un vitigno.

Infine, l'area nel comune di Salbertrand della Val di Susa, la più estesa, riguarda vegetazione boschiva.

Per le acquisizioni con drone del 2019 di Rivoira e Grugliasco sono state scaricate dal portale dell'ESA (Copernicus Open Access Hub [5]) le corrispondenti immagini satellitari; il dato fa riferimento alla stessa data dell'immagine da drone o, se non disponibile, all'orario più vicino. Si utilizza per i test il sito di Rivoira a causa della ridotta estensione dell'area interessata dalle acquisizioni con drone a Grugliasco. I dettagli sono riportati in Tabella 10.

Per maggiori dettagli sull'ubicazione dei diversi siti in analisi si rimanda alla tavola in allegato "Elaborati grafici – T1 – Ubicazione aree di studio".

Tabella 9: dettagli delle acquisizioni con drone a disposizione per i test

LOCALITÀ	DATA	SENSORE	BANDE	RISOLUZIONE
Rivoira	26/07/2019	Mapir	RGB, Red, Green, NIR	2 cm
Rivoira	22/07/2020	Dji Phantom 4 Multispectral	RGB, NIR, Red Edge, Red, Green, Blue	3 cm
Grugliasco	25/06/2019	Slant Range	RGB, Red, Red Edge, NIR	2 cm
Salbertrand	17/06/2020		RGB	4 cm

Tabella 10: dettagli delle acquisizioni satellitari a disposizione per i test

LOCALITÀ	DATA	SENSORE	RISOLUZIONE
Rivoira	26/07/2019	Sentinel – 2	10 m
Grugliasco	26/06/2019	Sentinel – 2	10 m

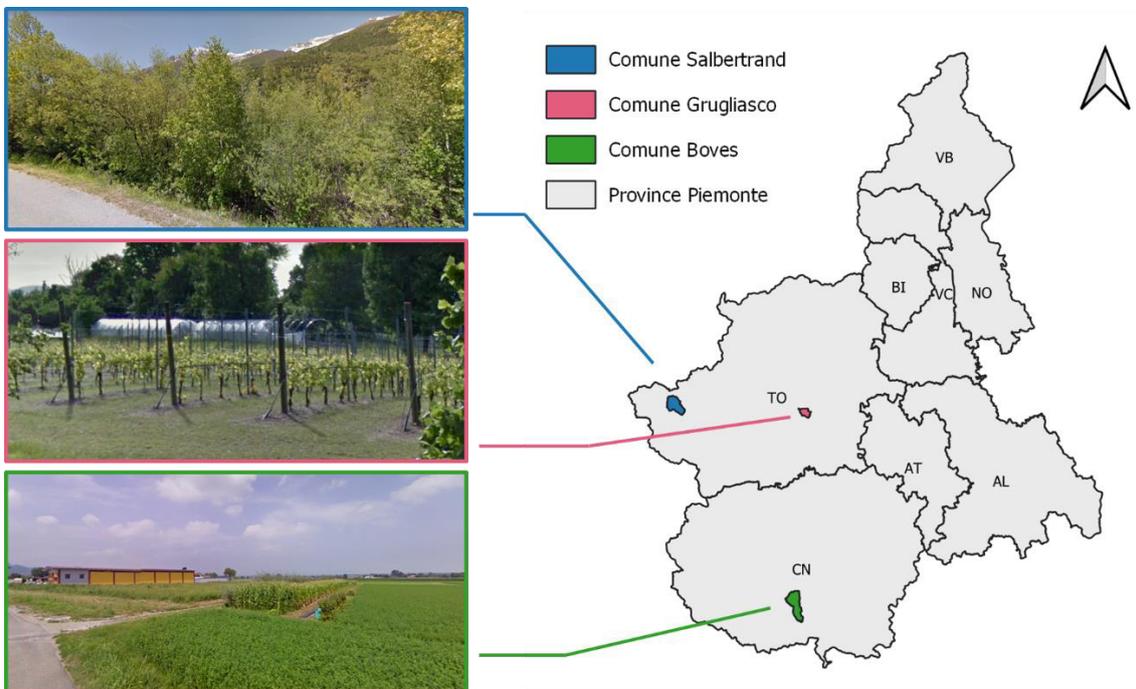


Figura 20: ubicazione delle aree di studio

7.2. Elaborazione immagini da drone

Le acquisizioni con drone necessitano di un'elaborazione per ottenere l'ortofoto da utilizzare come dataset per il training della rete neurale. Questo processamento viene eseguito tramite il software *Agisoft Metashape Professional 1.6.3*.

I dati di input a disposizione sono le immagini acquisite dal drone nelle diverse bande e le coordinate dei marker usati per la georeferenziazione del dato. L'elaborazione viene eseguita sulle singole bande, riunibili in uno stesso file tramite altri software che gestiscono dati territoriali (es: *GIS*).

Il flusso di lavoro da seguire per ogni banda è articolato nei seguenti passaggi:

1. Caricamento immagini

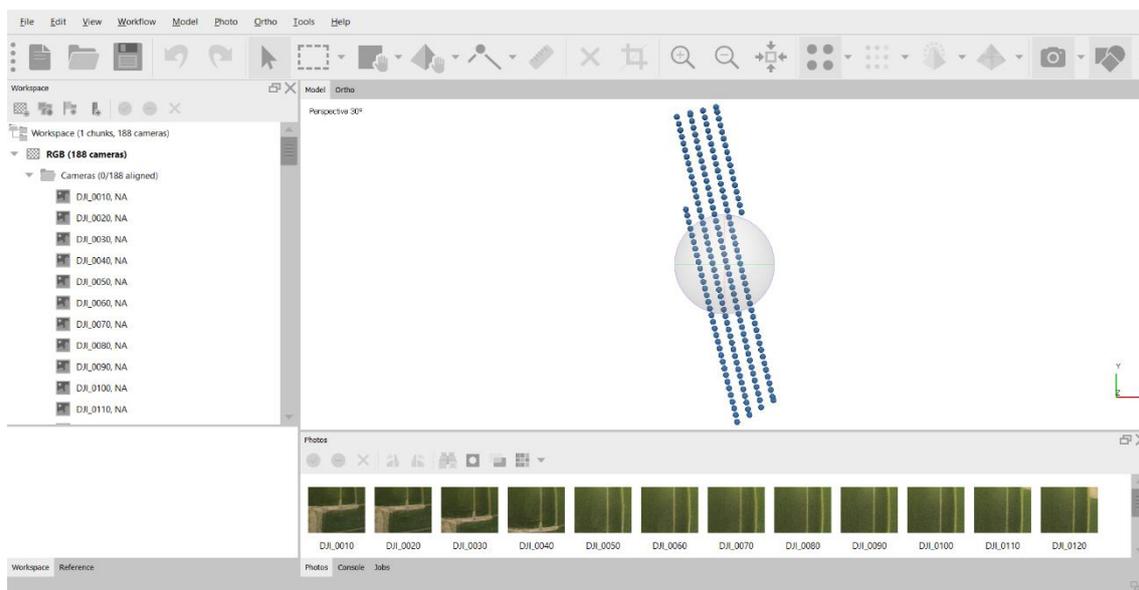


Figura 21: finestra relativa al caricamento delle immagini in Agisoft Metashape

2. Allineamento immagini e generazione della nuvola sparsa

Vengono determinate posizione e orientamento della fotocamera per ogni foto e viene creato un modello di nuvola di punti sparsa. I Tie points sono punti comuni tra coppie di immagini che vengono utilizzati per l'orientamento relativo. Al fine di georeferenziare correttamente il modello è necessario impostare i sistemi di coordinate del progetto, delle camere e dei punti di appoggio. Viene impostata per l'elaborazione un'accuratezza *medium*.

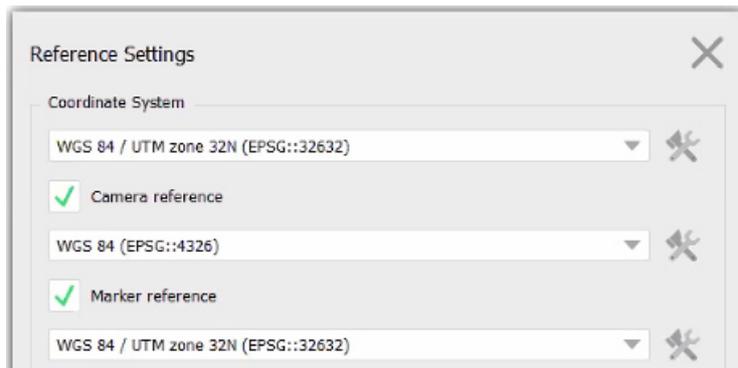


Figura 22: impostazione dei sistemi di riferimento del progetto, delle camere e dei punti di appoggio

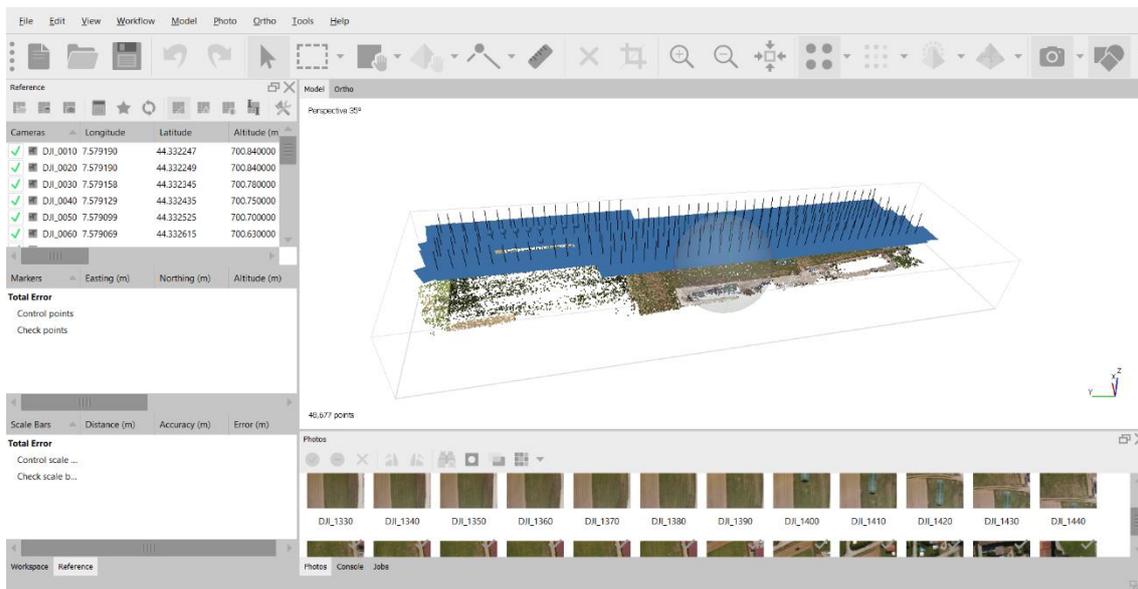


Figura 23: finestra relativa all'allineamento delle immagini e alla generazione della nuvola sparsa in Agisoft Metashape

3. Importazione coordinate GCP e loro collimazione sui rispettivi marker nelle immagini

Si individua la posizione dei punti di appoggio, con coordinate note, nelle immagini che li contengono per georeferenziare le immagini.

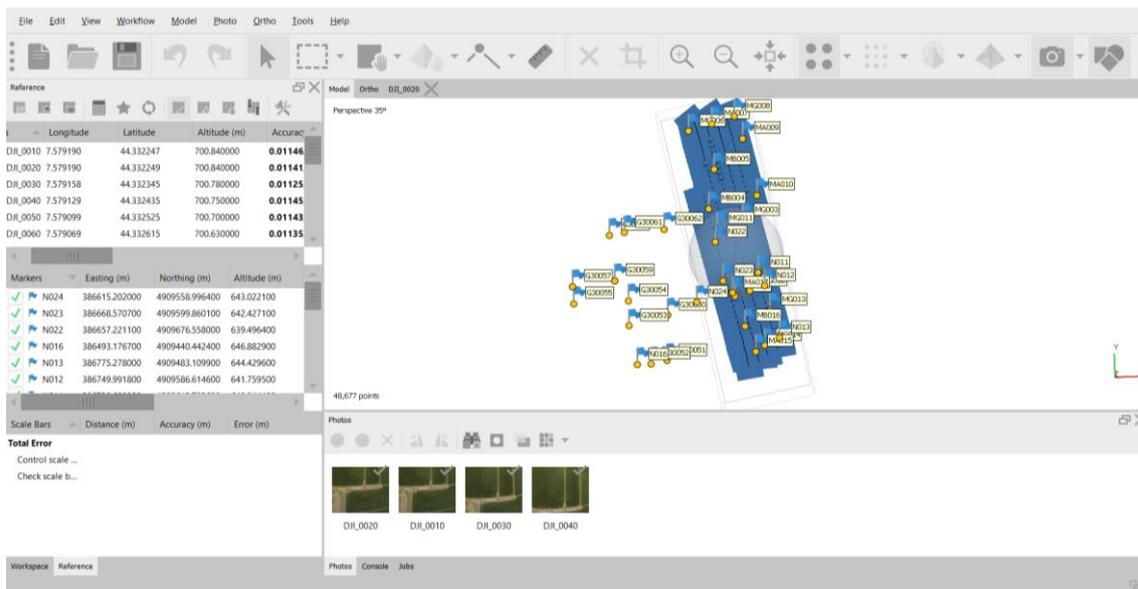


Figura 24: finestra relativa al caricamento dei markers in Agisoft Metashape

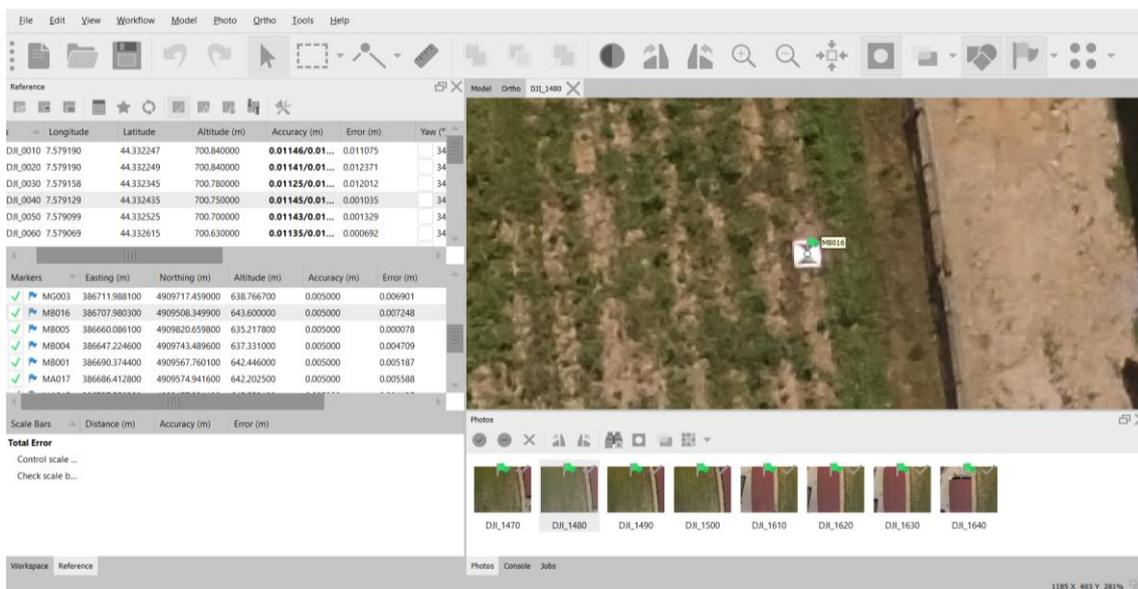


Figura 25: finestra relativa alla collimazione dei punti di appoggio in Agisoft Metashape

4. Ottimizzazione delle camere e verifica degli errori sui GCP

Questa funzione permette di ottimizzare i parametri di orientamento della fotocamera in base alle coordinate di riferimento note minimizzando gli errori.

5. Generazione della nuvola densa

Vengono impostate una qualità *medium* e un filtro *moderate* in modo da filtrare il rumore presente sulla vegetazione.

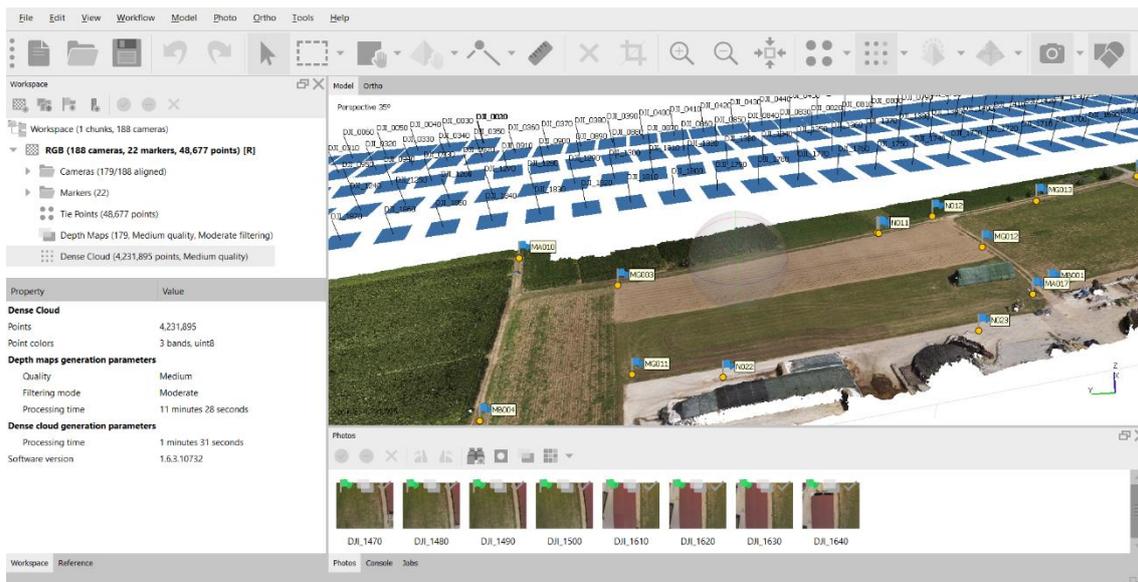


Figura 26: finestra relativa alla generazione della nuvola densa in Agisoft Metashape

6. Generazione del DEM

Sulla base della nuvola densa viene generato il DEM (Digital Elevation Model). Le quote ottenute per il modello digitale di elevazione sono espresse in coordinate ellissoidiche; è possibile effettuare la trasformazione a coordinate ortometriche sottraendo una costante Δ ($\Delta = 51$ m).

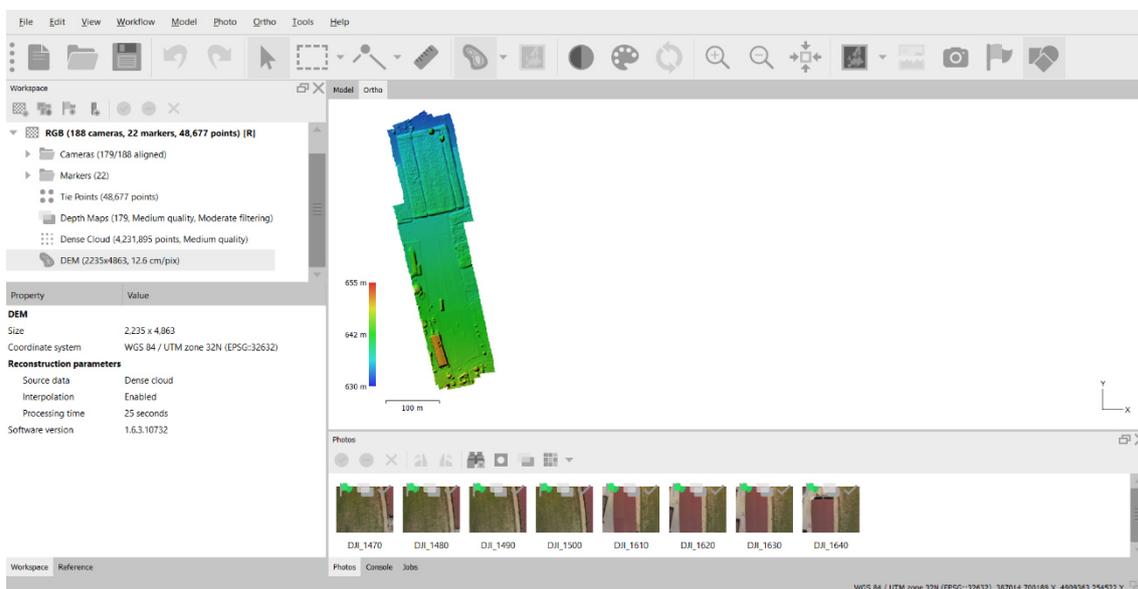


Figura 27: finestra relativa alla generazione del DEM in Agisoft Metashape

7. Generazione dell'ortomosaico

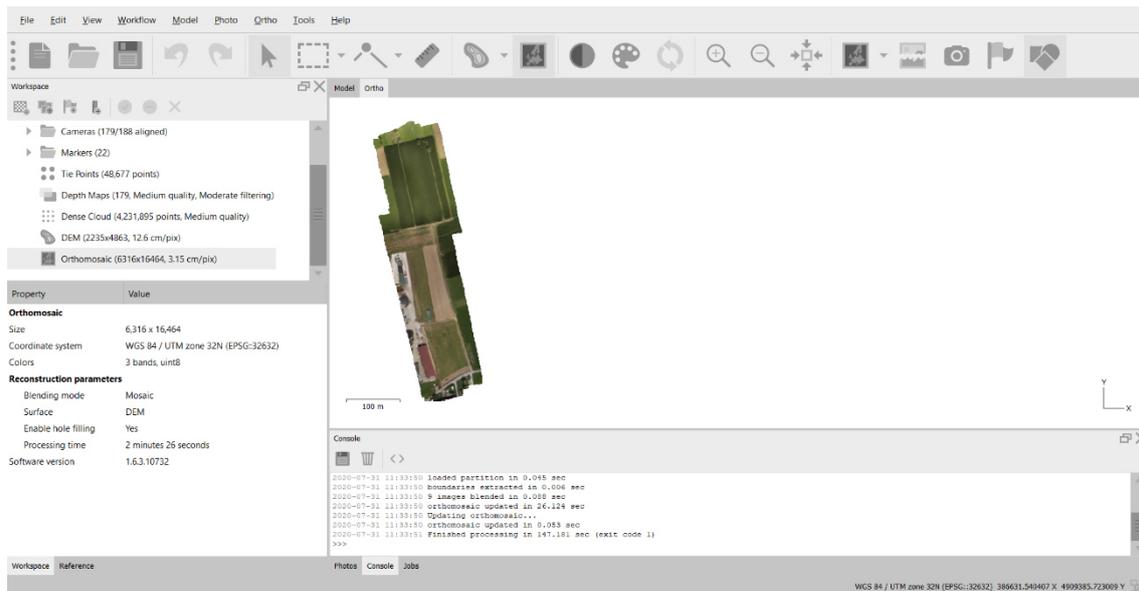


Figura 28: finestra relativa alla generazione dell'ortomosaico in Agisoft Metashape

8. Esportazione dei dati elaborati

Si esporta l'ortofoto ottenuta tramite orto-rettificazione e unione delle immagini originali da utilizzare per estrarre i dati ad alta risoluzione di training della rete neurale.

7.3. Estrazione del dataset per il training

L'allenamento della rete neurale risulta più affidabile aumentando il numero delle immagini di training; in particolare i deep model riescono ad avere prestazioni migliori solo con un adeguato numero di immagini di training. [28] Per ottenere un numero adeguato di dati, a partire dalle ortofoto ad alta risoluzione acquisite con drone a disposizione vengono estratte delle porzioni quadrate di circa 70 m di lato. Si ottiene in questo modo un campione di 479 immagini da utilizzare per il training. Inoltre, al fine di velocizzare l'applicazione della rete neurale e per ridurre la differenza di risoluzione tra le immagini da drone e quelle da satellite, le immagini ad alta risoluzione vengono ricampionate attraverso interpolazione Nearest Neighbour con risoluzione a 1 m. Questa affermazione è stata verificata testando il procedimento sia con immagini da drone con risoluzione di 2 cm, sia con immagini con risoluzione di 1 m; il risultato ottenuto per l'immagine della super risoluzione è analogo a fronte di tempi di elaborazione ridotti.

Queste elaborazioni vengono effettuate con il software *QGIS 3.10*.

7.4. Estrazione del dato per il test

Le immagini che costituiscono l'input della rete neurale VDSR sono immagini satellitari acquisite dalla missione Sentinel-2. I dati vengono scaricati gratuitamente dal portale ESA Scihub. [5] Il dato contiene le 13 bande e viene fornita inoltre un'immagine RGB, denominata TCI (True Color Image), costruita tramite la composizione delle bande B02 (Blue), B03 (Green), B04 (Red), con risoluzione spaziale di 10 m e distribuita con codifica a 8 bit.

Per il test delle immagini RGB viene utilizzata quest'ultima composizione.

Per il test delle immagini multispettrali è necessario combinare le bande del verde (B03), del rosso (B04) e dell'infrarosso vicino (B08). Queste bande hanno risoluzione spaziale di 10 m, ma l'informazione è espressa in 12 bit; ciò comporta problemi nella lettura del file multispettrale sul software Matlab e una discrepanza tra la rappresentazione ad alta risoluzione del drone e quella a bassa risoluzione del satellite. Il passaggio dalla suddivisione in 4096 intervalli della codifica a 12 bit alla suddivisione in 256 intervalli della codifica a 8 bit comporta una perdita di differenziazione della rappresentazione, dunque una maggior omogeneizzazione delle caratteristiche della scena inquadrata. Tuttavia, si rende necessario scalare i valori dell'immagine satellitare per riportarli alla codifica in 8 bit, importabile su Matlab, per procedere con l'analisi.

Data la notevole estensione dell'area inclusa nell'acquisizione satellitare, si estrae dall'immagine una porzione ridotta che includa la zona di interesse.

8. Metodologia

8.1. Scelte operative per il training della rete VDSR

La definizione della struttura della rete VDSR e la sua applicazione vengono effettuate tramite il software *Matlab R2020a*, attrezzato con i toolbox *Image Processing Toolbox* e *Deep Learning Toolbox*, e la specifica applicazione *Deep Network Designer App* per l'analisi e il design della rete. [29]

Il training della rete neurale è influenzato da tre aspetti:

- Dati di training
- Struttura della rete neurale
- Opzioni di training dell'algoritmo

È stato analizzato il risultato al variare di un singolo aspetto caratteristico alla volta in modo da individuare le impostazioni che permettano di ottenere l'accuratezza migliore.

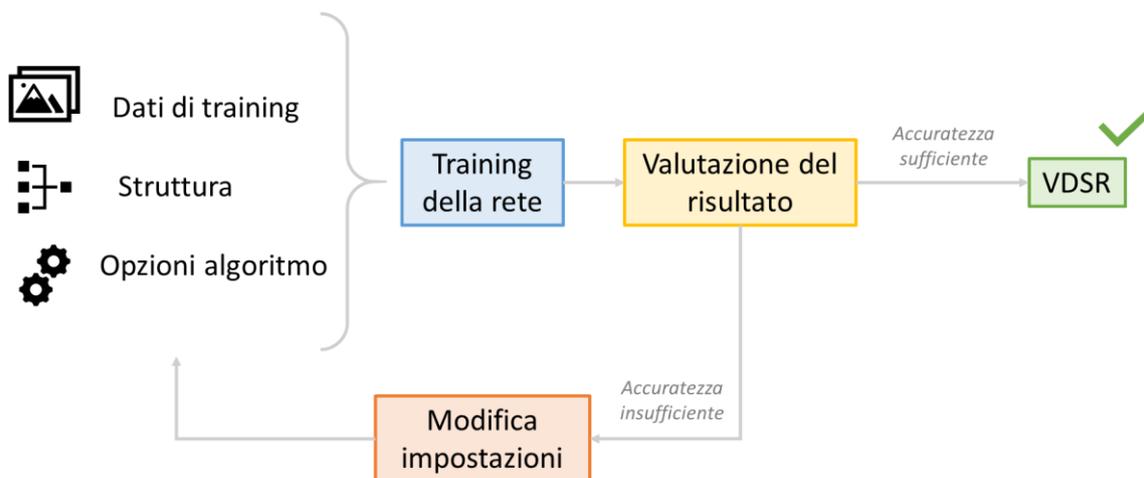


Figura 29: schema logico e iterativo per la definizione delle impostazioni per il training della rete neurale

I test effettuati per raggiungere la condizione ritenuta migliore sono i seguenti:

- Risoluzione data set di training
- Risoluzione immagine di test
- Dimensione immagini ad alta risoluzione
- Dimensione immagini a bassa risoluzione

- Dimensione immagine della super risoluzione, output della rete VDSR
- Fattori di scala per le immagini di training
- Angolo di rotazione delle immagini di training
- Numero di immagini di training

Per quanto riguarda i dati di training, si definisce un dataset di 479 immagini costituite da porzioni di immagini RGB ad alta risoluzione ricampionate a 1 m estratte dalle ortofoto elaborate dalle acquisizioni con drone. Queste immagini subiscono trasformazioni con fattori di scala pari a 2, 3 e 4 e rotazione di 20°. La risoluzione delle immagini di test viene mantenuta inalterata, corrispondente ai 10 m delle immagini satellitari.

Per migliorare il risultato di output della rete VDSR si esegue un processo iterativo ripetendo l'attivazione della rete neurale utilizzando come input ad ogni passaggio l'immagine a risoluzione migliorata dello step precedente e aumentando la dimensioni in pixels dell'immagine di output. La dimensione iniziale viene posta pari a quella dell'immagine di riferimento, se presente, altrimenti pari a quella dell'immagine a bassa risoluzione di input. In particolare, si raddoppia progressivamente la dimensione di partenza, in modo da mantenere inalterate le proporzioni dell'immagine, sino ad arrivare a un valore limite determinato in base ai limiti di memoria del computer utilizzato per l'elaborazione; il valore limite individuato risulta essere dell'ordine di grandezza di 3000 pixels x 3000 pixels. Questo porta a un miglioramento delle metriche usate come indicatori della qualità dell'immagine (PSNR, SSIM, NIQE).

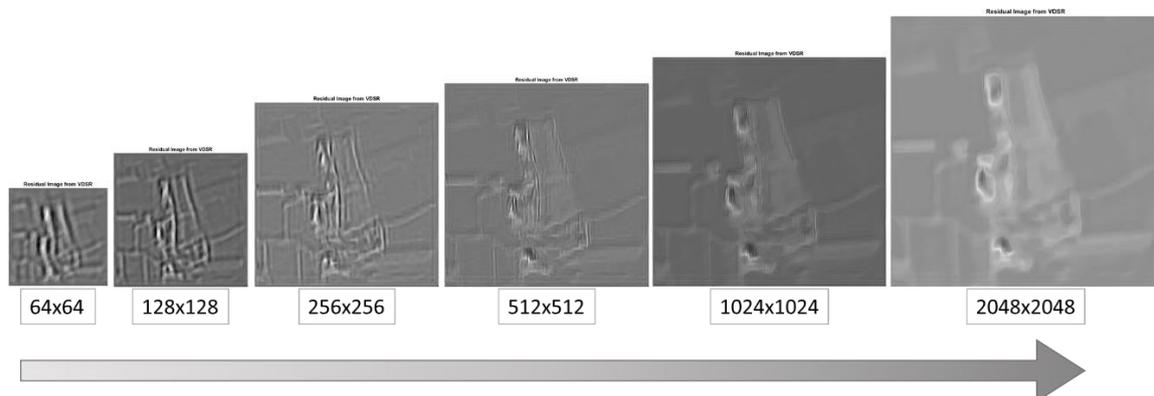


Figura 30: processo iterativo di attivazione della rete neurale VDSR; in figura sono mostrati i residui ottenuti come output di ogni step al crescere della dimensione dell'immagine

Per quanto riguarda la struttura della rete, si mantiene la struttura di base con 20 livelli convoluzionali. Si modifica il numero di filtri dei layers convoluzionali impostandolo a 128 in

modo da tenere maggiormente in considerazione la complessità delle forme geometriche; l'aumento del numero di filtri migliora le prestazioni del sistema, sebbene incidendo negativamente sulla durata dell'esecuzione. [20]

Le opzioni di training dell'algoritmo vengono mantenute inalterate.

8.2. Valutazione dell'accuratezza

L'immagine ottenuta come risultato dell'applicazione della rete neurale a un'immagine satellitare a bassa risoluzione viene confrontata con diversi dati noti al fine di valutare il miglioramento di accuratezza che si può ottenere.

Si eseguono sia valutazioni analitiche tramite il calcolo di metriche, sia valutazioni di quantificazione dell'accuratezza di rappresentazione di aspetti spaziali tramite il confronto con il dato vettoriale BDTRE e tramite l'elaborazione di classificazioni.

Per essere importata su un software e trattato come dato geografico per analisi di confronto, l'output della rete VDSR deve essere opportunamente georiferito in accordo con il sistema di riferimento utilizzato per gli altri dati (WGS 84 / UTM Zone 32N Proiettato).

8.2.1. Metriche di qualità dell'immagine

Le metriche di qualità dell'immagine necessitano di un dato di riferimento rispetto al quale valutare la coerenza dell'immagine ottenuta come output.

Per la valutazione statistica della qualità dell'immagine a risoluzione aumentata ottenuta rispetto all'immagine ad alta risoluzione di riferimento, facenti riferimento alla stessa area di studio, le metriche più comunemente utilizzate per la stima della qualità in processi di ricostruzione delle immagini sono PSNR e SSIM. [30]

Il PSNR (Peak Signal-to-Noise Ratio) è espresso come:

$$d_{PSNR} = 10 \log_{10} \left(\frac{v_{max}^2}{d_{MSE}} \right) \quad (eq\ 3)$$

Dove:

$v_{max} = 2^b - 1$ è una costante che rappresenta il limite superiore di possibili valori di intensità;

$d_{MSE} = \frac{1}{N} \sum_{n=1}^N (\widehat{y}_n - y_n)^2$ è lo scarto quadratico medio (Mean Squared Error).

Valori di PSNR più elevati indicano una qualità migliore.

L'indice SSIM (Structural Similarity index) è formulato per essere coerente con la percezione della visione umana e permette di valutare l'impatto visivo di luminanza, contrasto e struttura; risulta dunque particolarmente adatto per successive applicazioni con processamenti manuali come il Remote Sensing. [30]

Valori del SSIM tendenti al valore 1 indicano una maggior coerenza dell'immagine testata con quella di riferimento.

Inoltre, è stata presa in considerazione anche la metrica NIQE (Naturalness Image Quality Avaluator), misura della qualità percettiva dell'immagine. Una qualità maggiore è associata a valori minori.

L'utilizzo di diverse metriche di valutazione della qualità permette di analizzare diversi aspetti del risultato e questo si riflette nella discordanza del giudizio ricavabile dai vari indici.

8.2.2. Confronto con BDTRE

La Base Dati Territoriale di Riferimento degli Enti (BDTRE) è la base dei dati geografici della cartografia tecnica del territorio piemontese promossa dalla Regione. La BDTRE è disponibile in modalità open attraverso il Geoportale della Regione Piemonte. [31][32]

I dati utilizzati per il confronto al fine della valutazione dell'accuratezza sono in formato vettoriale (shapefiles) e vengono sovrapposti all'immagine di output della rete VDSR così come all'immagine satellitare. Questo permette di verificare visivamente la coerenza dell'elaborazione e il miglioramento di risoluzione ottenuto.

Gli elementi maggiormente presenti, utili per il confronto, risultano essere strade ed edifici.

8.2.3. Classificazione

Le classificazioni delle immagini hanno come obiettivo l'individuazione di categorie in cui gli elementi raggruppati all'interno della stessa classe abbiano caratteristiche analoghe. Per quanto riguarda le immagini multispettrali, queste caratteristiche sono rappresentate dalla risposta spettrale. Il risultato del processo di classificazione è una mappa tematica, ossia un'immagine con coordinate spaziali a singola banda che riporta i valori associati allo specifico aspetto semantico che si sta analizzando.

L'interpretazione dell'immagine nello spazio delle caratteristiche selezionato è effettuata in modo automatico attraverso la definizione di funzioni discriminanti che stabiliscono i confini tra le diverse classi.

Esistono due principali tipologie di classificazione:

- **Classificazione automatica (unsupervised)**

Si definisce il numero di classi (cluster) da ricercare. La classificazione consiste in un processo iterativo automatico che assegna ciascun punto a una classe sino ad arrivare a convergenza in base alle condizioni imposte dalla funzione discriminante. L'associazione dell'informazione semantica viene effettuata a posteriori dall'utente.

- **Classificazione assistita (supervised)**

L'utente estrae campioni di celle (ROI) per ciascuna classe, utilizzati nella fase di training per identificare le caratteristiche delle diverse categorie. L'informazione semantica viene dunque definita a priori. Per una buona riuscita della classificazione è necessario selezionare un campione rappresentativo e significativo dal punto di vista statistico delle diverse classi di interesse.

Per quanto riguarda le classificazioni di tipo assistito, per l'area di studio si definiscono tre classi:

1. Urbanizzato
2. Vegetazione
3. Suolo

Non viene inserita la classe "acqua", altrimenti tra le classi di base, poiché nelle aree analizzate non rientrano porzioni significative di territorio con presenza di acqua in superficie.

Per ciascuna classe si individua un campione di celle (ROI) dal quale si estraggono le firme spettrali di quella superficie, come riportata nell'esempio Figura 31. Sulla base di queste

informazioni si esegue l'algoritmo che fornisce come output il raster con i valori della classe di appartenenza per ciascun pixel.

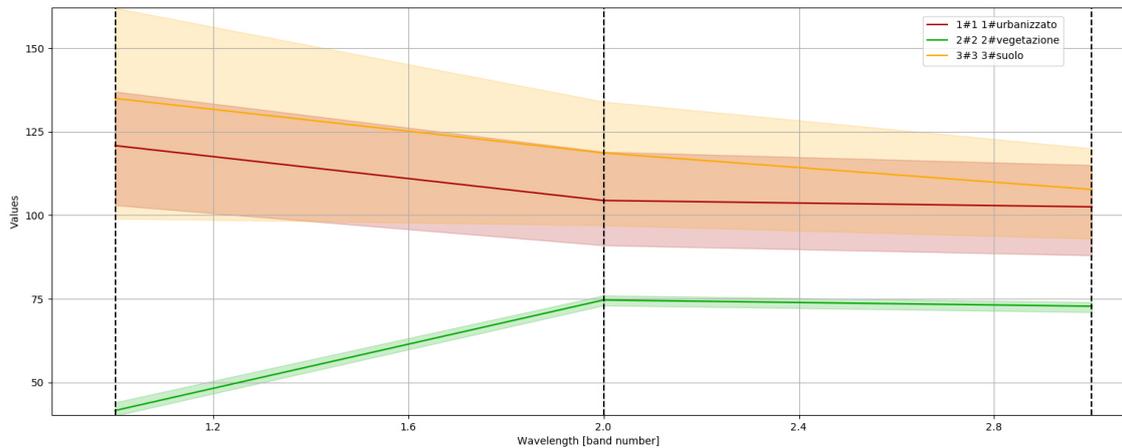


Figura 31: esempio di firme spettrali per le classi urbanizzato, vegetazione e suolo estratte da un'immagine RGB; sulle ascisse sono riportati i numeri di banda (1 = Red, 2 = Green, 3 = Blue), sulle ordinate i valori di DN

Ottenuta la mappa tematica si confronta l'informazione territoriale delle classi con le immagini RGB e con la BDTRE per valutare la corrispondenza degli elementi individuati.

Per avere una valutazione quantitativa dell'accuratezza della classificazione, viene calcolata la matrice di errore. La matrice di errore si basa sul confronto della classificazione ottenuta con un file vettoriale che identifica porzioni di territorio di classe nota, quantificando quante celle delle ROI di verifica sono state classificate nella giusta classe. La matrice ha dimensione $N \times N$, dove N è il numero delle classi della mappa tematica; le colonne rappresentano i dati di riferimento, ossia i dati di verità al suolo, mentre lungo le righe sono riportati i dati della classificazione. I valori lungo la diagonale principale riportano i casi di concordanza tra i dati di verità al suolo e i dati della classificazione, mentre i valori al di fuori rappresentano i casi di disaccordo, dunque di errata classificazione. Questo metodo permette di valutare l'accuratezza della classificazione e di analizzare la distribuzione dell'errore tra le diverse classi.

A partire dalla matrice di errore vengono determinate le seguenti misure di accuratezza:

- Accuratezza Globale (Overall Accuracy OA)

Si calcola come rapporto tra la somma dei casi in accordo (a_{ii}) e il numero totale di campioni (n). Viene espresso in percentuale e rappresenta la probabilità che un punto casuale venga classificato correttamente.

$$OA = \frac{\sum_{i=1}^N a_{ii}}{n} \quad (eq\ 4)$$

- Accuratezza Produttore (Producer's Accuracy PA)

Viene calcolata per ogni classe tramite il rapporto tra il numero di casi corretti e la somma totale della colonna. Viene espresso in percentuale e rappresenta la probabilità che un punto casuale classificato come classe i nei dati di riferimento rientri nella classe i della mappa tematica.

$$PA = \frac{a_{ii}}{a_{TOT,i}} \quad (eq\ 5)$$

- Accuratezza Utente (User's Accuracy UA)

Viene calcolata per ogni classe tramite il rapporto tra il numero di casi corretti e la somma totale della riga. Viene espresso in percentuale e rappresenta la probabilità che un punto casuale classificato come classe i nella mappa tematica rientri nella classe i dei dati di verità al suolo.

$$UA = \frac{a_{ii}}{a_{i,TOT}} \quad (eq\ 6)$$

Vengono calcolati inoltre i principali indicatori statistici (errore standard SE, intervallo di confidenza CI e kappa di Cohen \hat{k}).

Per l'analisi dell'accuratezza si eseguono sia classificazioni automatiche (metodo ISODATA), sia classificazioni assistite (metodo della minima distanza dalla media, metodo della massima verosimiglianza), al fine di valutare l'affidabilità della classificazione automatica e la necessità di definire delle ROI. Questi algoritmi di classificazione vengono effettuati tramite il software QGIS, implementato con il plugin *Semi-Automatic Classification Plugin (SCP)*. [33]

Si utilizzano inoltre gli algoritmi Random Forest e Support Vector Machine (SVM), implementati in QGIS tramite il plugin *Dzetska* [34], avendo installato la libreria *scikit-learn library*. Entrambi i metodi sono classificazioni assistite, per cui è necessario definire un campione (ROI) di training dell'algoritmo da cui estrarre le caratteristiche spettrali.

Vengono confrontati gli output dei diversi metodi al fine di selezionare il metodo di classificazione che restituisce il risultato più coerente con il dato.

In seguito alle elaborazioni multispettrali, si uniscono in un unico file le cinque bande blue, green, red, NIR e l'indice NDVI, con lo scopo di classificare più accuratamente gli elementi inquadrati nelle immagini; in questo modo è possibile sfruttare un numero maggiore di informazioni per differenziare le diverse superfici. Questa procedura viene effettuata sia per il dato satellitare sia per il dato ottenuto con la rete VDSR.

Per le analisi è stata selezionata la classificazione Support Vector Machine (SVM), applicata alle immagini con la composizione di bande blue, green, red, NIR e indice NDVI.

8.3. Analisi multispettrale

L'analisi dei dati multispettrali è svolta al fine di calcolare l'indice di vegetazione NDVI (Normalized Difference Vegetation Index) che permette di valutare la variazione spaziale e temporale dello stato di attività della vegetazione.

L'indice NDVI è un rapporto di bande spettrali definito come:

$$NDVI = \frac{NIR-RED}{NIR+RED} \quad (eq 7)$$

Il risultato di questo calcolo tra bande è un'immagine raster a banda singola che riporta informazione riguardanti lo stato vegetativo delle superfici inquadrare. I valori assumibili dai pixel rientrano nell'intervallo tra -1 e 1, dove valori bassi sono associati ad assenza di zone vegetate o vegetazione in condizioni di stress, mentre valori alti indicano superfici con vegetazione in buono stato. Questo è dovuto all'elevata riflessione nell'infrarosso (NIR) e all'elevato assorbimento nella banda del rosso (RED) da parte della vegetazione in uno stato attivo della fotosintesi, comportamento che permette di riconoscere lo stato vegetativo in cui si trova l'elemento analizzato al variare del ciclo fenologico. La vegetazione si riconosce infatti quando la riflettività nella banda dell'infrarosso risulta superiore alla riflettività nella banda del rosso.

Per riconoscere più nel dettaglio e comprendere più approfonditamente il comportamento spettrale della vegetazione si analizza la firma spettrale, ossia l'andamento della riflettività al variare della lunghezza d'onda dell'energia elettromagnetica riflessa dalla superficie di interesse. La firma spettrale ha un andamento specifico in caso di superfici omogenee; per quanto riguarda la vegetazione gli aspetti più significativi sono:

- Assorbimento nelle bande del blu e del rosso e picco massimo relativo nella banda del verde; questo andamento è dovuto principalmente ai pigmenti presenti nelle foglie (clorofilla);
- Massimo assoluto nella banda dell'infrarosso vicino, spiegabile in relazione al grado di sviluppo della struttura fogliare;

- Andamento per lunghezze d'onda superiori (SWIR) determinato in base al contenuto di acqua.

In Figura 32 si riporta un esempio delle firme spettrali non calibrate della vegetazione, in particolare di campioni di campi agricoli, estratte da un'immagine acquisita dal satellite Sentinel-2. Sull'asse delle ordinate sono riportati i valori di Digital Number (DN), non ancora convertiti in valori di radianza o riflettanza; sebbene la firma spettrale calibrata sia più rappresentativa del comportamento reale, tuttavia anche tramite l'espressione in termini di DN è possibile individuare i tratti caratteristici che permettono di riconoscere la vegetazione.

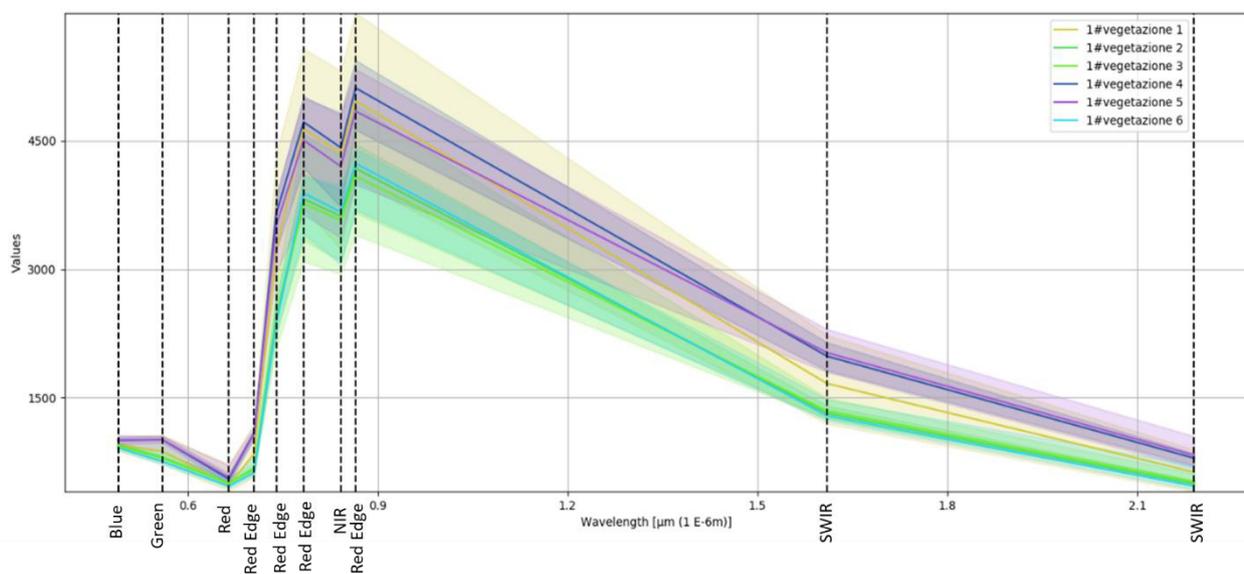


Figura 32: firma spettrale della vegetazione estratta da un'immagine satellitare Sentinel-2

Dato l'obiettivo di determinare l'indice NDVI, per quanto riguarda l'utilizzo dei dati multispettrali all'interno della rete neurale VDSR, è necessario combinare tre bande che verranno poi trasformate dallo spazio RGB allo spazio YCbCr per attivare la rete sul canale della luminanza, allo stesso modo di quando fatto per le immagini RGB a colori reali. La combinazione utilizzata è Green / Red / NIR, visualizzata tramite la composizione a falsi colori (R = NIR, G = Red, B = Green).

Si confronta quindi l'indice NDVI relativo all'immagine da drone (quando presente), satellitare e della rete VDSR.

9. Risultati

Il training selezionato utilizza 479 immagini ad alta risoluzione (1 m). Il processo è stato completato in 87 ore, circa 3 giorni e mezzo. Nella Tabella 11 si riportano le caratteristiche del computer utilizzato per il training. Le elaborazioni sono state svolte con l'impiego della CPU poiché si è rilevato un comportamento anomalo nei risultati scaricando il tool che permette l'utilizzo della GPU.

Tabella 11: specifiche tecniche computazionali del calcolatore utilizzato per l'elaborazione

CPU	CPU Intel Core i5 8th Generation, fino a 4 GHz
RAM	16 Gb, 2666 MHz
GPU	Nvidia gtx 1070, 8 Gb

Di seguito si riporta l'andamento dello scarto quadratico medio e degli scarti all'avanzare delle iterazioni.

Results	
Validation RMSE:	N/A
Training finished:	Reached final iteration
Training Time	
Start time:	15-Aug-2020 17:47:57
Elapsed time:	5219 min 6 sec
Training Cycle	
Epoch:	100 of 100
Iteration:	51000 of 51000
Iterations per epoch:	510
Maximum iterations:	51000
Validation	
Frequency:	N/A
Other Information	
Hardware resource:	Single CPU
Learning rate schedule:	Piecewise
Learning rate:	1e-10

Figura 33: dati relativi al completamento del processo di training della rete neurale VDSR

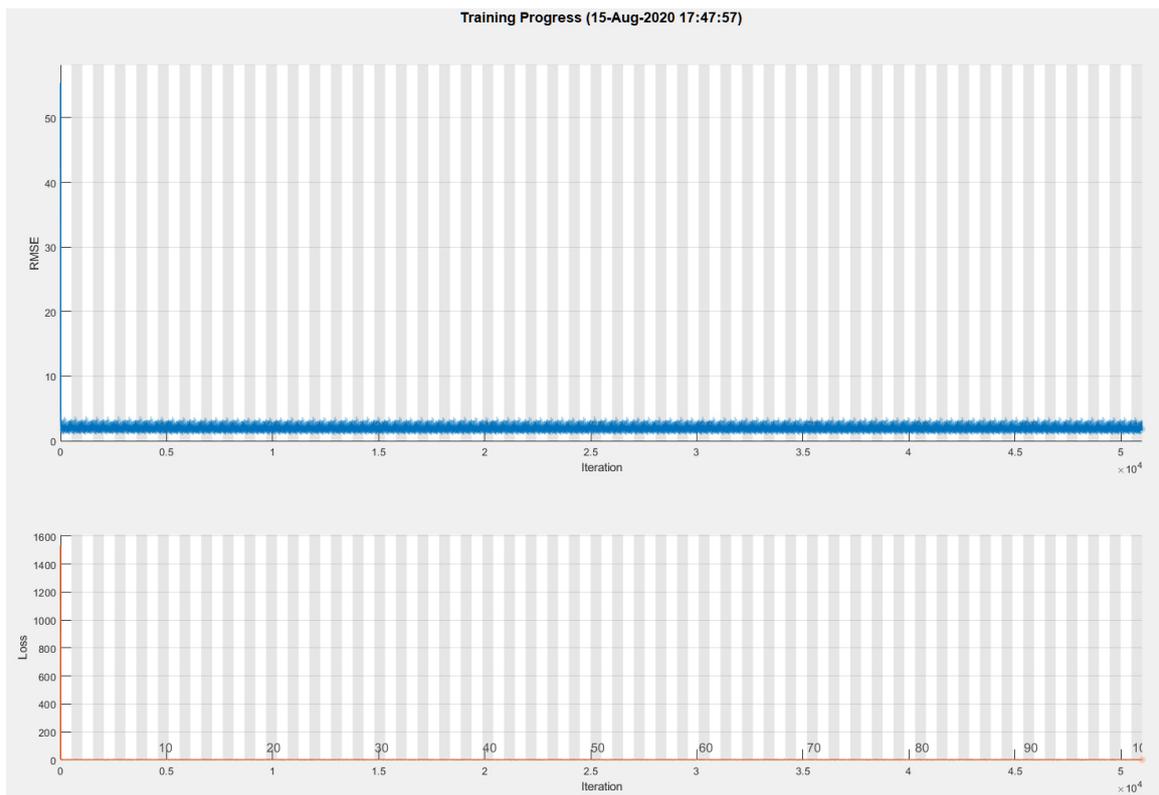


Figura 34: finestra Matlab del training della rete neurale VDSR

9.1. Test 01: area studio di 2 ettari

Per la valutazione dell'accuratezza è necessario estrarre una porzione di immagine satellitare di cui si dispone della corrispondente immagine ad alta risoluzione. I test vengono dunque effettuati sull'elaborazione tramite super risoluzione di tale porzione di immagine, avendo così a disposizione tre immagini di base per il confronto:

- Immagine del drone ad alta risoluzione (ricampionamento a 1 m)
- Immagine del satellite a bassa risoluzione (risoluzione 10 m)
- Immagine ottenuta tramite super risoluzione

I test per la valutazione del risultato ottenuto vengono effettuati sul sito di Rivoira. L'area utilizzata viene estratta in modo che rientri interamente nell'ortofoto acquisita con drone, senza contenere zone di bordo prive di valori. Le analisi effettuate su questa porzione di territorio vengono identificate come *Test01*.

L'area analizzata risulta avere dimensioni dell'ordine di grandezza di 100 m x 200 m. La ridotta estensione risulta essere un limite per l'applicazione della rete VDSR, ma si rende necessaria per

il confronto con l'immagine del drone a disposizione. Per valutazioni su aree più estese si utilizzano altri tipi di test dell'accuratezza.

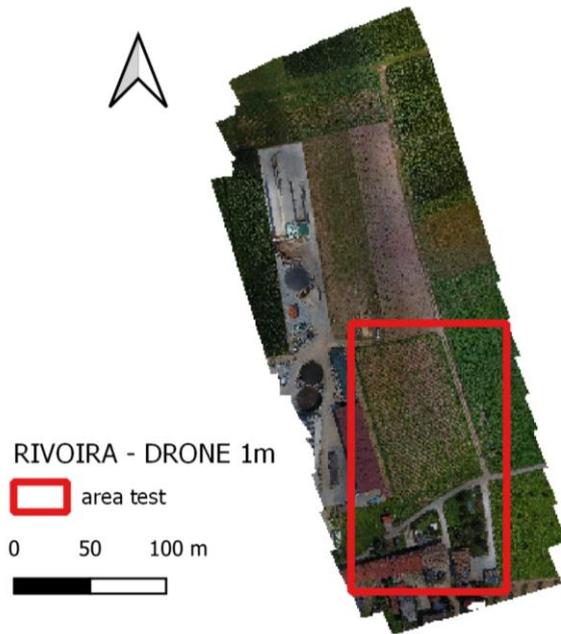


Figura 35: Inquadramento area test 01

Tabella 12: caratteristiche dimensionali delle immagini utilizzate per il test 01

	Numero righe	Numero colonne
Immagine bassa risoluzione	19	13
Immagine alta risoluzione di riferimento iniziale	177	102
Immagine finale	5664	3264

Inizialmente si attiva la rete definendo la dimensione dell'immagine in uscita pari alla dimensione dell'immagine di riferimento ad alta risoluzione.

In una fase successiva si aumenta progressivamente la dimensione dell'immagine a risoluzione aumentata definendo come input di ciascuno step il risultato della super risoluzione ottenuto al passaggio precedente, scalando dello stesso valore anche l'immagine di riferimento in modo da riuscire a calcolare le metriche. Le dimensioni ottenute risultano multipli dell'immagine ad alta risoluzione di partenza, mantenendo così inalterate le proporzioni.

Come riportato in Figura 36, le metriche migliorano effettuando il processo iterativo raggiungendo un valore massimo di PSNR = 15.1759, un valore massimo di SSIM = 0.4644 e un valore minimo di NIQE = 9.8823.



Figura 36: applicazione della rete neurale VDSR all'area test 01; si riportano i valori delle metriche PSNR, SSIM e NIQE per le immagini all'inizio e alla fine del processo iterativo

Questa area di test viene valutata anche sovrapponendo il dato vettoriale BDTRE. Le immagini complete sono riportate in allegato "Elaborati grafici – T2 – Confronto con BDTRE Test 01", mentre in Figura 37 è mostrato uno zoom su una porzione con presenza di edifici (rappresentati con bordo grigio) e strade (in giallo).

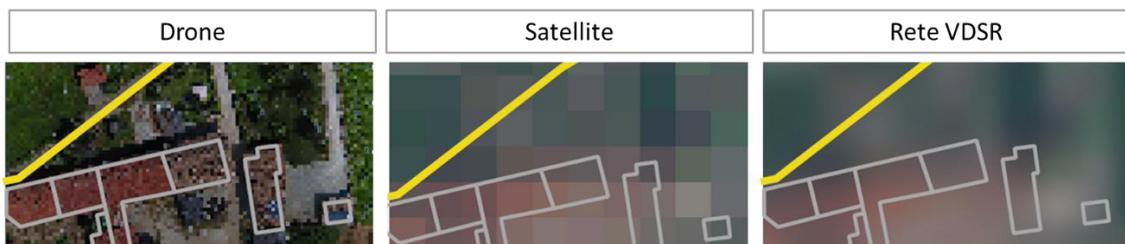


Figura 37: zoom relativo al confronto con BDTRE dell'area studio Test 01

Sulla stessa area viene inoltre effettuata l'analisi multispettrale. In particolare, si confronta l'indice NDVI ottenuto per le immagini alle diverse risoluzioni; l'elaborato grafico complessivo è riportato in allegato "Elaborati grafici – T3 – Indice NDVI Test 01". La Figura 38 fa riferimento a uno stralcio delle mappe dell'indice NDVI, raffigurante la porzione inferiore dell'area di studio in cui sono presenti alcuni edifici circondati da prati. Le aree vegetate sono identificabili dal colore più chiaro, corrispondente a un valore di NDVI elevato, mentre con le gradazioni più scure, vale a dire NDVI basso, si individuano zone più aride sino ad arrivare alle zone urbane di colore tendente al nero.

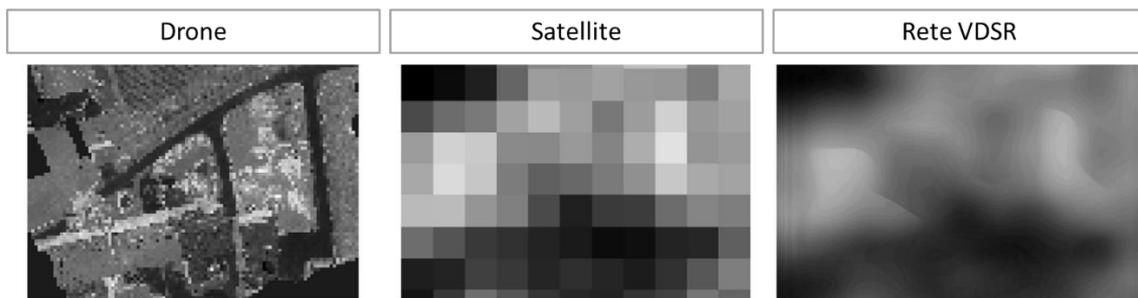


Figura 38: zoom relativo alle mappe dell'indice NDVI dell'area studio Test 01

9.2. Test 02: area studio di 25 ettari

Per analizzare il risultato su un'area più estesa, si estrae dal dato satellitare una porzione quadrata di circa 500 m di lato. L'area selezionata include la zona di cui si dispone del rilevamento con drone, ma si estende ulteriormente su zone senza disponibilità della corrispondente immagine ad alta risoluzione. Questo test risulta dunque interessante per analizzare il comportamento della rete neurale quando si fornisce un dato di input "sconosciuto", non raffigurato nel dataset di training. Le analisi effettuate su questa porzione di territorio vengono identificate come *Test02*.

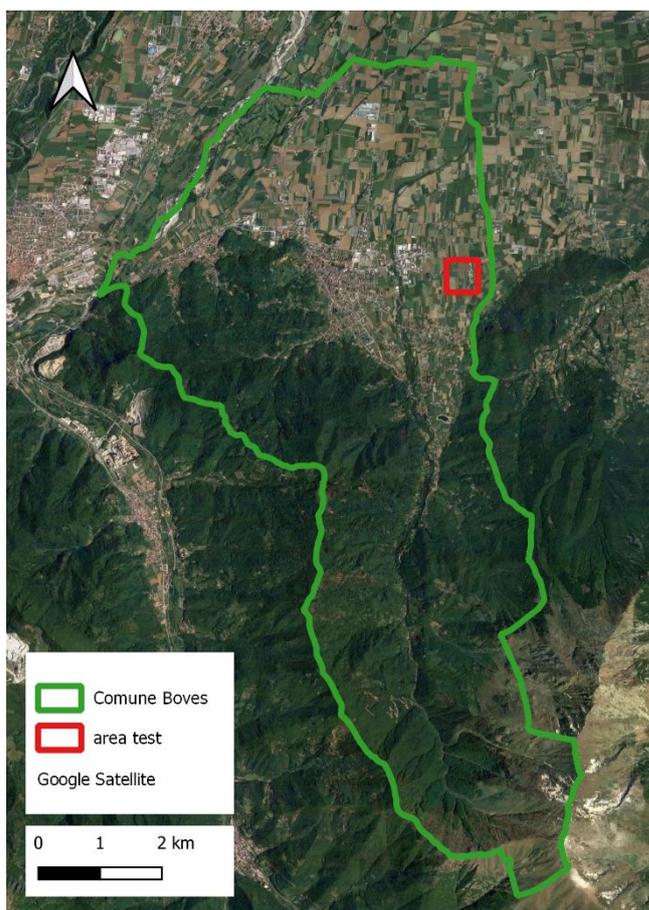


Tabella 13: caratteristiche dimensionali delle immagini utilizzate per il test 02

	Numero righe	Numero colonne
Immagine bassa risoluzione	54	52
Immagine VDSR finale	1728	1664

Figura 39: inquadramento area test 02

L'immagine satellitare costituisce l'input della rete neurale; la dimensione finale dell'immagine di output viene anche in questo caso aumentata con un processo iterativo mantenendo le proporzioni dell'immagine. Le caratteristiche dimensionali sono riportate Tabella 13.

Poiché non si dispone dell'immagine ad alta risoluzione di riferimento, la valutazione dell'accuratezza viene effettuata visivamente tramite il confronto con il dato BDTR. La visualizzazione ottenuta è riportata in allegato "Elaborati grafici – T4 – Confronto con BDTR Test 02". In Figura 40 si mostra una porzione dell'area analizzata con presenza di edifici e strade.

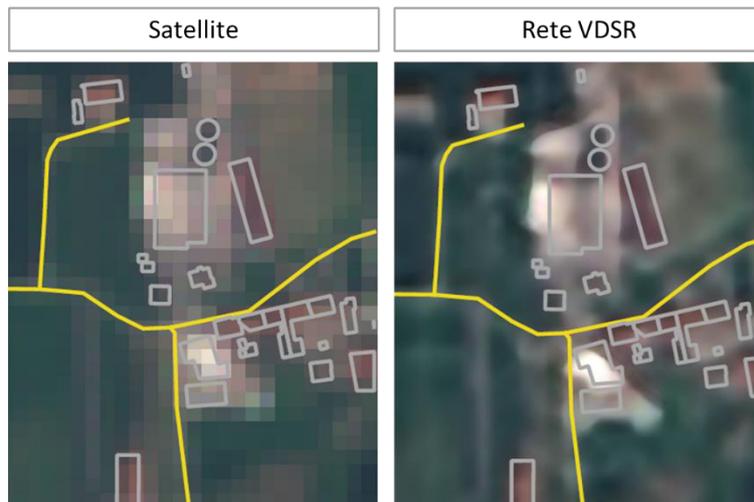


Figura 40: zoom relativo al confronto con BDTRE dell'area studio Test 02

Per quanto riguarda l'analisi multispettrale, viene calcolato l'indice NDVI per il dato satellitare e per il dato ottenuto tramite la rete neurale VDSR. Si associa alla mappa relativa all'indice la visualizzazione a falsi colori NIR (R) / Red (G) / Green (B) dove la vegetazione è raffigurata in colore rosso, ossia elevata riflettività nella banda dell'infrarosso vicino, e uno stato vegetativo più attivo è associabile alle aree di colore rosso acceso. Alle aree a cui è associato il colore rosso nella visualizzazione a falsi colori corrisponde un valore di NDVI più alto, dunque raffigurato con tonalità chiara. Le porzioni di territorio rappresentate di colore ciano nella composizione a falsi colori fanno riferimento invece a terreni con assenza di vegetazione oppure ad aree urbanizzate, come viene confermato da valori di indice NDVI bassi. Si rimanda agli allegati "Elaborati grafici – T5 – Indice NDVI Test 02" per la rappresentazione grafica di tutta l'area di studio, mentre in Figura 41 si riporta un particolare.

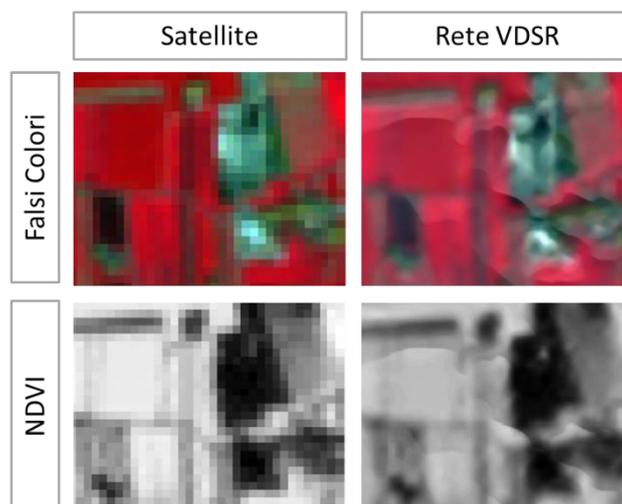


Figura 41: zoom relativo alle mappe dell'indice NDVI dell'area studio Test 02

Come si può notare dalle immagini, elaborando il dato multispettrale con la rete neurale i bordi vengono esaltati; tuttavia compaiono delle striature inattese, incoerenti con il dato satellitare.

Inoltre, le immagini vengono elaborate attraverso l’algoritmo assistito basato sul metodo Support Vector Machine (SVM) per ottenere la suddivisione del territorio nelle tre classi urbanizzato (1), vegetazione (2) e suolo (3). Il risultato è riportato in allegato “Elaborati grafici – T6 – Classificazione Test 02” e la Figura 42 ne mostra uno stralcio.

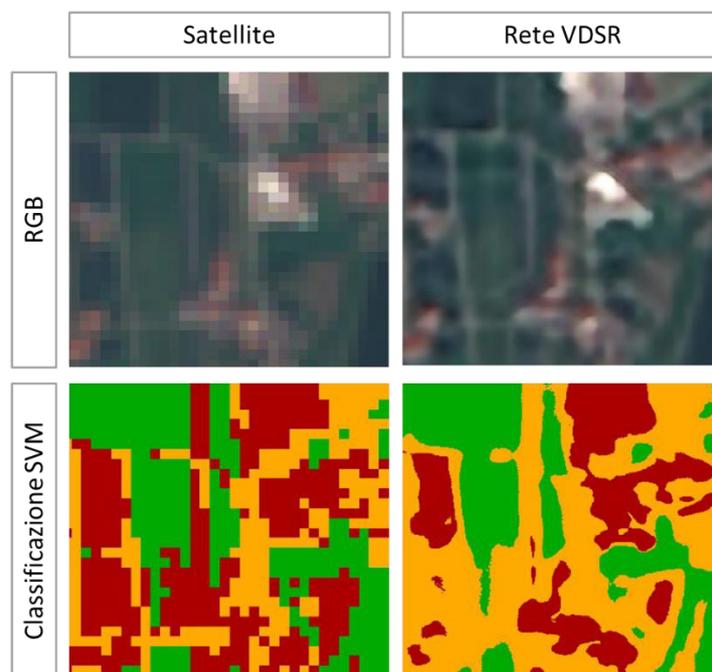


Figura 42: zoom relativo alla classificazione SVM dell'area studio Test 02

Tramite la matrice di errore, in Tabella 14 per il dato satellitare e Tabella 15 per il dato da drone, si evidenziano le caratteristiche probabilistiche delle classificazioni ottenute. In particolare, si noti: il valore di accuratezza globale, accettabile in entrambi i casi anche se più elevato nel caso della classificazione basata sull’esito della rete VDSR; il valore di \hat{K} di ciascuna classe, pari a 1 per la classe “vegetazione - 2”, indice di un’ottima concordanza tra dati casuali, di valore basso < 0.5 per le altre classi, rappresentante una concordanza discreta; la minor corretta rappresentazione dei pixels appartenenti alle classi “urbanizzato - 1” e “suolo - 3”, come si può leggere dalle celle lungo la diagonale della matrice confrontandole con i valori delle celle della stessa riga o colonna, indicatori di casi errati di classificazione. La scarsa accuratezza nella rappresentazione delle classi “urbanizzato - 1” e “suolo - 3” rispetto alla classe “vegetazione - 2” è anche riscontrabile dai valori bassi dei parametri di accuratezza produttore (PA) e accuratezza utente (UA).

Tabella 14: matrice di errore relativa alla classificazione SVM basata sull'immagine satellitare Sentinel-2 per l'area test 02; i valori di area sono espressi in m². SE = standard error; CI = confidence interval; PA = producer's accuracy; UA = user's accuracy

MATRICE DI ERRORE (pixel count)

		Dati di riferimento			Totale
		1	2	3	
Dati classificazione	1	16	0	10	26
	2	0	64	0	64
	3	20	0	27	47
Totale		36	64	37	137

MATRICE DI ERRORE (area based)

		Dati di riferimento			Area	Wi
		1	2	3		
Dati classificazione	1	0.1653	0	0.1033	72600	0.2686
	2	0	0.4314	0	116600	0.4314
	3	0.1277	0	0.1724	81100	0.3000
Totale		0.2930	0.4314	0.2757	270300	
Area		79188	116600	74512	270300	

Classe	1	2	3
SE	0.0341	0	0.0341
SE area	9212	0	9212
95% CI area	18055	0	18055
PA [%]	56.4	100	62.5
UA [%]	61.5	100	57.4
Kappa hat	0.46	1	0.41

Overall accuracy [%]	76.9
Kappa hat classification	0.65

Tabella 15: matrice di errore relativa alla classificazione SVM basata sull'elaborazione della rete neurale VDSR per l'area test 02; i valori di area sono espressi in m². SE = standard error; CI = confidence interval; PA = producer's accuracy; UA = user's accuracy

MATRICE DI ERRORE (pixel count)

		Dati di riferimento			Totale
		1	2	3	
Dati classificazione	1	15630	0	1460	17090
	2	0	72171	0	72171
	3	17726	1446	35450	54622
Totale		33356	73617	36910	143883

MATRICE DI ERRORE (area based)

		Dati di riferimento			Area	Wi
		1	2	3		
Dati classificazione	1	0.1114	0	0.0104	32493	0.1218
	2	0.0000	0.371	0	98994	0.3710
	3	0.1646	0.0134	0.3292	135342	0.5072
Totale		0.2760	0.3844	0.3396	266828	
Area		73638	102577	90614	266828	

Classe	1	2	3
SE	0.0010	0.0003	0.0011
SE area	280	93	285
95% CI area	549	182	559
PA [%]	40.4	96.5	96.9
UA [%]	91.5	100	64.9
Kappa hat	0.88	1	0.47

Overall accuracy [%]	81.2
Kappa hat classification	0.71

9.3. Test 03: area studio di 400 ettari

Viene ulteriormente definita un'area di maggiore estensione di circa 2 km per lato al fine di valutare il miglioramento del risultato ottenuto con la rete VDSR su una zona in cui anche il dato satellitare fornisce informazioni adeguatamente leggibili sugli elementi inquadrati. Le analisi effettuate su questa porzione di territorio vengono identificate come *Test03*.

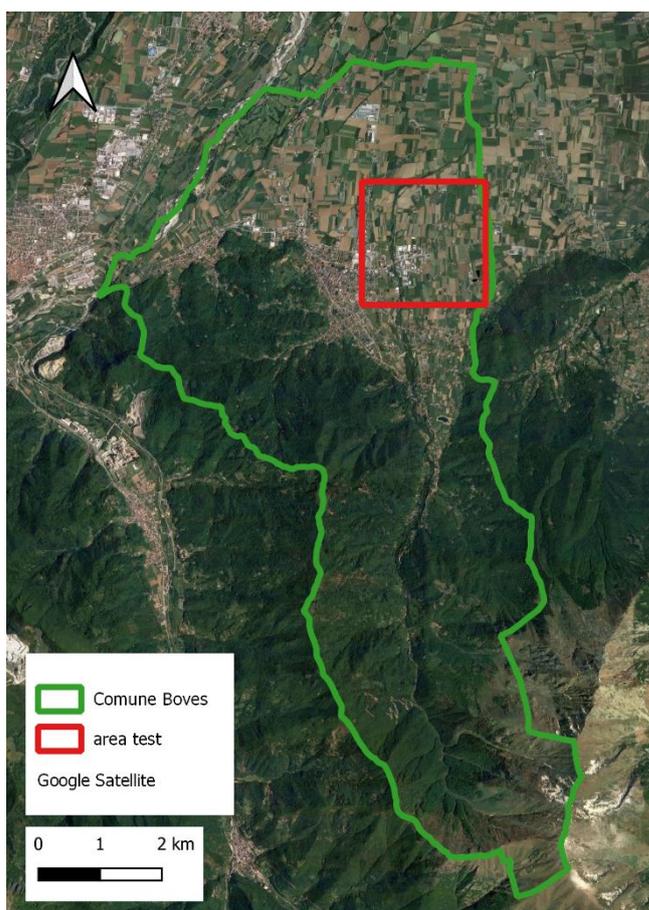


Tabella 16: caratteristiche dimensionali delle immagini utilizzate per il test 03

	Numero righe	Numero colonne
Immagine bassa risoluzione	203	201
Immagine VDSR finale	3248	3216

Figura 43: inquadramento area test 03

Il dato satellitare viene elaborato con la stessa procedura del test precedente, utilizzando le dimensioni riportate in Tabella 16.

L'analisi multispettrale mostra chiaramente la tipologia di area inquadrata, ossia una zona prevalentemente agricola con insediamenti urbani di ridotte dimensioni. Dalla visualizzazione a falsi colori e dalla mappa dell'indice NDVI si riconoscono inoltre i campi con vegetazione in uno stato attivo del ciclo fenologico, identificati rispettivamente da colore rosso acceso e da tonalità tendenti al bianco, distinguendoli da aree agricole con minor attività vegetativa, in entrambe le

rappresentazioni più scure rispetto al caso precedente, e da aree non coltivate o urbane. Le visualizzazioni grafiche sono riportate in allegato “Elaborati grafici – T7 – Indice NDVI Test 03”. La Figura 44 mostra una porzione dell’area complessiva in cui si possono notare le precedenti osservazioni.

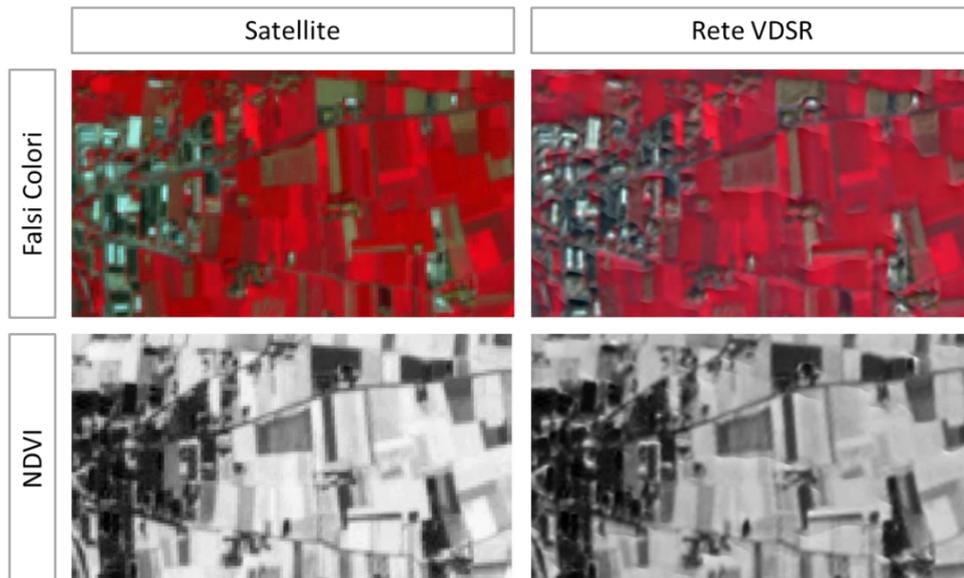


Figura 44: zoom relativo alle mappe dell’indice NDVI dell’area studio Test 03

Data l’estensione dell’area analizzata, una procedura di valutazione dell’accuratezza significativa è la classificazione. Per il risultato grafico della classificazione assistita secondo il criterio SVM, elaborato sia per l’immagine satellitare sia per l’immagine ottenuta con la rete VDSR, si rimanda agli allegati “Elaborati grafici – T8 – Classificazione Test 03”. Un dettaglio di tale elaborazione è riportato in Figura 45.

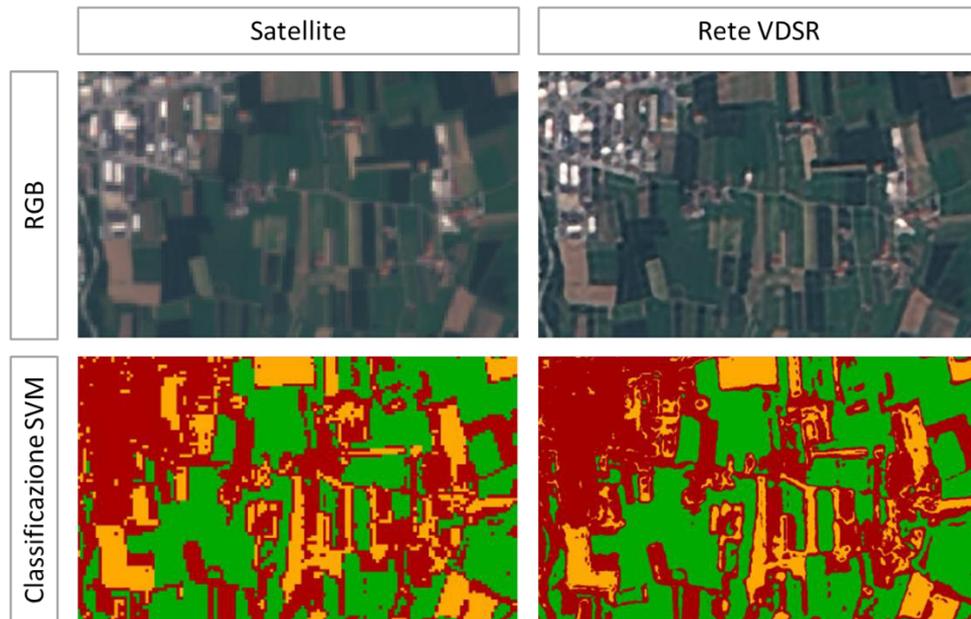


Figura 45: zoom relativo alla classificazione SVM dell'area studio Test 03

Di seguito si riporta, per entrambi i casi, la matrice di errore con le derivanti misure di accuratezza. In questo caso l'esito ottenuto è migliore rispetto a quello relativo al *Test 02*. Infatti, il valore di accuratezza globale, prossimo a 91 %, risulta ottimo sia nel caso dell'immagine satellitare sia nel caso dell'immagine ottenuta con la rete VDSR, sebbene di valore analogo nelle due immagini analizzate. Inoltre, anche i valori del kappa di Cohen \hat{k} delle singole classi e della classificazione nel complesso migliorano rispetto al caso precedente del test 02, assumendo valori corrispondenti a un grado di concordanza buono-ottimo. Le classificazioni ottenute per l'immagine satellitare e l'immagine della rete VDSR sono paragonabili, sebbene quest'ultima sia rappresentata da valori lievemente migliori dei parametri connessi alla matrice di errore.

Tabella 17: matrice di errore relativa alla classificazione SVM basata sull'immagine satellitare Sentinel-2 per l'area test 03; i valori di area sono espressi in m². SE = standard error; CI = confidence interval; PA = producer's accuracy; UA = user's accuracy

MATRICE DI ERRORE (pixel count)

		Dati di riferimento			Totale
		1	2	3	
Dati classificazione	1	374	8	78	460
	2	0	566	0	566
	3	10	0	185	195
Totale		384	574	263	1221

MATRICE DI ERRORE (area based)

		Dati di riferimento			Area	Wi
		1	2	3		
Dati classificazione	1	0.3624	0.0078	0.0756	1864000	0.4457
	2	0	0.4093	0	1711500	0.4093
	3	0.0074	0	0.1376	606500	0.1450
Totale		0.3698	0.417	0.2132	4182000	
Area		1546616	1743917	891467	4182000	

Classe	1	2	3
SE	0.0084	0.0027	0.0081
SE area	35254	11374	34032
95% CI area	69099	22292	66702
PA [%]	98.0	98.1	64.5
UA [%]	81.3	100	94.9
Kappa hat	0.70	1	0.93

Overall accuracy [%]	90.9
Kappa hat classification	0.86

Tabella 18: matrice di errore relativa alla classificazione SVM basata sull'elaborazione della rete neurale VDSR per l'area test 03; i valori di area sono espressi in m². SE = standard error; CI = confidence interval; PA = producer's accuracy; UA = user's accuracy

MATRICE DI ERRORE (pixel count)

		Dati di riferimento			Totale
		1	2	3	
Dati classificazione	1	91755	288	19758	111801
	2	50	138957	225	139232
	3	1803	0	49500	51303
Totale		93608	139245	69483	302336

MATRICE DI ERRORE (area based)

		Dati di riferimento			Area	Wi
		1	2	3		
Dati classificazione	1	0.3904	0.0012	0.0841	1934853	0.4756
	2	0.0002	0.4220	0.0007	1719899	0.4228
	3	0.0036	0	0.0980	413124	0.1016
Totale		0.3941	0.4232	0.1827	4067876	
Area		1603069	1721486	743321	4067876	

Classe	1	2	3
SE	0.0006	0.0001	0.0006
SE area	2247	358	2240
95% CI area	4404	701	4391
PA [%]	99.1	99.7	53.6
UA [%]	82.1	99.8	96.5
Kappa hat	0.70	0.99	0.96

Overall accuracy [%]	91.0
Kappa hat classification	0.85

10. Conclusioni e commenti

L'aspetto su cui si è voluta porre l'attenzione in questo studio è la possibilità di sfruttare la tecnologia del deep learning, e in particolare della rete neurale VDSR, per ottenere un prodotto a risoluzione migliorata a partire da immagini satellitari gratuite a bassa risoluzione (10 m), basandosi sulle informazioni imparate dalla rete da dati ad alta risoluzione (o.d.g. cm) acquisiti da drone. Lo scopo di questo miglioramento di qualità dell'immagine è l'applicazione nel campo del monitoraggio della vegetazione, per cui riveste particolare importanza l'utilizzo di dati multispettrali dai quali calcolare indici o elaborare classificazioni.

I risultati ottenuti nel capitolo precedente mostrano l'esito positivo dell'applicazione della rete neurale convoluzionale VDSR utilizzando come immagini di training i dati acquisiti con drone e come immagine di input su cui attivare la rete il dato satellitare. Questo risultato è una base per incentivare specifici studi per ottimizzare la rete neurale per questa applicazione, mentre sino ad ora la ricerca nel campo della Super Risoluzione si è concentrata sul miglioramento di immagini RGB di dettaglio.

Per quanto riguarda il trattamento di dati multispettrali, aspetto problematico come mostrato in letteratura [30], si è affrontato il problema del maggior numero di bande rispetto a un'immagine RGB elaborando una composizione a tre bande alla volta, unendole in un secondo momento se necessario. Questo è stato possibile in quanto l'obiettivo dell'analisi multispettrale era il calcolo dell'indice NDVI, ottenibile a partire dalla banda Red e NIR. Un aspetto negativo, sempre inerente al dato multispettrale, è la necessità di convertire il dato dalla codifica a 12 bit/px a 8 bit/px; questo permette di effettuare il miglioramento di risoluzione spaziale a discapito della risoluzione radiometrica.

I test effettuati sulle aree di diversa estensione mettono in evidenza la diversa possibilità di fruizione dell'immagine elaborata con la rete VDSR al variare dell'area di indagine. Per una porzione di territorio di dimensione dell'ordine di grandezza del centinaio di metri di lato, come per il test 01, il dato acquisito con drone ha una risoluzione e un dettaglio che le altre immagini non riescono a rappresentare. Per un'area di circa 25 ettari, esemplificata dal test 02, il miglioramento ottenuto con l'elaborazione con rete neurale VDSR viene esaltato; l'estensione risulta abbastanza elevata per valutare l'utilizzo del drone con attenzione, ma non così ampia da accettare il dettaglio dell'immagine satellitare. In questo ambito l'utilizzo della rete neurale mette in risalto in modo più marcato i bordi degli elementi inquadrati rendendoli più facilmente

riconoscibili. Per una zona di analisi di dimensione dell'ordine di grandezza di alcuni km di lato o maggiore, come si può vedere nel test 03, l'elaborazione con rete neurale VDSR offre un miglioramento, ma il dettaglio richiesto dallo studio può essere soddisfatto anche dall'utilizzo dell'immagine satellitare originale.

Un aspetto determinante nell'applicazione del deep learning, da valutare attentamente in combinazione con il miglioramento dell'immagine che si vuole ottenere, è la potenza di calcolo richiesta per eseguire le elaborazioni. Il tempo di elaborazione sia per il training della rete neurale, sia per la sua attivazione, risulta non trascurabile se non si dispone di un'attrezzatura adeguata. Per fare un esempio, il training per allenare la rete VDSR utilizzata per le analisi di questo studio sarebbe durato una decina di giorni su un computer portatile commerciale nella media con processore Intel Core i5 5th Generation e 8 Giga di memoria RAM. Inoltre, ottenendo un'immagine di dimensioni in pixels maggiori di quella satellitare, si deve tenere in considerazione che anche il tempo di calcolo per elaborazioni successive, come per esempio una classificazione, viene incrementato.

Il fattore tempo incide negativamente sulla valutazione dell'utilizzo pratico della rete neurale, in particolare se confrontato con altri metodi di miglioramento della risoluzione di un'immagine come può essere l'interpolazione.

Infatti, un primo approccio più semplice per affrontare il problema della Single Image Super Resolution è l'interpolazione, ottenibile tramite diverse formulazioni, che permette di ottenere buoni risultati e dunque può essere utilizzato come riferimento per un confronto. Tuttavia, l'interpolazione è soggetta a restrizioni geometriche poiché si basa su informazioni relative a uno spazio limitato limitrofo dell'immagine. Utilizzando una rete neurale convoluzionale invece è possibile migliorare il dato attraverso informazioni teoriche ricavate da un campione numeroso di dati reali. [30]

Dai test effettuati risulta evidente l'analogia dei risultati ottenuti con interpolazione bicubica e con rete neurale VDSR. Questo aspetto conferma il corretto funzionamento della rete, ma evidenzia come i due metodi offrano prestazioni paragonabili.

La Figura 46 mostra il confronto tra le immagini ottenute con l'interpolazione bicubica e con la rete neurale VDSR per il test 01; le dimensioni dell'immagine di output sono impostate allo stesso valore per entrambi i metodi e sono state calcolate le metriche di qualità dell'immagine ottenute tramite il confronto con il dato da drone ad alta risoluzione per una valutazione quantitativa.



Figura 46: Confronto tra interpolazione bicubica e rete neurale VDSR per il Test 01

Per quanto riguarda la qualità dell'immagine che si può ottenere tramite metodi di miglioramento, è importante mettere in evidenza la notevole differenza di risoluzione presente tra l'immagine da drone, con risoluzione di qualche centimetro, e l'immagine satellitare Sentinel-2, pari a 10 m. La differenza di elementi che le due risoluzioni riescono a rappresentare condiziona notevolmente il risultato infatti, persino riscalando l'immagine ad alta risoluzione del drone alla dimensione dell'immagine satellitare, il dato rappresentato non coincide. Questo si riflette nel risultato che mostra un miglioramento di risoluzione rispetto all'immagine satellitare, ma è ben distante dalla rappresentazione di dettaglio dell'immagine da drone.

Lo sviluppo tecnologico assume oggi un ruolo fondamentale e di notevole aiuto alle applicazioni di monitoraggio ambientale. È bene tuttavia ricordare l'importanza dell'affiancamento dei dati di monitoraggio a terra per la calibrazione e validazione del risultato ottenuto così come l'aspetto imprescindibile di interpretazione critica del dato da parte di personale esperto per non perdere la conoscenza profonda del fenomeno che si sta analizzando.

11. Allegati

11.1. Schede tecniche camere multispettrali per drone

11.1.1. Slant Range

SLANT RANGE		
Specification	4P	4P+
Spatial Resolution (GSD @ 100 m AGL)	4.0 cm	2.2 cm
Spectral Channels	6	6
Spectral Band Positions	470, 550, 620, 650, 710, 850 nm*	470, 520, 620, 650, 715, 850 nm*
Available Spectral Range	410 – 950 nm*	410 – 950 nm*
Available Bit Depth	8 – 10 bit	8 – 12 bit
Sensor Dynamic Range	55.8 dB	69.2 dB
Sensor Type	Si CMOS	Si CMOS
Shutter Type	Global	Global
Processor Type	Snapdragon 801	Snapdragon 801
Processor Speed	Quad-Core 2.26 GHz	Quad-Core 2.26 GHz
On-Board RAM	2 GB	2 GB
Positioning & Pointing	GPS / IMU + EKF	GPS / IMU + EKF
Recommended Image Overlap	20% **	20% **
160 Acre Survey @ 2.0 cm GSD, 12 m/s (rotary)	50 minutes	32 minutes
160 Acre Survey @ 120 m AGL, 20 m/s (fixed)	16 minutes	18 minutes
160 Acre Survey @ 120 m AGL, 12 m/s (rotary)	22 minutes	24 minutes
Available Data Layers	All SlantView	All SlantView
In-Flight Data	Available with DJI SKYPORT Integration	Available with DJI SKYPORT Integration
Precision Navigation Module	Available	Available
Removable SD Card Storage (up to 128 GB)	64 GB (4 hours)	64 GB (2 hours)
Output Formats	KML, SHP, GeoTIFF	KML, SHP, GeoTIFF

Size, Vegetation Sensor	14.6 x 6.9 x 5.7 cm	14.6 x 6.9 x 5.7 cm
Size Ambient Illumination Sensor	8.1 x 3.5 x 1.7 cm	8.1 x 3.5 x 1.7 cm
Weight	350 g	350 g
Power	12 W @ 9.0 – 28.0 VDC	14 W @ 9.0 – 28.0 VDC
Aircraft Compatibility	Many	Many

11.1.2. Mapir Survey 3

MAPIR SURVEY 3	
Image Resolution	12 MegaPixel (4,000 x 3,000 px)
Image Format	RAW+JPG, JPG (RAW is 12bit per channel, JPG is 8bit per channel)
Video Resolution	2160p24, 1440p30, 1080p60, 720p60
Video Format	MP4 (H.264 Codec)
Lens Optics Options	Survey3W: 87° HFOV (19mm) f/2.8 Aperture, -1% Extreme Low Distortion (Non-Fisheye) Glass Lens Survey3N: 41° HFOV (47mm) f/3.0 Aperture, -1% Extreme Low Distortion (Non-Fisheye) Glass Lens
Filter Transmission Options	Visible Light (RGB): 375nm - 650nm OCN (Orange+Cyan+NIR): 490nm/615nm/808nm RGN (Red+Green+NIR): 550nm/660nm/850nm NGB (NIR+Green+Blue): 475nm/550nm/850nm Red-Edge (RE): 725nm Near Infrared (NIR): 850nm
Ground Sample Distance (GSD)	Survey3W: 5.5 cm/px (2.17in/px) at 120 m (~400 ft) AGL Survey3N: 2.3 cm/px (0.9in/px) at 120 m (~400 ft) AGL
Sensor	Sony Exmor R IMX117 12MP (Bayer RGB)
Chipset	Novatek NTK96663
GPS/GNSS (External)	Standard: u-blox UBX-G7020-KT Advanced: u-blox NEO-M8
Capture Speed	RAW+JPG: 2.75 Seconds / Photo. JPG: 1.5 Seconds / Photo
Remote Trigger	PWM via HDMI Port (see below)
Battery	Removable Li-ion (1200mAh) (Not Required When USB Powered)
Power Draw	5.2V 0.2A (Without Battery), 5.2V 0.4A (With Battery)
Weight	50g (1.8 oz) (Without Battery), 76g (2.7 oz) (With Battery)
Dimensions	59 x 41.5 x 36mm (Length x Height x Depth)
Memory Storage	Micro SD (Up To 128GB Card) (64GB Card ≈ 15,000 JPG, 2,200 RAW+JPG)

White Balance	Auto / Daylight / Cloudy / Tungsten / Fluorescent / Blue / Light Blue / Red / Light Red / Custom*
Capture Interval	0.5sec, 1sec, 2sec, 5sec, 10sec, 30sec, 1min, 5min, 10min, 30min, 1hour, 2hours, 6hours, 12hours, 24hours
ISO	50 / 100 / 200 / 400, Auto
Shutter Speed (s)	1/2000, 1/1000, 1/500, 1/250, 1/125, 1/90, 1/60, 1/30, 1/15, 1/8, 1, 2, 3, 5, 10, 15, 20, 30, 60, Auto
Exposure	+2.0 / +1.67 / +1.33 / +1.0 / +0.67 / +0.33 / +0.0 / -0.33 / -0.67 / -1.0 / -1.33 / -1.67 / -2.0
Metering	Average / Center / Spot
Color	Normal / Black and White / Sepia / Vivid
Sharpness	Strong / Medium / Soft
Capture Mode	Single / 3 Sequence / 10 Sequence
LCD	2.0" Ultra Bright Color LCD Touch Screen
Video Out	HD 1080p (HDMI Micro), SD 480p (Optional USB FPV Cable)
TV Mode	NTSC / PAL
Power Input	Battery, USB (Micro-A Cable Included, Optional Micro USB FPV Cable)
Auto Power On (When Power Applied to USB Port)	ON / OFF
OSD Language	English, French, Spanish, Portuguese Brazil, Dutch, Czech, Polish, German, Italian, Chinese, Russian, Japanese, Korean
Frequency	60Hz / 50Hz
OSD Display	ON / OFF
Date Stamp	ON / OFF
Sound	ON / OFF
Quick Capture	ON / OFF
Auto Power Off	OFF / 1min / 3min / 5min / 10min / 15min / 30min / 60min
Auto Sleep LCD	1min / 3min / 5min / OFF
Vertical Rotate	ON / OFF
Included Accessories	USB GPS Receiver, Battery, Lens Cap, USB Charge Cable, Manual

11.1.3. Parrot Sequoia

PARROT SEQUOIA	
TELECAMERA RGB DA 16 MPIX	
Definizione	4608 x 3456 pixel
HFOV	63.9°
VFOV	50.1°
DFOV	73.5°
4 1,2 MPIX GLOBAL SHUTTER SINGLE-BAND-KAMERAS	
Definizione	1280 x 960 pixel
HFOV	61.9°
VFOV	48.5°
DFOV	73.7°
4 BANDE SEPARATE	
Verde	550 BP 40
Rosso	660 BP 40
Red Edge	735 BP 10
Infrarosso vicino	790 BP 40
DIMENSIONI E CARATTERISTICHE	
Dimensioni	59 mm x 41 mm x 28 mm
Peso	72 g (2.5 oz)
Frequenza di cattura	Fino a 1 fps
Memoria integrata	64 GB
IMU e magnetometro	
Potenza	5 W (~12 W massimo)
SENSORE DI LUMINOSITÀ	
4 sensori spettrali (stessi filtri che per il corpo centrale)	
GPS	
IMU e magnetometro	
Dimensioni	47 mm x 39,6mm x 18,5mm

Peso	35 g (1.2 oz)
Potenza	1 W

11.1.4. Maia WV

MAIA WV	
Physical Characteristics	<p>Width 99 mm</p> <p>Height 129 mm</p> <p>Depth 47 mm</p> <p>Fixing 4 fixing holes M3x0.5-6H</p> <p>Weight 420 g</p>
Sensors	<p>1 RBG Bayer pattern Sensor (MAIA WV)</p> <p>8 CMOS Mono-Chromatic sensors with Bandpass filters (MAIA WV)</p> <p>Or</p> <p>9 CMOS Mono-Chromatic sensors with Bandpass filters (MAIA S2)</p> <p>Array 3x3 – Centre to centre: 25 mm</p> <p>Resolution: 1.2Mpixel (1280x960) each</p> <p>Type: Global Shutter</p> <p>Pixel size: 3.75 μm x 3.75 μm</p>
Optics	<p>Lens Fixed focus</p> <p>Focal length: 7.5 mm</p> <p>Open f/#2.8</p> <p>FOV: 35° HFOV; 26° VFOV; 43° DFOV</p>
Exposure	<p>Type: Manual / Automatic / Automatic based on Max Time Exposure</p> <p>Start simultaneous for each sensor</p> <p>Exposure Time: 0.1 ms - 50 ms</p> <p>Typical exposure time: 1ms</p>
Acquisition	<p>Type: Single shot / Continuous with external trigger / Continuous at fixed-time interval</p> <p>Max frame rate: 3 frames/sec with RAW 10bit and RAW 12bit; 6 frames/s with RAW 8bit</p>
File format	RAW 8 bit

	<p>RAW 10 bit</p> <p>RAW 12 bit</p>
Memory	<p>Type: Internal SSD</p> <p>Capacity: 120GB (standard); 250GB; 500GB (on demand)</p> <p>Image size: 21.2 MByte in RAW10 and RAW12</p> <p>11.8 MByte in RAW8</p>
Embedded data	<p>Exposure time for each sensor.</p> <p>Timestamp at the shot time.</p> <p>Time, position, speed, fix GNSS.</p>

11.1.5. Dji Phantom 4 Multispectral

DJI PHANTOM 4 MULTISPECTRAL	
Fotocamera	
Sensori	Sei sensori CMOS 1/2.9", incluso un sensore RGB per le immagini su luce visibile e cinque sensori monocromatici per l'acquisizione di immagini multispettrali. Ciascun sensore: Pixel effettivi 2,08 MP (2,12 MP in totale)
Filtri	Blu (B): 450 nm ± 16 nm Verde (G): 560 nm ± 16 nm Rosso (R): 650 nm ± 16 nm Red-Edge (RE): 730 nm ± 16 nm Vicino infrarosso (NIR): 840 nm ± 26 nm
Obiettivi	FOV (campo visivo): 62,7° Lunghezza focale: 5,74 mm (formato equivalente 35 mm: 40 mm), autofocus a ∞ Apertura: f/2.2
Intervallo ISO sensore RGB	200 – 800
Guadagno del sensore monocromatico	1 – 8x
Otturatore elettronico globale	1/100 – 1/20000 s (luce visibile); 1/100 – 1/10000 s (multispettrale)
Dimensione massima dell'immagine	1600×1300 (4:3.25)
Formato foto	JPEG (immagini luce visibile) + TIFF (immagini multispettrali)
File system supportati	FAT32 (≤ 32 GB); exFAT (> 32 GB)
Schede SD supportate	microSD con velocità di scrittura minima di 15 MB/s. Capacità: 128 GB. Classe 10 o standard UHS-1
Temperatura operativa	0 – 40 °C

11.2. Scheda tecnica camera iperspettrale per drone

SENOP HSC-2	
Spectral Range	500-900 nm
Spectral FWHM	5-15 nm
Spectral Step	0.1 nm
Spectral Bands	Up to 1000 (freely selectable)
Horizontal FOV	36.8°
Vertical FOV	36.8°
Image Sensor	CMOS
Dynamic Range	10/12 bit
Max Image Rate (frame/s)	74 (12 bit) 149 (10 bit)
Image Resolution	1024x1024
Exposure time	Adjustable
Memory	1 TB
Connections	GigE RJ-45 Mini-Displayport v 1.2 IO port with UART and 4GPIO pins MMCX for external GPS antenna
Weight	986 g
Dimensions (l x w x h)	199.5 mm x 130.9 mm x 97.2 mm
Positioning	GPS and BeiDou
Voltage supply	7-17 VDC
Internal Measurement Unit (IMU)	Gyroscope and 3 axis accelerometer
Adjustable optics	Focus distance: 30 cm - ∞
Live Use	External display can be attached
PC-software	Senop HSI-2
Data export	Standard ENVI
Connectivity	Open API

11.3. Codice Matlab rete VDSR

```
%% VDSR (Very-Deep Super-Resolution) per realizzare una Single
Image Super Image Super-Resolution %%
clear all
close all

%% LOADING TRAINING DATA %%
trainImagesDir = 'C:\Tesi\Matlab VDSR\data set\high res';
exts = {'.tif', '.jpg'};
pristineImages =
imageDatastore(trainImagesDir,'FileExtensions',exts);

% elencazione delle immagini
numel(pristineImages.Files)

%% PREPARE TRAINING DATA %%
% generazione di coppie di immagini: upsampled image e
corrispondente immagine dei residui
upsampledDirName = [trainImagesDir filesep 'upsampledImages'];
residualDirName = [trainImagesDir filesep 'residualImages'];

% helper function per preprocessare i dati di training:
% - 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,upsampledDirName,
residualDirName);

%% DEFINE PREPROCESSING PIPELINE FOR TRAINING SET %%
% creazione di un datastore di immagini dalla collezione di
input e dalla collezione dei residui calcolati;
% entrambi i datastore necessitano di una helper function
(matRead) per leggere i dati immagine dai dati files
upsampledImages =
imageDatastore(upsampledDirName,'FileExtensions','.mat','ReadFcn'
,@matRead);
residualImages =
imageDatastore(residualDirName,'FileExtensions','.mat','ReadFcn'
,@matRead);

% specificazione dei parametri per aumentare i dati di training
a disposizione (rotazione, riflessione in direzione x)
ang_dir = -10;
ang_analisi = 20;

augmenter = imageDataAugmenter( ...
    'RandRotation',@( ) (rand-0.5)*ang_analisi+ang_dir, ...
```

```

    'RandXReflection',true);

% estrazione random di porzioni (patch) dai datastore delle
immagini upsampled e dei residui;
% il processo prevede l'estrazione di un grande numero di
piccole porzioni da un'immagine più grande. Questo permette di
ottenere un maggior numero di dati da usare per il training
patchSize = [41 41];
patchesPerImage = 128;
dsTrain =
randomPatchExtractionDatastore(upsampledImages,residualImages,pa
tchSize, ...

'DataAugmentation',augmenter,'PatchesPerImage',patchesPerImage);

% preview delle letture dal datastore
inputBatch = preview(dsTrain);
disp(inputBatch)

%% SET UP VSDR LAYERS %%
% Image Input Layer: opera sui patches delle immagini.
% la dimensione del patch è basata sul campo ricettivo della
rete, ossia la regione dello spazio dell'immagine che condiziona
la risposta del layer più superficiale della rete.
% Per una rete con D layers convoluzionali, il campo ricettivo è
di dimensione (2D+1)-by-(2D+1).
% VSDR ha 20 levels convoluzionali, quindi il campo ricettivo ha
dim 41x41.
% Il layer di input accetta immagini con un solo canale, quello
della luminanza.
networkDepth = 20;
firstLayer = imageInputLayer([41 41
1],'Name','InputLayer','Normalization','none');

% 2D Convolutional Layer, contiene 64 filtri di dimensione 3x3.
% La dimensione delle mappe dopo ogni convoluzione è mantenuta
uguale a quella di input "tamponando" con zeri.
% Il metodo di He inizializza i pesi a valori casuali in modo da
introdurre l'asimmetria nell'insegnamento neurale.
% ReLU Layer: introduce non linearità nella rete.
convLayer = convolution2dLayer(3,128,'Padding',1, ...

'WeightsInitializer','he','BiasInitializer','zeros','Name','Conv
1');

reluLayer = reluLayer('Name','ReLU1');

% Middle Layer, contiene 18 layer alternando strati di unità
lineari convoluzionali e rettificati. Ogni layer convoluzionale
contiene 64 filtri di dimensione 3x3x64, dove un filtro opera in
una regione spaziale di 3x3 su 64 canali.
% ReLU Layer: introduce non linearità nella rete.
middleLayers = [convLayer reluLayer];
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(layerNumber)]);
    middleLayers = [middleLayers convLayer relLayer];
end

% Convolutional Layer, singolo filtro 3x3x64 che ricostruisce
l'immagine
convLayer = convolution2dLayer(3,1,'Padding',[1 1], ...
    'WeightsInitializer','he','BiasInitializer','zeros', ...
    'NumChannels',128,'Name',[ 'Conv' num2str(networkDepth)]);

% Ultimo leyer, è un layer di regressione che calcola lo scarto
quadratico medio tra l'immagine dei residui e la stima della
rete.
finalLayers = [convLayer
    regressionLayer('Name','FinalRegressionLayer')];

% Concatena tutti i layers per formare la rete VDSR
layers = [firstLayer middleLayers finalLayers];

% Helper function come alternativa per creare la rete VDSR.
layers = vdsrLayers;

%% SPECIFY TRAINING OPTIONS %%
% SGDM Stochastic Gradient Descent with Momentum optimization
% La funzione 'trainingOptions' permette di specificare le
impostazioni iperparametriche del SGDM;
% Il rate di insegnamento è posto inizialmente pari a 0.1 e
viene fatto decrescere di un fattore 10 ogni 10 epochs. Si
ripete per 100 epochs.
% Questo richiede molto tempo; per accelerare si specifica un
rate di insegnamento più alto. Tuttavia, questo potrebbe portare
a una crescita incontrollata della rete e a un insuccesso del
training.
% Per mantenere il gradiente in un range significativo si impone
un valore soglia di 0.01 e si specifica l'utilizzo del metodo
L2-norm per il gradiente.
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 %%
% la funzione 'trainNetwork' permette di effettuare
l'allenamento della rete.
% do Train = false per caricare una rete precedentemente
allenata, = true per allenare 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-15-Aug-2020-17-47-47-Epoch-100-
ScaleFactors-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
tecniche tradizionali di processamento delle immagini (es:
interpolazione bicubica)
exts = {'.tif'};
dir = 'C:\Tesi\Matlab VDSR\data set\high res\test\';
filename = [dir,'test_rivoira_01.tif'];
Ireference = imread(filename);
Ireference = im2double(Ireference);
figure (5)
imshow(Ireference)
title('High-Resolution Reference Image')

%% LOADING LOW-RESOLUTION IMAGE %%
dir = 'C:\Tesi\Matlab VDSR\data set\low res\';
filename = [dir,'test_rivoira_01_S2.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 ad alta risoluzione di riferimento, se presente,
altrimenti pari a quelle dell'immagine a bassa risoluzione di
input
% [nrows,ncols,np] = size(Ireference);
[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 dei canali 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;

% concatenazione della componente di luminanza ottenuta con i
componenti ingranditi dei colori per convertire l'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
% metriche di qualità dell'immagine per confrontare
quantitativamente le immagini ad alta risoluzione ottenute con
interpolazione bicubica e con VDSR. L'immagine di riferimento è
l'immagine originale ad alta risoluzione.
% PSNR = peak signal-to-noise ratio
% qualità migliore per valori più alti;
% SSIM = structural similarity index
% valutazione dell'impatto visivo di luminanza, contrasto e
struttura; più il valore tende a 1, più l'immagine testata
concorda con quella di riferimento;
% NIQE = naturalness image quality evaluator
% misura della qualità dell'immagine percettiva. Valori minori
indicano qualità maggiore;
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 = 1:4

```

```

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));

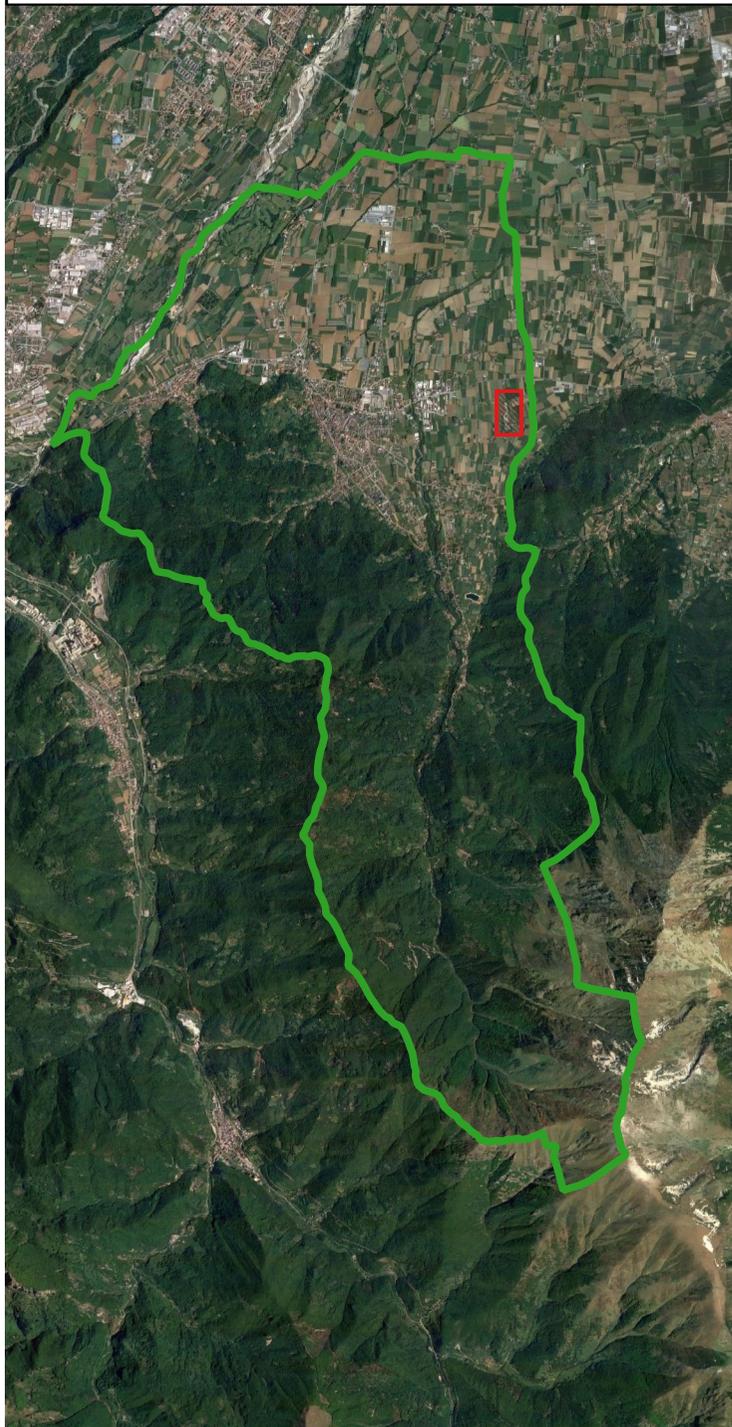
Ireference = imresize(Ireference, [nrows,ncols]);
vdsrPSNR = psnr(Ivdsr,Ireference)
vdsrSSIM = ssim(Ivdsr,Ireference)
vdsrNIQE = niqe(Ivdsr)
end

figure (41)
imshow(Ivdsr)
title('High-Resolution Image Obtained Using VDSR')

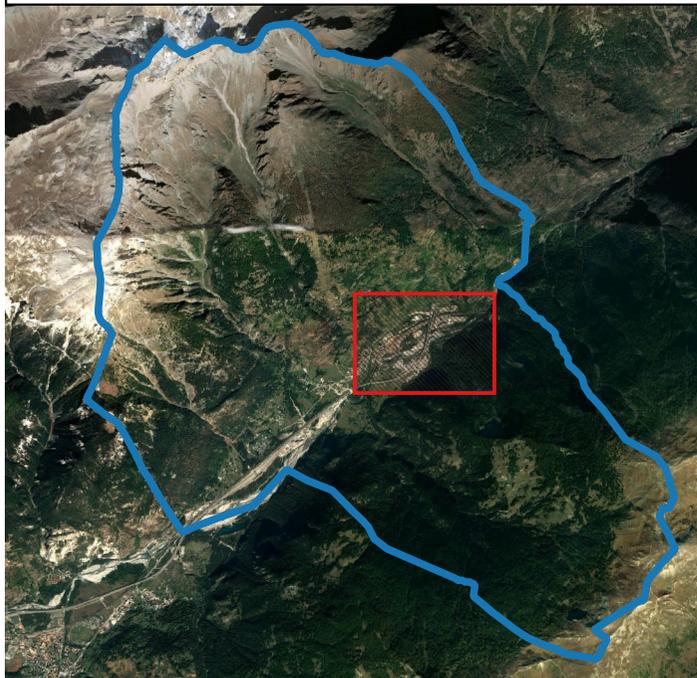
```

11.4. Elaborati grafici

Comune di Boves



Comune di Salbertrand



Comune di Grugliasco



T1

Ubicazione aree di studio

 Comune Salbertrand

 Comune Grugliasco

 Comune Boves

Google Satellite

 Area con acquisizioni

scala 1 : 100 000



0 1 2 3 4 km



 Comune Salbertrand

 Comune Grugliasco

 Comune Boves

 Province Piemonte

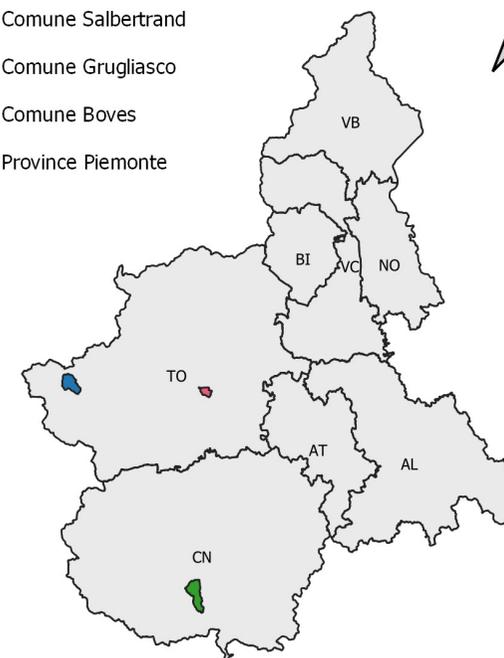


Immagine drone



Immagine satellite

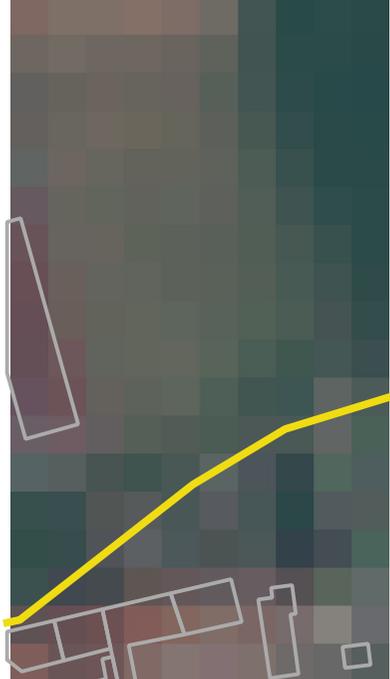
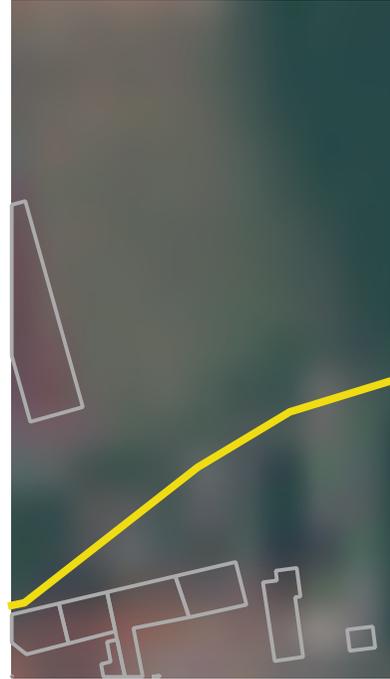


Immagine rete VDSR



T2

Confronto con BDTRE Test 01

BDTRE

— Strade

□ Edificato

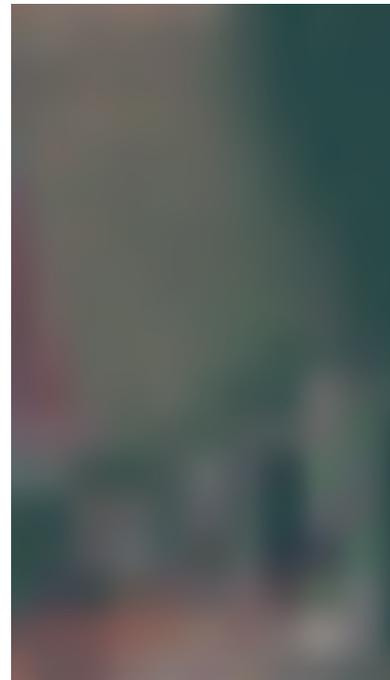
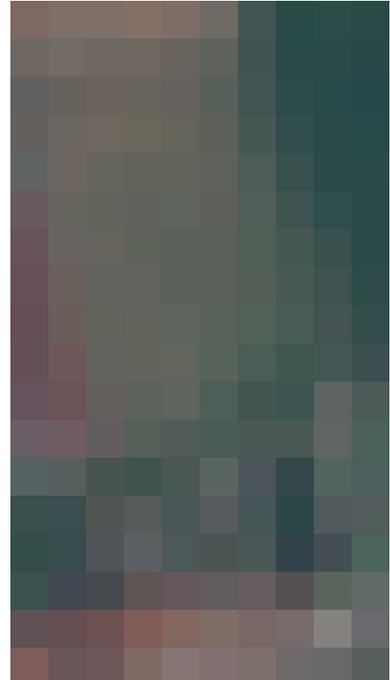
scala 1 : 2 000



0

50

100 m



RIVOIRA - DRONE 1m

□ area test

0 50 100 m



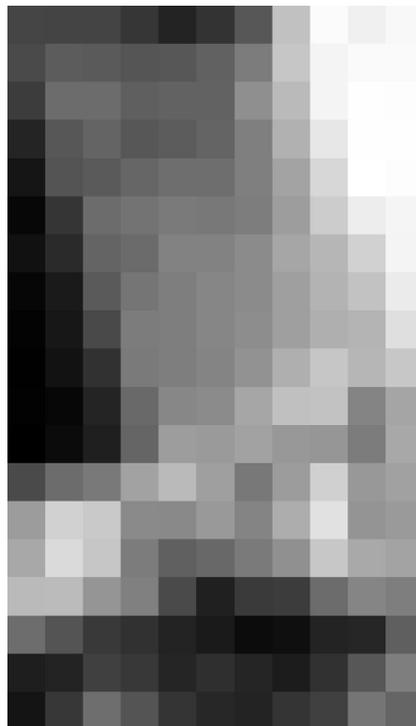
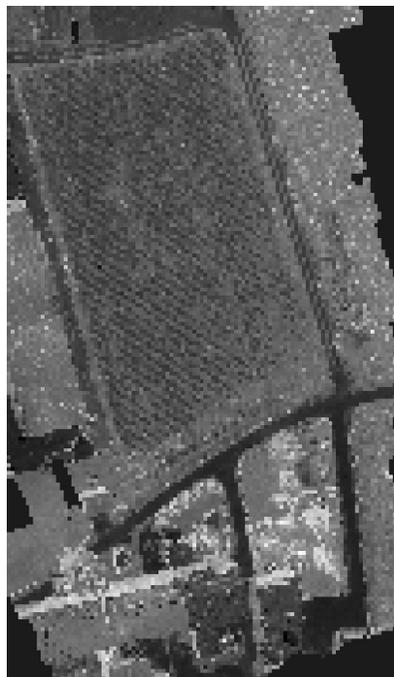
Immagine drone

Immagine satellite

Immagine rete VDSR

T3

Indice NDVI Test 01



Data di acquisizione:
26/07/2019

scala 1 : 2 000



0 50 100 m



RIVOIRA - DRONE 1m
multispettrale

NDVI_test01_drone

■ -0.1

□ 0.8

RIVOIRA - SATELLITE 10m
multispettrale

NDVI_test01_S2

■ 0.08

□ 0.8

RIVOIRA VDSR
multispettrale

NDVI_test01_VDSR

■ 0.05

□ 1



RIVOIRA - DRONE 1m

■ area test

0 50 100 m



T4

Confronto con BDTRE
Test 02

Immagine satellite bassa risoluzione

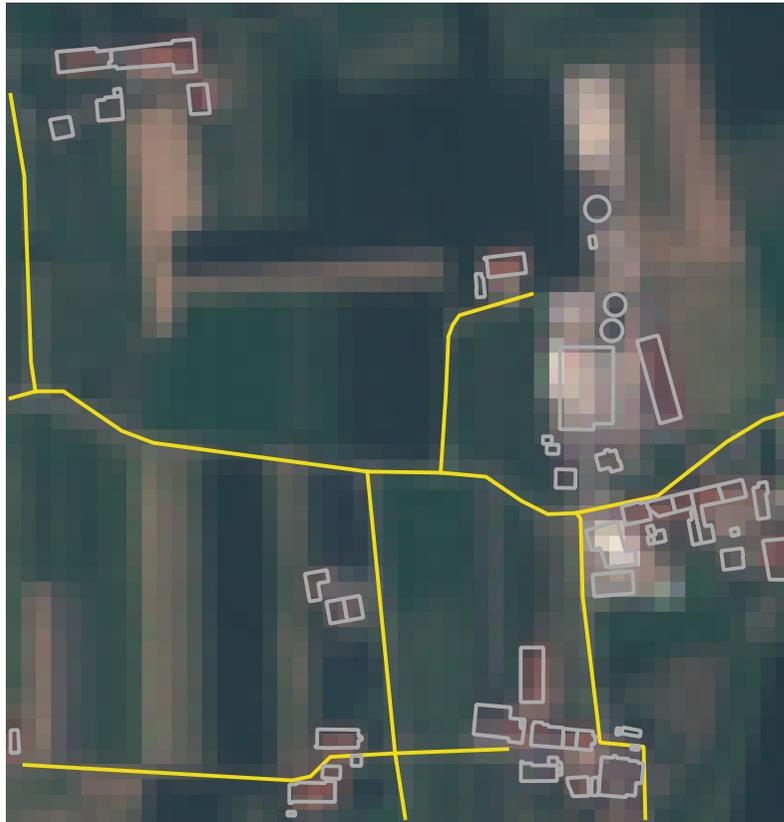


Immagine rete VDSR Super Risoluzione



BDTRE

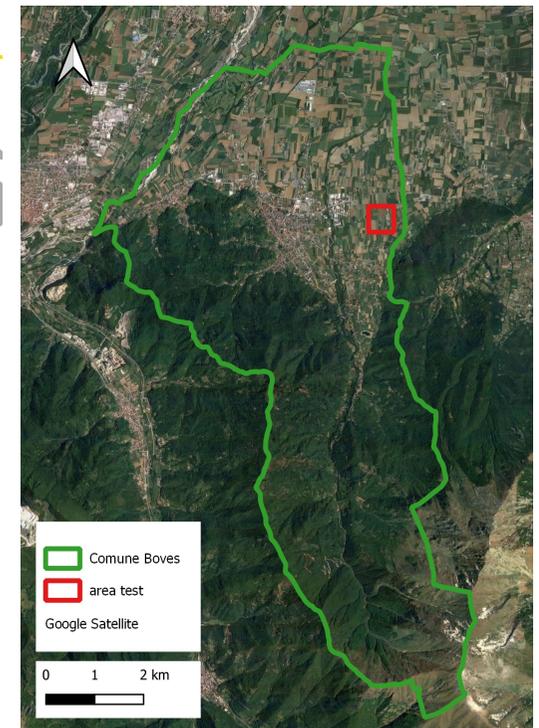
— Strade

□ Edificato

scala 1 : 5 000



0 100 200 m



□ Comune Boves

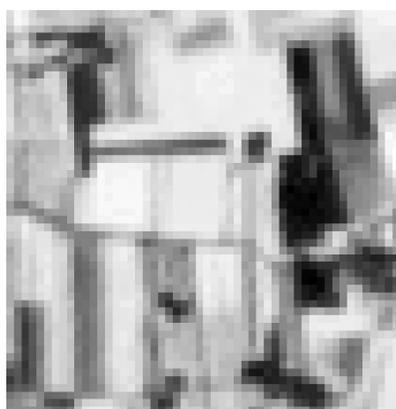
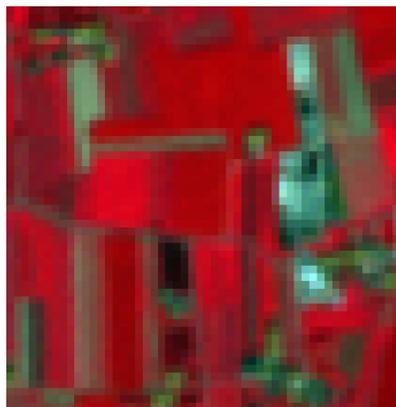
□ area test

Google Satellite

0 1 2 km

Immagine satellite bassa risoluzione

Immagine rete VDSR Super Risoluzione



RIVOIRA SATELLITE 10m
multispettrale
NDVI_test02_S2
■ 0.03
□ 0.8

RIVOIRA VDSR
multispettrale
NDVI_test02_VDSR
■ 0.03
□ 1

T5

Indice NDVI Test 02

In alto:
visualizzazione RGB a falsi colori
(NIR / Red / Green)

In basso:
banda singola dell'indice NDVI

scala 1 : 10 000

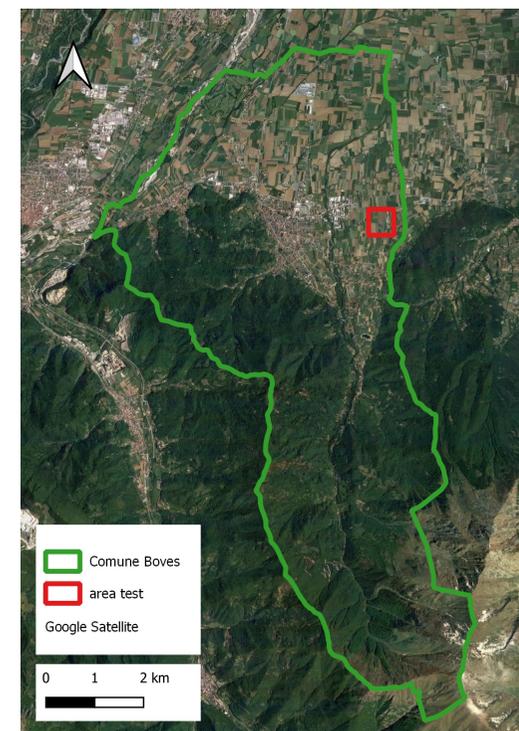
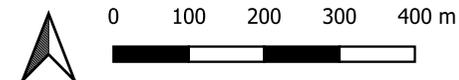
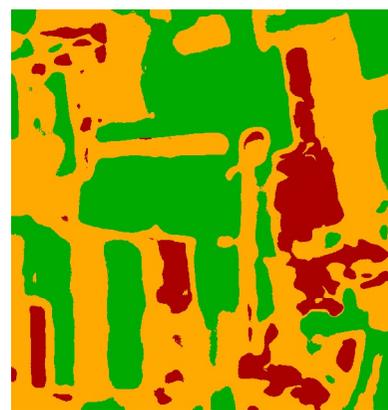
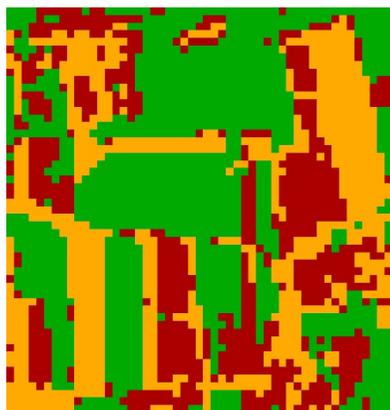


Immagine satellite bassa risoluzione



Immagine rete VDSR Super Risoluzione



T6

Classificazione Test 02

Classificazione SVM

-  1 - Urbanizzato
-  2 - Vegetazione
-  3 - Suolo

scala 1 : 10 000



0 100 200 300 400 m



-  Comune Boves
 -  area test
- Google Satellite

0 1 2 km



Immagine satellite bassa risoluzione

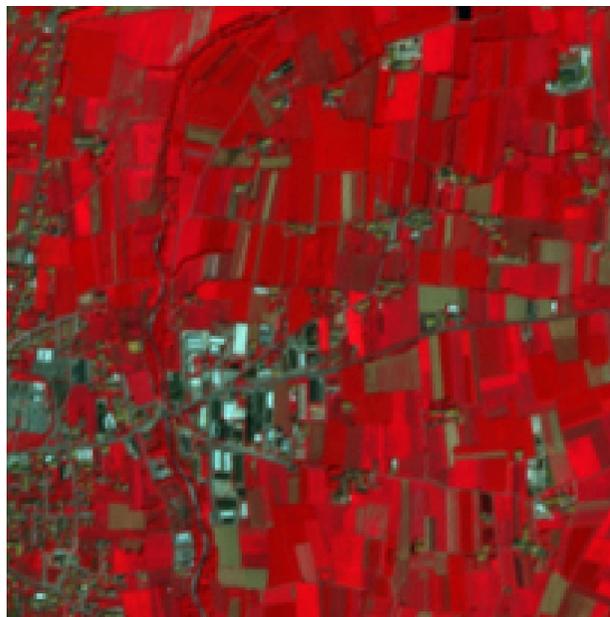


Immagine rete VDSR Super Risoluzione



T7

Indice NDVI Test 03

In alto:
visualizzazione RGB a falsi colori
(NIR / Red / Green)

In basso:
banda singola dell'indice NDVI

scala 1 : 25 000



0 0.25 0.5 0.75 1 km

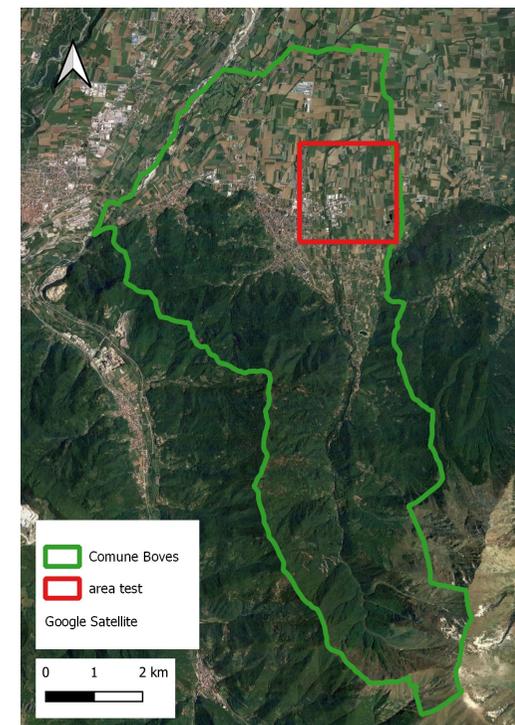
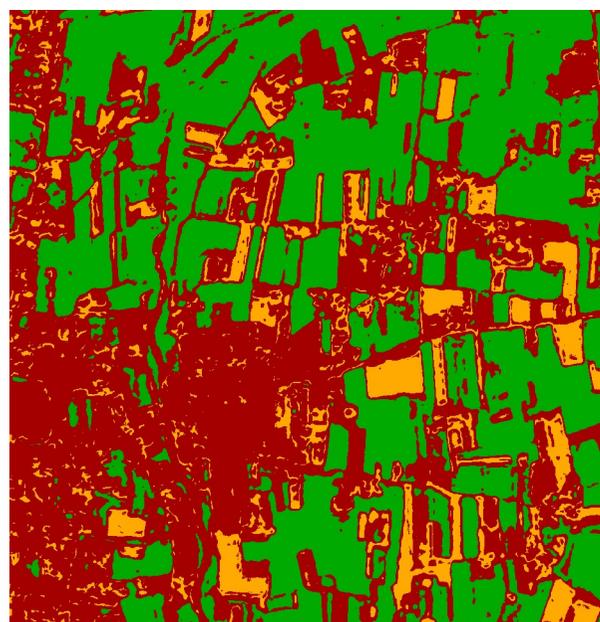
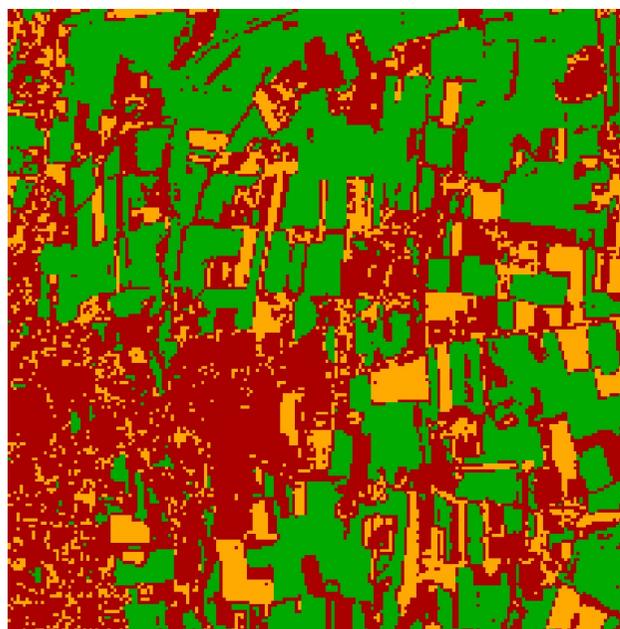


Immagine satellite bassa risoluzione



Immagine rete VDSR Super Risoluzione



T8

Classificazione Test 03

Classificazione SVM

1 - Urbanizzato

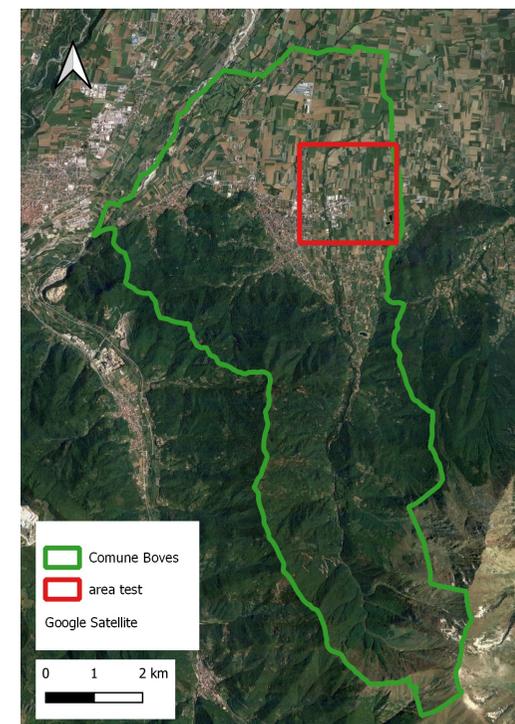
2 - Vegetazione

3 - Suolo

scala 1 : 25 000



0 0.25 0.5 0.75 1 km



12. Bibliografia

- [1] A. Matese *et al.*, “Intercomparison of UAV, aircraft and satellite remote sensing platforms for precision viticulture,” *Remote Sens.*, vol. 7, no. 3, pp. 2971–2990, 2015, doi: 10.3390/rs70302971.
- [2] K. Whitehead and C. H. Hugenholtz, “Remote sensing of the environment with small unmanned aircraft systems (UASs), part 1: a review of progress and challenges,” *J. Unmanned Veh. Syst.*, vol. 02, no. 03, pp. 69–85, 2014, doi: 10.1139/juvs-2014-0006.
- [3] D. Stroppiana *et al.*, “Estimating crop density from multi-spectral uav imagery in maize crop,” *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci. - ISPRS Arch.*, vol. 42, no. 2/W13, pp. 619–624, 2019, doi: 10.5194/isprs-archives-XLII-2-W13-619-2019.
- [4] S. Manfreda *et al.*, “On the use of unmanned aerial systems for environmental monitoring,” *Remote Sens.*, vol. 10, no. 4, 2018, doi: 10.3390/rs10040641.
- [5] “Copernicus Open Access Hub.” <https://scihub.copernicus.eu/>.
- [6] “ESA Sentinel online.” <https://sentinel.esa.int/web/sentinel/home>.
- [7] M. A. Boon and S. Tesfamichael, “Wetland vegetation integrity assessment with low altitude multispectral UAV imagery,” *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci. - ISPRS Arch.*, vol. 42, no. 2W6, pp. 55–62, 2017, doi: 10.5194/isprs-archives-XLII-2-W6-55-2017.
- [8] T. V. Haavardsholm, T. Skauli, and A. Stahl, “Multimodal Multispectral Imaging System for Small UAVs,” *IEEE Robot. Autom. Lett.*, vol. 5, no. 2, pp. 1039–1046, 2020, doi: 10.1109/LRA.2020.2967301.
- [9] S. Nebiker and N. Lack, “Multispectral and thermal sensors on UAVs,” *GIM Int.*, vol. 30, no. 12, pp. 19–21, 2016.
- [10] “Slant Range.” <https://slanrange.com/>.
- [11] “MAPIR Survey3: Multi-Spectral Survey Cameras.” <https://www.mapir.camera/pages/survey3-cameras>.
- [12] “Parrot Sequoia.” <https://www.parrot.com/en/shop/accessories-spare-parts/other-drones/sequoia>.

- [13] "MAIA the multispectral camera." <https://www.spectralcam.com/>.
- [14] "Dji Phantom 4 Multispectral." <https://www.dji.com/it/p4-multispectral>.
- [15] C. L. Doughty and K. C. Cavanaugh, "Mapping coastal wetland biomass from high resolution unmanned aerial vehicle (UAV) imagery," *Remote Sens.*, vol. 11, no. 5, 2019, doi: 10.3390/rs11050540.
- [16] "SENOP." <https://senop.fi/industry-research/hyperspectral-imaging/>.
- [17] "Single Image Super-Resolution Using Deep Learning." <https://it.mathworks.com/help/images/single-image-super-resolution-using-deep-learning.html>.
- [18] "Deep Learning in MATLAB." <https://it.mathworks.com/help/deeplearning/ug/deep-learning-in-matlab.html>.
- [19] M. U. Müller, N. Ekhtiari, R. M. Almeida, and C. Rieke, "Super-resolution of multispectral satellite images using convolutional neural networks," vol. V, pp. 33–40, 2020, [Online]. Available: <http://arxiv.org/abs/2002.00580>.
- [20] C. Dong, C. C. Loy, K. He, and X. Tang, "Image Super-Resolution Using Deep Convolutional Networks," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 38, no. 2, pp. 295–307, 2016, doi: 10.1109/TPAMI.2015.2439281.
- [21] J. Kim, J. K. Lee, and K. M. Lee, "Accurate image super-resolution using very deep convolutional networks," 2016, doi: 10.1109/CVPR.2016.182.
- [22] and T. D. Grubinger, M., P. Clough, H. Müller, "The IAPR TC-12 Benchmark: A New Evaluation Resource for Visual Information Systems," *Proc. OntoImage 2006 Lang. Resour. Content-Based Image Retr.*, vol. 5, p. 10, 2006.
- [23] and J. S. He, K., X. Zhang, S. Ren, "Delving Deep into Rectifiers: Surpassing Human-Level Performance on ImageNet Classification," *Proc. IEEE Int. Conf. Comput. Vis.*, pp. 1026–1034, 2015.
- [24] Govoni Lorenzo, "Semplice architettura di rete neurale convoluzionale." <https://lorenzogovoni.com/architettura-di-rete-neurale-convoluzionale/>.
- [25] "List of Deep Learning Layers." <https://it.mathworks.com/help/deeplearning/ug/list-of-deep-learning-layers.html>.

- [26] F. Iqbal, A. Lucieer, and K. Barry, "Simplified radiometric calibration for UAS-mounted multispectral sensor," *Eur. J. Remote Sens.*, vol. 51, no. 1, pp. 301–313, 2018, doi: 10.1080/22797254.2018.1432293.
- [27] "Calibrating Images in MAPIR Camera Control Application." <https://www.mapir.camera/pages/calibrating-images-in-mapir-camera-control-application>.
- [28] C. Dong, C. C. Loy, and X. Tang, "Accelerating the super-resolution convolutional neural network," *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 9906 LNCS, no. August, pp. 391–407, 2016, doi: 10.1007/978-3-319-46475-6_25.
- [29] "Transfer Learning with Deep Network Designer." <https://it.mathworks.com/help/deeplearning/ug/transfer-learning-with-deep-network-designer.html>.
- [30] L. Liebel and M. Körner, "Single-image super resolution for multispectral remote sensing data using convolutional neural networks," *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci. - ISPRS Arch.*, vol. 41, no. June, pp. 883–890, 2016, doi: 10.5194/isprsarchives-XLI-B3-883-2016.
- [31] "BDTRE 2019 - Database GeoTopografico (dataset vettoriale)." <http://www.geoportale.piemonte.it/geocatalogorp/index.jsp>.
- [32] "Geoportale Regione Piemonte." <https://www.geoportale.piemonte.it/cms/>.
- [33] Luca Congedo, "Semi-Automatic Classification Plugin Documentation Release 4.8.0.1," 2016, [Online]. Available: <https://media.readthedocs.org/pdf/semiautomaticclassificationmanual-v4/latest/semiautomaticclassificationmanual-v4.pdf>.
- [34] N. Karasiak, "Dzetsaka Qgis Classification plugin." 2016, doi: 10.5281/zenodo.2552284.
- [35] "Deep Learning Tips and Tricks." <https://it.mathworks.com/help/deeplearning/ug/deep-learning-tips-and-tricks.html>.
- [36] "Deep Learning Onramp." <https://it.mathworks.com/learn/tutorials/deep-learning-onramp.html>.
- [37] "Enhance Multispectral Color Composite Images."

<https://it.mathworks.com/help/images/enhancing-multispectral-color-composite-images.html>.

- [38] "Find Vegetation in a Multispectral Image."
<https://it.mathworks.com/help/images/finding-vegetation-in-a-multispectral-image.html>.
- [39] M. Kawulok, S. Piechaczek, K. Hrynczenko, P. Benecki, D. Kostrzewa, and J. Nalepa, "On Training Deep Networks for Satellite Image Super-Resolution," *Int. Geosci. Remote Sens. Symp.*, no. Section 2, pp. 3125–3128, 2019, doi: 10.1109/IGARSS.2019.8899098.

