

DEEP LEARNING BASATO SU IMMAGINI DA DRONE PER LA SUPER RISOLUZIONE DI SCENE MULTISPETTRALI ACQUISITE DA SATELLITE

DEEP LEARNING BASED ON UAV DATA FOR SUPER RESOLUTION OF MULTISPECTRAL SATELLITES SCENES

M. Casabona^{a*}, A. Lingua^a, N. Grasso^a

^a Dipartimento di Ingegneria dell'Ambiente, del Territorio e delle Infrastrutture (DIATI), Politecnico di Torino, C.so Duca degli Abruzzi 24, 10129 Torino, Italy; marina.casabona@studenti.polito.it, andrea.lingua@polito.it, nives.grasso@polito.it;

PAROLE CHIAVE: Super Risoluzione, Deep Learning, UAV, satellite, immagini multispettrali

KEY WORDS: Super Resolution, Deep Learning, UAV, satellite, multispectral images

RIASSUNTO

Oggigiorno esistono numerose tecnologie di telerilevamento che permettono di acquisire immagini su estese porzioni di territorio; la scelta della piattaforma più adeguata va valutata in funzione della scala di applicazione, finalità dello studio e analisi dei costi. In questo contesto, in particolare nel caso in cui non prevalga l'utilizzo di una precisa piattaforma, può essere interessante combinare l'utilizzo di diverse tecnologie per sfruttare i punti di forza di ognuna. L'aspetto centrale dello studio è la valutazione della potenzialità della 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 neurale 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. Per raggiungere questo obiettivo vengono effettuati test su aree di differente estensione riguardanti un'area agricola nel Comune di Boves (CN), utilizzando per il training della rete neurale acquisizioni con drone inquadranti diverse tipologie di vegetazione. I risultati ottenuti incentivano lo sviluppo e l'approfondimento del metodo, sebbene l'effettiva applicazione su casi reali sia da valutare tenendo in considerazione anche altri aspetti, come potenza di calcolo richiesta e fattore tempo, in relazione ad altri metodi di miglioramento della risoluzione spaziale dell'immagine.

ABSTRACT

Nowadays different remote sensing technologies allow to acquire images over extended areas; the choice of the most suitable platform must be evaluated according to the scale of application, purpose of the study and cost analysis. In this frame, especially when the use of a specific platform does not prevail, it may be interesting to combine the use of different technologies to benefit from the strengths of each one. The main topic of this study is to evaluate the potentiality of deep learning technology, in particular the VDSR neural network, to obtain an improved resolution product starting from free low resolution satellite images (10 m), based on the information learned from high resolution data (cm) acquired by drone. The improved quality image is intended to be used for vegetation monitoring: in this context the use of multispectral data is important, helping in the calculations of indices or elaborations of classifications. To achieve this goal, tests are carried out on areas of different extension concerning an agricultural area near Boves (CN), using images acquired by drone, characterized by different types of vegetation, for training the neural network. The obtained results encourage further studies on this topic, although the actual application on real cases might be affected by other factors, like the required computing power and time factor compared to other methods of spatial resolution improvement of images.

ACRONIMI

VDSR Very Deep Super Resolution
SIRS Single Image Super-Resolution
CNN Convolutional Neural Network
SSIM Structural Similarity Index
PSNR Peak Signal-to-Noise Ratio
NIQE Naturalness Image Quality Avaluator
SVM Support Vector Machine
BDTRE Base Dati Territoriale di Riferimento degli Enti

OA Overall Accuracy
PA Producer's Accuracy
UA User's Accuracy
SE errore standard
CI intervallo di confidenza
 $\hat{\kappa}$ kappa di Cohen
NDVI Normalized Difference Vegetation Index

1. 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 (K. Whitehead, C. H. Hugenholtz, 2014).

Questa tecnologia trova applicazione in svariati ambiti, tra cui quello del monitoraggio ambientale (S. Manfreda *et al.*, 2018), permettendo di congiungere l'acquisizione di dati su un'area vasta con una risoluzione elevata e con la disponibilità di

informazioni multispettrali (D. Stroppiana *et al.*, 2019). 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 altre tecniche di Remote Sensing (Matese *et al.*, 2015).

In questo contesto si inserisce l'utilizzo del machine learning (Matrone *et al.* 2020; Pierdicca *et al.*, 2020), 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 (odg decine di metri) 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 comprende un'attenta pianificazione del volo e la conseguente elaborazione dei dati richiede fino a diversi giorni di lavoro, andando così ad 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-Atmosfera (Level-1C) o di riflettanza Bottom-Of-Atmosfera (Level-2A) (<https://sentinels.copernicus.eu/web/sentinel/missions/sentinel-2/data-products>).

Diverse analisi, soprattutto nell'ambito dell'agricoltura di precisione o per l'analisi della vegetazione e del suolo, che vengono condotte su dati satellitari, richiedono la valutazione del comportamento spettrale delle superfici nelle diverse bande dello spettro elettromagnetico.

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. Lo studio si concentra sul miglioramento della risoluzione di immagini satellitari secondo il principio della SISR. La Single Image Super-Resolution (SISR) mira a costruire un'immagine a risoluzione migliorata a partire da una singola immagine a minor risoluzione. Gli aspetti più problematici di questa procedura risiedono nella mancanza di componente ad alta frequenza nelle immagini a minor risoluzione, limitando così la qualità dell'immagine a risoluzione migliorata, e nella possibilità di ottenere diverse possibili immagini a partire da una singola immagine a minor risoluzione in ingresso (<https://it.mathworks.com/help/images/single-image-super-resolution-using-deep-learning.html>). Esistono diverse tecniche con cui si può ottenere il risultato della SISR; in questo studio si valuta l'efficacia del Deep Learning, in particolare della rete neurale convoluzionale VDSR (Very Deep Super Resolution). 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) (Müller *et al.*, 2020).

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 di 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. Con il lavoro presentato nei paragrafi a seguire si intende dunque effettuare un'analisi critica non dell'algoritmo VDSR stesso, sebbene adattato all'applicazione specifica, ma della sua efficacia in combinazione con la tipologia di dati trattati finalizzata all'utilizzo pratico al fine di definire l'ambito in cui la procedura studiata può essere competitiva con altri metodi esistenti. Il dato riveste perciò un ruolo centrale nell'analisi. In risposta all'esito positivo di questa fase di test si incentiva lo studio specialistico e mirato dell'algoritmo.

2. METODOLOGIA E DATI

2.1 Scelta operativa per la rete neurale VDSR

VDSR è una rete neurale convoluzionale CNN (Convolutional Neural Network) con lo scopo di relazionare immagini a maggiore e minore 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 a maggiore risoluzione e una a minor 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):

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

Una volta che la rete VSDR impara a calcolare l'immagine dei residui, è possibile ricostruire un'immagine a risoluzione migliorata sommando i residui stimati all'immagine scalata a minor risoluzione (<https://it.mathworks.com/help/images/single-image-super-resolution-using-deep-learning.html>). L'algoritmo viene perciò applicato solo al canale della luminanza (Y), mentre i canali della crominanza (Cb e Cr) sono aumentati di scala tramite interpolazione bicubica (C. Dong *et al.*, 2016).

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 (J. Kim *et al.*, 2016).

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 (J. Kim *et al.*, 2016).

Per i test presentati nei capitoli seguenti, è stata utilizzata la rete VDSR disponibile sul portale del software Matlab e supportata da diversi studi (J. Kim *et al.*, 2016; T. D. Grubinger *et al.*, 2006; J. S. He *et al.*, 2015). I tre componenti necessari per definire una rete neurale sono: layers della rete, dati di training e 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, in particolare 19 livelli costituiti da 64 filtri di dimensione 3x3 e un livello con singolo filtro 3x3x64 per la ricostruzione dell'immagine, e layers ReLU (Rectified Linear Unit), che introducono non linearità nel sistema imponendo una soglia che azzeri tutti i valori negativi consentendo di accelerare i tempi di training della rete.

Il data store con i dati di input viene rielaborato per essere correttamente analizzato dalla rete. In particolare, le immagini subiscono trasformazioni di ridimensionamento, in modo da corrispondere alle dimensioni attese dalla rete, e di rotazione, riflessione in direzione x e variazione di scala per aumentare la variabilità dei dati di training a disposizione.

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 (C. Dong *et al.*, 2016). Tali parametri permettono poi di elaborare qualsiasi immagine di cui si vuole migliorare la risoluzione, a prescindere dal fatto che l'area di studio rientri tra quelle riprese dal dataset di training. 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.

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 (<https://it.mathworks.com/help/deeplearning/ug/transfer-learning-with-deep-network-designer.html>).

Il training della rete neurale è influenzato da tre aspetti: dati di training, struttura della rete e 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. Gli aspetti analizzati e le impostazioni risultanti sono riassunti in Tabella 1.

Tabella 1. Impostazioni delle caratteristiche della rete neurale utilizzare nello studio

Aspetto analizzato	Impostazione
Risoluzione data set di training	1 m
Risoluzione immagine di test	10 m
Fattori di scala per le immagini di training	2, 3 e 4
Angolo di rotazione delle immagini di training	20°
Numero di immagini di training	479 immagini RGB da drone
Numero di filtri dei layer convoluzionali	128 filtri

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).

Le opzioni di training dell'algoritmo vengono mantenute inalterate.

2.2 Dati satellitari

Tra i numerosi programmi che si occupano di acquisizione di dati tramite satellite, è stato selezionato il dato fornito dai satelliti Sentinel del progetto europeo Copernicus dell'Agenzia Spaziale Europea (ESA) poiché distribuito ad accesso libero sul portale ESA – Copernicus Open Access Hub (<https://scihub.copernicus.eu/>). La gratuità del dato è un presupposto primario per l'utilità del metodo proposto, perciò le immagini acquisite dai satelliti Sentinel sono un buon punto di partenza dal quale sviluppare le analisi.

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 risoluzione radiometrica di 12 bit e con differenti risoluzioni spaziali. Ai fini dello studio vengono selezionate le bande con risoluzione spaziale di 10 m: Blue, Green, Red e NIR.

Il dato per il test viene estratto selezionando una porzione ridotta che include la zona di interesse. Il test sulle immagini RGB viene effettuato sull'immagine 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 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. Si rende perciò necessario scalare i valori dell'immagine satellitare per riportarli alla codifica in 8 bit per procedere con l'analisi.

2.3 Dati da drone

Per quanto riguarda il dato da drone, 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; tuttavia, oggigiorno sono disponibili diverse soluzioni commerciali (S. Nebiker and N. Lack, 2016).

Le diverse soluzioni attualmente presenti sul mercato utilizzate in questo studio, che si differenziano per risoluzione, numero di bande acquisite, intervallo spettrale, peso e prezzo, sono: Slant Range 4P, Mafir Survey 3, dji Phantom Multispectral. Le caratteristiche tecniche sono riassunte in Tabella 2.

Tabella 2. Confronto delle caratteristiche spettrali, geometriche ed economiche delle camere multispettrali per drone utilizzate nello studio

	SlantRange 4P+	MAPIR Survey3W	Dji Phantom 4 Multispectral (drone)
Intervallo spettrale (nm)	410 – 950	375 – 850	450 – 840
Numero di bande spettrali	6	3 (6 diverse combinazioni)	5
Sensore di luminosità	si	no	si
Risoluzione spaziale (GSD)	2.2 cm/px at 100 m AGL	5.5 cm/px at 120 m AGL	5.29 cm/px at 100 m AGL
Risoluzione radiometrica (bit)	8 – 12		
Dimensioni	146 x 69 x 57 mm	59 x 41.5 x 36 mm	289.5 x 289.5 x 196 mm
Peso	350 g	76 g	1 487 g
Costo	4 870 €	340 €	5 500 €

I dati da drone vengono utilizzati esclusivamente nella fase di training della rete neurale. Concluso il training si ottengono i parametri di ciascun layer della rete che consentono di utilizzarla come strumento operativo senza la necessità di disporre di immagini ad alta risoluzione dell'area di interesse.

2.4 Valutazione dell'accuratezza

Le valutazioni effettuate al fine di valutare il miglioramento di accuratezza che si può ottenere sono sia di tipo analitico 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.

2.4.1 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 (Peak Signal-to-Noise Ratio) e SSIM (Structural Similarity index) (L. Liebel and M. Körner, 2016).

L'indice SSIM 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.

Valori di PSNR più elevati indicano una qualità migliore, 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.

2.4.2 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 (<http://www.geoportale.piemonte.it/geocatalogorp/index.jsp>).

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.

2.4.3 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.

La classificazione selezionata è la classificazione Support Vector Machine (SVM), applicata alle immagini con la composizione di bande blue, green, red, NIR e indice NDVI; è una classificazione di tipo assistito e per l'area di studio si definiscono tre classi: Urbanizzato (1), Vegetazione (2) e Suolo (3). 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 avere una valutazione quantitativa dell'accuratezza della classificazione, tramite i descrittori Accuratezza Globale (Overall Accuracy OA), Accuratezza Produttore (Producer's Accuracy PA), Accuratezza Utente (User's Accuracy UA), viene calcolata la matrice di errore che permette inoltre di analizzare la distribuzione dell'errore tra le diverse classi e di determinare i principali indicatori statistici (errore standard SE, intervallo di confidenza CI e kappa di Cohen \hat{k}). Questa procedura viene effettuata sia per il dato satellitare sia per il dato ottenuto con la rete VDSR.

2.5 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:

$$NDVI = \frac{NIR-RED}{NIR+RED} \quad (2)$$

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.

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.

3. CASI STUDIO

3.1 Dataset di training

Si dispone di immagini acquisite con drone in differenti località del Piemonte (Rivoira – frazione del Comune di Boves, Grugliasco e Salbertrand) e in diversi giorni nei mesi di giugno e luglio, mesi di fase attiva del ciclo vegetativo. I dettagli delle acquisizioni con drone sono riportati in Tabella 3. I sensori utilizzati permettono di disporre di dati nelle bande RGB e NIR, ad eccezione dell'acquisizione nel sito di Salbertrand per la quale si è utilizzata solamente la banda RGB. Tutte le aree sono accomunate dalla presenza di vegetazione, seppur di diversa tipologia: il sito di Rivoira riguarda un'area agricola con campi coltivati; la porzione di Grugliasco inquadra un vigneto; l'area nel Comune di Salbertrand riguarda vegetazione boschiva. La disponibilità di aree vegetate con caratteristiche diverse permette di riconoscere una maggiore variabilità spettrale nelle immagini sottoposte a test. A partire da questi dati si costruisce il dataset di immagini ad alta risoluzione per il training della rete neurale. La Tabella 3 riassume i dati utilizzati.

Tabella 3. Dettagli delle acquisizioni con drone utilizzate nello studio

	Area N.	Data	Sensore	Risoluzione
Rivoira	1	26/07/19	Mapir	2 cm
Rivoira	1	22/07/20	Dji Phantom 4 Multispectral	3 cm
Grugliasco	2	25/06/19	Slant Range	2 cm
Salbertrand	3	17/06/20	Dji Phantom 4 Multispectral	4 cm

3.2 Dato per il test

La rete neurale allenata con i dati da drone relativi ai siti sopra menzionati può essere utilizzata su qualsiasi area, anche al di fuori delle tre aree per le quali si dispone delle acquisizioni con drone. Tuttavia, essendo obiettivo dello studio valutare la qualità del risultato dell'algoritmo di miglioramento della risoluzione, risulta interessante utilizzare come immagine di input per il test un'area che trovi corrispondenza tra quelle sopra citate, in modo da poter effettuare un confronto. Si è selezionato per i test il sito di Rivoira a causa della tipologia di area inquadrata, ossia campi agricoli, e della ridotta estensione dell'area interessata dalle acquisizioni con drone a Grugliasco. È stata scaricata dal portale dell'ESA (Copernicus Open Access Hub, <https://scihub.copernicus.eu/>) l'immagine satellitare corrispondente all'acquisizione con drone nel sito di Rivoira del

2019; il dato fa riferimento alla stessa data dell'immagine da drone, come riportato in Tabella 4.

Tabella 4. Dettagli dell'immagine satellitare utilizzata nello studio

	Data	Sensore	Risoluzione
Rivoira	26/07/19	Sentinel-2 MSI	10 m

Vengono effettuati tre differenti test sul sito di Rivoira incrementando l'estensione dell'area in esame al fine di valutare l'efficacia del metodo al variare della scala.

In particolare, le aree analizzate hanno le seguenti dimensioni:

- Test 01: 100 m x 200 m circa (2 ettari)
- Test 02: 500 m x 500 m circa (25 ettari)
- Test 03: 2 km x 2 km circa (400 ettari)

4. ELABORAZIONE DEI DATI

4.1 Pre-processing dei dati satellitari

Le immagini satellitari costituiscono il dato su cui viene effettuato il miglioramento dell'immagine. L'immagine viene scaricata dal portale ESA corretto in termini di riflettanza Top-Of-Atmosphere (Level-1C). Dall'immagine scaricata, che ritrae un'area di circa 100 km di lato, viene estratta la porzione da analizzare per ciascun test.

Per il test inerente alle immagini RGB si utilizza la banda TCI (True Color Image) con risoluzione spaziale di 10 m e codifica a 8 bit e non vengono effettuate ulteriori elaborazioni.

Per applicare l'algoritmo alla composizione multispettrale è necessario combinare le bande del verde (B03), del rosso (B04) e dell'infrarosso vicino (B08) in un unico stack; queste bande hanno risoluzione spaziale di 10 m e codifica a 12 bit. Per analogia con il dato acquisito da drone (con codifica a 8 bit) è necessario scalare l'immagine portandola alla codifica a 8 bit.

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

4.2 Pre-processing dei dati da drone

Per essere utilizzate come dati di training della rete neurale, le acquisizioni con drone necessitano di un'elaborazione. Tramite il software *Agisoft Metashape Professional 1.6.3*, basato su algoritmi di Structure from Motion (SfM) le immagini acquisite dal drone nelle diverse bande vengono allineate e viene generato un modello di nuvola di punti sparsa. Avendo a disposizione coordinate note di alcuni punti, detti marker o punti di appoggio, misurate con tecnica GNSS RTK, si collimano questi punti nelle singole immagini in modo da georeferenziare le immagini. Dopo aver ottimizzato i parametri di orientamento della fotocamera in base alle coordinate di riferimento note minimizzando gli errori, è possibile generare la nuvola densa di punti e infine il DEM (Digital Elevation Model) e l'ortomosaico.

Per ottenere un numero adeguato di immagini di training, considerando che l'allenamento della rete neurale per i deep model risulta più affidabile aumentando il numero delle immagini di training (C. Dong *et al.*, 2016), a partire dalle ortofoto ad alta risoluzione così ottenute 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 a maggior risoluzione (drone)

vengono ricampionate attraverso interpolazione Nearest Neighbour con risoluzione a 1 m. Queste elaborazioni vengono effettuate con il software *QGIS 3.10*.

5. RISULTATI

Il processo di training è stato completato in 87 ore, utilizzando un computer con le seguenti specifiche tecniche: CPU Intel Core i5 8th Generation, fino a 4 GHz; RAM 16 Gb, 2666 MHz; GPU Nvidia gtx 1070, 8 Gb.

I test vengono eseguiti sul sito di Rivoira su aree di estensione crescente al fine di valutare l'efficacia del metodo al variare della scala. Si rimanda all'appendice per gli output grafici dei test, le matrici di errore delle classificazioni e le metriche statistiche.

5.1 Test 01 – Rivoira

L'area ha dimensioni dell'ordine di grandezza di 100 m x 200 m (2 ettari), ridotta ma necessaria per avere a disposizione oltre all'immagine satellitare e all'immagine della Super Risoluzione, anche la corrispondente immagine a maggiore risoluzione da drone per poter calcolare le metriche di qualità dell'immagine. La ridotta estensione inoltre risulta essere un limite per l'applicazione della rete VDSR.

Le metriche di qualità dell'immagine ottenute dal confronto del risultato della Super Risoluzione con l'immagine ad alta risoluzione sono le seguenti: PSNR = 15.18, SSIM = 0.46, NIQE = 9.88.

5.2 Test 02 – Rivoira

L'area ha dimensioni di circa 500 m per lato (25 ettari). 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.

La valutazione dell'accuratezza viene effettuata tramite la sovrapposizione del dato BDTRE, il confronto tra analisi multispettrale e classificazione ottenute con le immagini alle diverse risoluzioni e l'analisi quantitativa della relativa matrice di errore.

Si osserva che elaborando il dato multispettrale con la rete neurale i bordi vengono esaltati; tuttavia compaiono delle striature inattese, incoerenti con il dato satellitare.

Dalla matrice di errore si nota:

- 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", 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" e "suolo" come riscontrabile anche dai valori bassi dei parametri di accuratezza produttore (PA) e accuratezza utente (UA).

5.3 Test 03 – Rivoira

L'area ha dimensioni di circa 2 km per lato (400 ettari) 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.

Dall'analisi probabilistica eseguita tramite la matrice di errore derivano i seguenti risultati: 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; 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 per l'immagine della rete VDSR sono paragonabili, sebbene quest'ultima sia rappresentata da valori lievemente migliori dei parametri connessi alla matrice di errore.

6. CONCLUSIONI

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 (L. Liebel and M. Körner, 2016), si è affrontato il problema del maggior numero di bande rispetto a un'immagine RGB elaborando una composizione di tre bande alla volta, unendole in un secondo momento se necessario. Questo è stato possibile in quanto l'obiettivo dell'analisi multispettrale è il calcolo dell'indice NDVI, ottenibile a partire dalle bande 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. 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 (L. Liebel and M. Körner, 2016). Dai test effettuati risulta un'evidente 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.

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. Questo studio rappresenta il punto di partenza di uno scenario più ampio di cui i passi successivi di approfondimento dovranno riguardare l'ottimizzazione dell'algoritmo stesso e il confronto con altri algoritmi di Deep Learning come SelfEX o SRCNN.

7. BIBLIOGRAFIA

- BDTRE 2019 - Database GeoTopografico (dataset vettoriale).” <http://www.geoportale.piemonte.it/geocatalogorp/index.jsp>. (16 June 2021).
- Copernicus Open Access Hub. <https://scihub.copernicus.eu/>. (16 June 2021).
- Data Products Sentinel-2. <https://sentinels.copernicus.eu/web/sentinel/missions/sentinel-2/data-products>. (16 June 2021).
- Dji Phantom 4 Multispectral. <https://www.dji.com/it/p4-multispectral>. (16 June 2021).
- Dong, C., Loy, C. C., He, K., & Tang, X., 2015. Image super-resolution using deep convolutional networks. *IEEE transactions on pattern analysis and machine intelligence*, 38(2), 295-307.
- Dong, C., Loy, C. C., & Tang, X. 2016, October. Accelerating the super-resolution convolutional neural network. In *European conference on computer vision* (pp. 391-407). Springer, Cham.
- ESA Sentinel online. <https://sentinel.esa.int/web/sentinel/home>. (16 June 2021).
- Geoportale Regione Piemonte. <https://www.geoportale.piemonte.it/cms/>. (16 June 2021).
- Grubinger, M., Clough, P., Müller, H., & Deselaers, T., 2006, May. The iapr tc-12 benchmark: A new evaluation resource for visual information systems. In *International workshop ontoImage* (Vol. 2).
- He, K., Zhang, X., Ren, S., & Sun, J., 2015. Delving deep into rectifiers: Surpassing human-level performance on imagenet classification. In *Proceedings of the IEEE international conference on computer vision* (pp. 1026-1034).
- Kim, J., Lee, J. K., & Lee, K. M., 2016. Accurate image super-resolution using very deep convolutional networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 1646-1654).
- Liebel, L., & Körner, M. 2016. Single-image super resolution for multispectral remote sensing data using convolutional neural networks. *ISPRS-International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 41, 883-890.
- Manfreda, S., McCabe, M. F., Miller, P. E., Lucas, R., Pajuelo Madrigal, V., Mallinis, G., ... & Toth, B., 2018. On the use of unmanned aerial systems for environmental monitoring. *Remote sensing*, 10(4), 641.
- MAPIR Survey3: Multi-Spectral Survey Cameras. <https://www.mapir.camera/pages/survey3-cameras>. (16 June 2021).
- Matese, A., Toscano, P., Di Gennaro, S. F., Genesio, L., Vaccari, F. P., Primicerio, J., ... & Gioli, B., 2015. Intercomparison of UAV, aircraft and satellite remote sensing platforms for precision viticulture. *Remote Sensing*, 7(3), 2971-2990.
- Matrone, F., Lingua, A., Pierdicca, R., Malinverni, E., Paolanti, M., Grilli, E., Remondino, F., Muriyoso, A. and Landes, T. 2020. A benchmark for large-scale heritage point cloud semantic segmentation. *Bollettino della società italiana di fotogrammetria e topografia*. 1, 10–18.
- Müller, M. U., Ekhtiari, N., Almeida, R. M., & Rieke, C., 2020. Super-resolution of multispectral satellite images using convolutional neural networks. *arXiv preprint arXiv:2002.00580*.
- Nebiker, S., & Lack, N., 2016. Multispectral and thermal sensors on UAVs. *GIM International-The Worldwide Magazine For Geomatics*, 30(12), 19-21.
- Pierdicca, R., Paolanti, M., Matrone, F., Martini, M., Morbidoni, C., Malinverni, E., Frontoni, E. and Lingua, A. 2020. Point cloud semantic segmentation using a deep learning framework for cultural heritage. *Bollettino della società italiana di fotogrammetria e topografia*.1, 1-9.
- Single Image Super-Resolution Using Deep Learning. <https://it.mathworks.com/help/images/single-image-super-resolution-using-deep-learning.html>. (16 June 2021).
- Slant Range. <https://slanrange.com/>. (16 June 2021).
- Stroppiana, D., Pepe, M., Boschetti, M., Crema, A., Candiani, G., Giordan, D., ... & Monopoli, L., 2019. Estimating crop density from multi-spectral UAV imagery in maize crop. *International Archives of the Photogrammetry, Remote Sensing & Spatial Information Sciences*.

Transfer Learning with Deep Network Designer.
<https://it.mathworks.com/help/deeplearning/ug/transfer-learning-with-deep-network-designer.html>. (16 June 2021).

Whitehead, K., & Hugenholtz, C. H., 2014. Remote sensing of the environment with small unmanned aircraft systems (UASs), part 1: A review of progress and challenges. *Journal of Unmanned Vehicle Systems*, 2(3), 69-85.

7. APPENDICE

7.1 Output grafici – Test 01

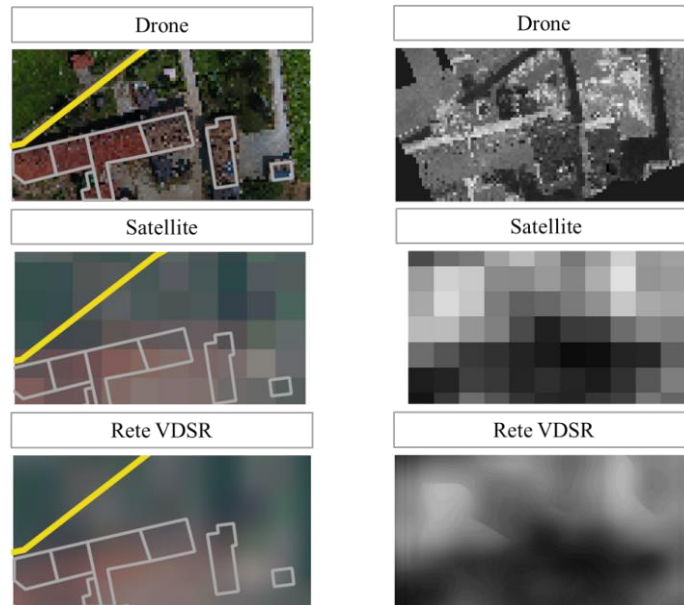


Figura 1. Estratto del confronto con BDTRE (sinistra) e della mappa dell'indice NDVI (destra) relativi all'area studio Test 01

7.2 Output grafici – Test 02




Figura 2. Estratto del confronto con BDTRE relativo all'area studio Test 02




Figura 3. Estratto del confronto della mappa dell'indice NDVI relativo all'area studio Test 02

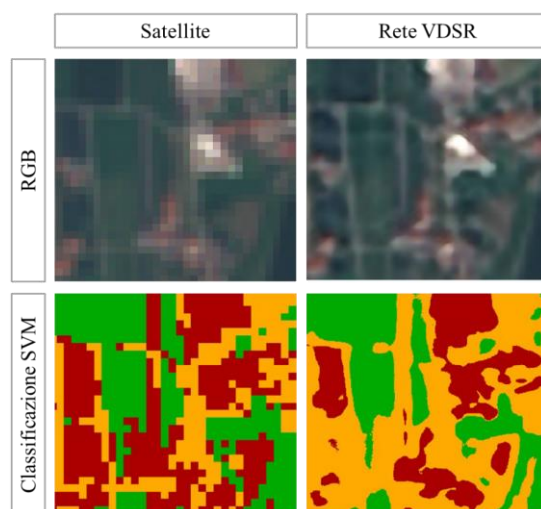


Figura 4. Estratto del confronto della classificazione SVM relativo all'area studio Test 02

7.3 Matrice di errore – Test 02

Sulla sinistra vengono riportate la matrice di errore e le principali statistiche relative alla classificazione SVM basata sull'immagine satellitare Sentinel-2, mentre sulla destra quelle relative alla classificazione SVM basata sull'elaborazione della rete neurale VDSR. 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 (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	0.1653	0.000	0.1033	72600	0.269
	2	0.000	0.4314	0.000	116600	0.431
	3	0.1277	0.000	0.1724	81100	0.300
Totale		0.2930	0.4314	0.2757	270300	
Area		79188	116600	74512	270300	

MATRICE DI ERRORE (area based)

		Dati di riferimento			Area	Wi
		1	2	3		
Dati classificazione	1	0.1114	0.000	0.0104	32493	0.123
	2	0.0000	0.371	0.000	98994	0.371
	3	0.1646	0.0134	0.3292	135342	0.507
Totale		0.2760	0.3844	0.3396	266828	
Area		73638	102577	90614	266828	

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		

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		

7.4 Output grafici – Test 03




Figura 5. Estratto del confronto della mappa dell'indice NDVI relativo all'area studio Test 03

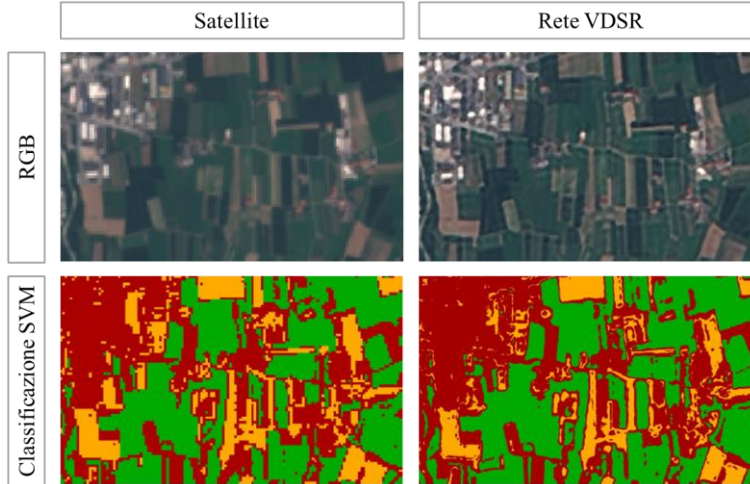


Figura 6. Estratto del confronto della classificazione SVM relativo all'area studio Test 03

7.5 Matrice di errore – Test 03

Sulla sinistra vengono riportate la matrice di errore e le principali statistiche relative alla classificazione SVM basata sull'immagine satellitare Sentinel-2, mentre sulla destra quelle relative alla classificazione SVM basata sull'elaborazione della rete neurale VDSR. 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 (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	0.3624	0.0078	0.0756	1864000	0.446
	2	0.0000	0.4093	0.0000	1711500	0.409
	3	0.0074	0.0000	0.1376	606500	0.145
Totale		0.3698	0.417	0.2132	4182000	
Area		1546616	1743917	891467	4182000	

MATRICE DI ERRORE (area based)

		Dati di riferimento			Area	Wi
		1	2	3		
Dati classificazione	1	0.3904	0.0012	0.0841	1934853	0.476
	2	0.0002	0.4220	0.0007	1719899	0.423
	3	0.0036	0.000	0.0980	413124	0.102
Totale		0.3941	0.4232	0.1827	4067876	
Area		1603069	1721486	743321	4067876	

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

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