



UNIVERSITÀ DEGLI STUDI DI PADOVA

**Dipartimento AGRONOMIA ANIMALI ALIMENTI RISORSE NATURALI E
AMBIENTE**

**Dipartimento TERRITORIO E SISTEMI AGRO-FORESTALI
Corso di laurea in SCIENZE E TECNOLOGIE AGRARIE**

**IMPIEGO DI MAPPE SATELLITARI PER LO STUDIO
DELLA VARIABILITÀ IN AREE COLTIVATE A SOIA**

RELATORE:

Dott. Francesco Marinello

CORRELATORE:

Dott. Kayad Ahmed

LAUREANDO:

Alessandro Zanchin

Matricola n. 1183600

ANNO ACCADEMICO 2018-2019

RIASSUNTO

Lo studio della variabilità delle aree agricole è fondamentale per tutti gli agricoltori che vogliono interfacciarsi alle moderne tecniche agronomiche previste dall'agricoltura di precisione (AP). Riuscire a prevedere risultati di produttività affidabili, in anticipo rispetto alla data di raccolta, attraverso un modello previsionale, sarebbe di estrema utilità a tutti i soggetti afferenti all'agribusiness. Affinare le tecniche agronomiche, nel contesto dell'AP, e riuscire a mettere a punto un modello previsionale su una coltura molto importante nel panorama agricolo italiano come la soia (*glycine max*), porterebbe degli enormi vantaggi a produttori e commercianti. Nel presente studio si è voluto studiare in che modo gli indici vegetazionali (IV) siano correlati alla produzione in aree coltivate a soia, situate nel nord-est Italia. Sono state campionate diverse immagini satellitari di sette aree agricole coltivate a soia in tre anni differenti (2018, 2017, 2016), situate in provincia di Rovigo, dalle quali sono stati calcolati 8 IV nei vari stadi fenologici della coltura. È stata scelta la missione satellitare Sentinel-2 come fonte di immagini, in quanto le informazioni rilasciate sono gratuite e ad elevata risoluzione. Ogni IV, calcolato per ogni foto rilievo disponibile, in ogni appezzamento, è stato confrontato con la rispettiva mappa di produzione fornita dal monitor della mietitrebbia utilizzata per la raccolta della soia. Dal confronto è risultato che Green Chlorophyll Vegetation (GCVI), Green Normalized Difference Vegetation Index (GNDVI) e Wide Dynamic Range Vegetation Index (WDRVI), sono gli indici che mediamente mostrano il maggiore coefficiente di correlazione con la produzione (R^2 0,41 ÷ 0,68 in cinque aree su sette), se raccolti in un periodo compreso tra 85 e 105 giorni dopo la semina, nonché tra 30 e 20 giorni prima della raccolta. Utilizzando uno di questi IV, calcolato possibilmente in più foto rilievi di quel periodo, è possibile stimare la variabilità di aree coltivate a soia.

È stata verificata la validità di un modello lineare sfruttando l'equazione della retta di regressione tra un IV e la produzione verificata in un'area in cui la correlazione è molto elevata (produzione attesa = $1,022\text{GCVI} + 0,7188$). Con tale modello si vuole poter prevedere la variabilità in termini di produzione. Il modello è stato verificato per tutte le altre aree e ha fornito risultati interessanti tra le aree coltivate nel 2018 e 2017, (RMSE 0,47 Mg/ha), mentre nel 2016 ha dato risultati piuttosto scadenti (RMSE 2,07 Mg/ha). Probabilmente, le diverse condizioni climatiche che hanno caratterizzato i tre anni, hanno influito sulla correlazione, oltre ad altre cause ambientali per cui la correlazione tra IV e resa risulta di per sé bassa.

ABSTRACT

The spatial variability study in agricultural areas, is essential for all farmers who want to approach modern agronomic techniques of Precision Agriculture (PA). The fact of being able to provide a predicting model that gives information about fields production, before the harvesting date, can be extremely useful for all agribusiness players. The improvement of PA techniques and the development of a reliable forecasting model for a fundamental crop of Italian agricultural landscape, like soybean (*glycine max*), could lead many benefits for both farmers and dealers.

This paper studies how Vegetation Indices (VIs) are correlated with yield in northern east areas of Italy cultivated with soybean. Thanks to Sentinel-2 satellite images it has been possible to calculate eight VIs among all crop phenological stages of seven different soybean areas. These areas are located in the province of Rovigo and had been analysed in three different years (2018, 2017 and 2016). As Sentinel-2 provides free data and high-resolution images, it has been the main source of information for this paper.

Moreover, the study shows that for every single image it is possible to calculate a Vegetation Index that can be compared with its respective yield map provided by a combine monitor.

The VIs that show the best connection with yield variability are: Green Chlorophyll Vegetation (GCVI), Green Normalized Difference Vegetation Index (GNDVI) and Wide Dynamic Range Vegetation Index (WDRVI); if data are collected between 85-105 days after sowing, as well as 30-20 days before harvesting these indices enhance the highest correlation factor (R^2 values of $0,41 \div 0,68$ in five areas out of seven).

Thanks to just one of these indices, better if calculated on the basis of different images collected in that period of time, it is possible to assess spatial variability in soybean areas. This study shows the effectiveness of a linear model using necessarily the equation of the regression line between a VI and the production of a field with a high correlation to it (predicted yield = $1,022GCVI + 0,7188$). This linear model can provide information in terms of yield variability: it has been tested on each area but it gives interesting results only when those fields are cultivated in the year 2018 and 2017, (RMSE 0,47 Mg/ha), but not in 2016 (RMSE 2,07 Mg/ha). In fact, different weather conditions that characterised the three years of the analysis, may have interfered with the correlation in 2016.

SOMMARIO

RIASSUNTO.....	1
ABSTRACT	2
SOMMARIO.....	3
Capitolo 1	5
INTRODUZIONE	5
1.1 Introduzione.....	5
1.2 Il presente lavoro.....	9
Capitolo 2	10
SATELLITI IN AGRICOLTURA.....	10
2.1 Uso di dati da remoto per il monitoraggio delle colture.....	10
2.2 Integrazione dei dati da remoto all'agricoltura	13
2.3 Uso di dati da remoto come strumento previsionale della produttività.....	18
Capitolo 3	22
MATERIALI E METODI	22
3.1 Sentinel-2	22
3.2 Indici vegetazionali	23
3.3 Software ausiliari	26
3.3.1 Google Earth Engine.....	26
3.3.2 ArcGis	26
3.3.3 SMS basic.....	27
3.3.4 Excel	27
3.4 Mappe di produzione	27
3.4.1 Aree studio.....	27
3.4.2 Raccolta dati satellitari	28
3.4.3 Raccolta dati di produzione	29
3.4.4 Elaborazione dei dati.....	30

Capitolo 4.....	32
CASO STUDIO	32
4.1 Analisi della correlazione	32
4.2 Risultati principali.....	42
4.3 Discussione	43
Capitolo 5.....	48
CONCLUSIONI.....	48
BIBLIOGRAFIA.....	51
Documenti scientifici.....	51
Siti web.....	55

Capitolo 1

INTRODUZIONE

1.1 Introduzione

Soia (*glycine max*) è la specie leguminosa più coltivata nell'intero panorama agricolo mondiale (Giardini e Baldoni, 2001). Nella campagna 2017/2018 sono state prodotte 346,02 milioni di tonnellate di semi di soia, l'82% della produzione è attribuita a soli tre stati: Stati Uniti, Brasile ed Argentina.

Cina, Europa, Stati Uniti e Brasile consumano il 64% dell'intera produzione mondiale, viene impiegata principalmente come fonte proteica nell'alimentazione degli animali da allevamento, ma è presente in molti prodotti alimentari per il consumo umano: surrogati della carne, tofu, olio di semi di soia, latte di soia e molti altri prodotti (www.soymeal.org/). In Italia nel 2018 vennero coltivati 326.587ha e prodotti 1.173.451 Mg di semi di soia, mentre nell'anno 2019 sono stati coltivati 274.516 ha e prodotti 977.049 Mg di semi (<http://dati.istat.it/>). Lo storico di produzione e consumo, proposto in figura 1.1, illustra un netto trend di crescita sia nella produzione che nei consumi.

Dato il valore economico, agricolo e nutrizionale che la coltura ha assunto negli anni, è essenziale affinare ed implementare tecniche agronomiche moderne e sostenibili al fine di rendere la produzione della soia più stabile nel tempo, per far fronte alle varie sfide che il futuro ci preserva, (prima tra tutte i cambiamenti climatici), a basso impatto per l'ambiente e proficua per gli agricoltori. Un passaggio fondamentale sarà riuscire a calibrare le classiche tecniche agronomiche, che caratterizzano questa coltura, con la moderna agricoltura di precisione (AP) (De Benedetto et al., 2013).

L'AP dispone di una vasta gamma di strumenti e tecnologie applicabili in campo, attualmente l'attenzione è focalizzata su due grandi argomenti: "internet of things" (IoT) e raccolta e gestione di dati in ambito agricolo.

Internet of things è un neologismo che può essere parafrasato come: estensione della rete internet agli oggetti. Questa procedura vede l'interconnessione di più oggetti, nonché dispositivi, ad una rete, i quali possono trasferire ed elaborare informazioni tra di essi, ma anche trasferire informazioni agli operatori e viceversa.

Un esempio pratico nel quale da diversi anni l'IoT si concretizza è la tecnologia a rateo variabile (in anglosassone Variable Rate Technology, VRT), ovvero la capacità di alcune particolari attrezzature agricole di assegnare input agricoli a dosaggi differenti in base a:

a) posizione in campo nella quale si trova la macchina operatrice, comunicazione di tipologia

Satellite → Macchina Operatrice → Dispositivo

b) dati rilevati in diretta da sensori applicati alle stesse macchine. comunicazione di tipologia

Sensore → Dispositivo.

La progressiva riduzione dei costi e lo sviluppo della tecnologia wireless alla sensoristica, ha permesso l'introduzione di innumerevoli tipologie di sensori applicabili in agricoltura, dalla semina alla raccolta (Srbinovska et al., 2015).

I dati raccolti in campo devono però, ai fini di una corretta ed efficiente integrazione all'agronomia di base, essere validi e rappresentativi della reale situazione in campo, inoltre può essere necessario dover rielaborarli al fine di trarre informazioni impiegabili in campo. L'elaborazione può venir effettuata direttamente dai mezzi agricoli oppure da un operatore sfruttando appositi software, è indispensabile che sia la fase di raccolta che elaborazione risultino economicamente sostenibili, nonché proficue.

Solo disponendo di particolari dispositivi interconnessi da una rete e di informazioni riguardanti terreni e colture, è possibile interfacciarsi all' AP (Srbinovska et al., 2015).

Sebbene mettere in pratica l'AP comporti un costo aggiuntivo per le aziende agricole (spese ad esempio per nuove attrezzature, sensori, software, corsi di formazione), la quota di mercato di queste nuove tecnologie è in continua crescita e lo sarà anche nel prossimo futuro, alcune stime effettuate nell'area agricola del Nord America riferiscono che dal 2014 al 2025 il mercato delle tecnologie affini all' AP crescerà più di tre volte e mezza, figura 1.2.

Fase cruciale per la corretta applicazione dell'AP è lo studio della variabilità delle aree agricole: ciò consiste nell'identificare sub aree meno produttive da aree più produttive e discriminare i fattori limitanti, con lo scopo di attuare una gestione ad hoc per ogni sub area (De Benedetto et al., 2013).

Impiegando la tecnologia VRT integrata a mappe di prescrizione o sensori che rilevano dati in diretta, è possibile gestire e coltivare in modo variabile le aree agricole.

La mappatura delle produzioni, tramite sensori di resa applicati alle macchine raccogliatrici, è uno dei modi più efficaci per ottenere mappe storiche di produzione degli appezzamenti, grazie alle quali è possibile ottenere immagini ad alta risoluzione nelle quali identificare la variabilità delle aree agricole, anche su piccola scala (Hunt et al., 2019).

Un'altra via economica ed efficace consiste nel ricavare immagini satellitari delle colture: esiste una diretta correlazione tra la biomassa potenziale di una coltura ed il rispettivo spettro di riflettanza captato dai satelliti in orbita (Toulios et al., 1998).

In particolare, grazie alle riprese satellitari, è possibile calcolare vari indici vegetazionali (IV), i quali possono restituire informazioni utili riguardo all'approvvigionamento idrico delle colture, lo stato nutrizionale e lo stato salutare (Taylor et al., 1997).

In aggiunta questo genere di informazioni, accoppiate a specifiche riguardo alle condizioni fisiologiche delle colture e dati climatico-ambientali, possono essere integrati a specifici algoritmi i quali restituiscono modelli previsionali di sviluppo e produzione delle colture (Ferencz et al., 2004).

La raccolta di immagini satellitari spazia nell'ambito del Remote Sensing (RS), ovvero la raccolta di informazioni a distanza senza che ne 'operatore, né lo specifico sensore, entrino in contatto con la coltura.

Si presume che il RS abbia origine nel XIX secolo con il fotografo Gaspard-Félix Tournachon (Parigi, 6 aprile 1820-Parigi, 21 marzo 1910), il quale nel 1858 fotografò la città di Parigi da un pallone aerostatico. Varie riprese aeree vennero sperimentate durante i due conflitti mondiali, le fotografie venivano acquisite a bordo di aeroplani. Il telerilevamento via satellite ha inizio solo nel 1957 con il lancio del primo satellite in orbita: lo Sputnik. Il primo satellite munito di sensore ottico multibanda adatto ad acquisire informazioni dettagliate di terre ed oceani, e quindi applicabile in ambito agricolo, fu il Landsat 1 (NASA), lanciato il 23 luglio 1972. Tuttavia le prime missioni satellitari riscossero il maggior successo in ambito meteorologico, in ambito militare e nella categorizzazione della superficie terrestre (Wardlow e Egbert, 2008), mentre l'utilizzo intensivo da parte di ricercatori in ambito agricolo, allo scopo di monitorare e calcolare gli IV delle colture, ha inizio solo negli anni ottanta con il lancio del satellite TIROS-N, appartenente alla National Oceanic and Atmospheric Administration (NOAA): esso campionava sia bande del visibile, sia del vicino infrarosso, quelle più indicate per il monitoraggio delle colture (Tucker et al., 1985).

L'importanza dei dati satellitari in agricoltura è stata enfatizzata dall'entrata in funzione delle ultime missioni satellitari, in particolare Landsat-8 (Wulder et al., 2012) e Sentinel (Hunt et al., 2019). L'elevata frequenza di rilievo di immagini, il basso costo e l'aumento della risoluzione sia spaziale, che spettrale, hanno giocato un ruolo fondamentale nell'applicazione dei satelliti al RS contestualizzato in ambito agricolo.

Utilizzando dettagliati fotogrammi satellitari, è addirittura possibile studiare e prevedere la variabilità della produzione che si verificherà in campo ancor prima della raccolta (Ferencz et al., 2004).

A tal proposito è possibile procedere attraverso due metodologie differenti: sfruttare modelli previsionali complessi che forniscano a loro volta indicazioni sulla produttività, oppure calcolare la diretta relazione tra lo spettro di riflessione di una coltura e la sua relativa produzione verificata (Toulios et al., 1998).




Figura 1.1: Dati di produzione (Production) e consumo (Usage) in milioni di Mg (MMT) aggiornato a marzo 2018, (www.soymeal.org/, modificata)

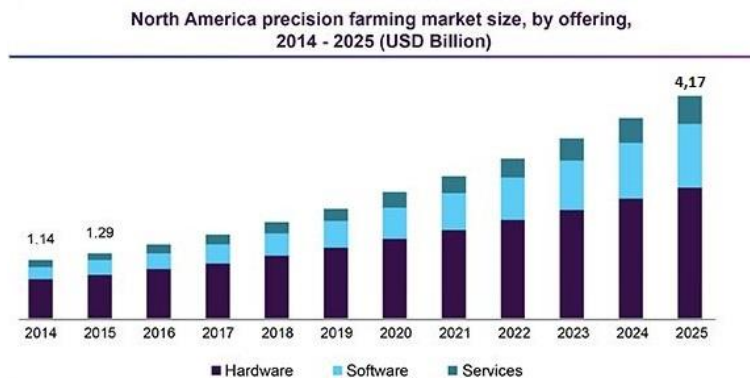


Figura 1.2: L'istogramma illustra il trend dal 2014 al 2025 della quota di mercato relativa a dispositivi (hardware), software e servizi (service) affini all' AP, nei paesi del Nord America, (www.grandviewresearch.com, modificata).

1.2 Il presente lavoro

Questo lavoro di tesi si è basato sull'esistenza di una correlazione tra produttività verificata in campo ed informazioni fornite da immagini satellitari ad alta definizione, immagini raccolte durante il periodo di coltivazione della coltura stessa. Scendendo nei particolari sono stati confrontati vari IV, calcolati dai rilievi satellitari, ed identificati quelli che mostrassero il maggior coefficiente di correlazione con l'effettiva produzione realizzata in aree coltivate a soia. Questa procedura vuole proporre un modello diretto di stima della variabilità in anticipo rispetto alla raccolta ed è stata validata in diversi studi pubblicati su riviste di fama internazionale, in particolare è stata ricalcata la metodologia proposta da Schwalbert et al. nel 2018. Questo metodo si basa su una relazione empirica tra due variabili che di per sé sono correlate, tuttavia tale relazione è verificata solo a determinati stadi fenologici e fisiologici delle colture e può dare risultati diversi variando il metodo di calcolo degli IV. In aggiunta lo stesso modello calcolato per una coltura non è replicabile per altre, anche se il periodo di coltivazione è simile (non è estendibile né tra colture estive, mais e soia, né tra colture autunno vernine). Si è deciso di lavorare in un'area nel sud del Veneto ad elevata specializzazione nella produzione di soia al fine di determinare:

- Quale sia il momento migliore per raccogliere dati ottici di provenienza satellitare allo scopo di stimare la variabilità della produzione di soia;
- Quale sia il migliore, o i migliori, IV che dimostrino il maggior coefficiente di correlazione con la produttività verificata, da considerare nella costituzione di un modello previsionale;
- Ricavare un modello lineare con cui poter stimare la variabilità di un appezzamento basandosi solo sugli IV.

I dati considerati per lo studio provengono da un'unica mietitrebbia munita di sensore di resa ad ettaro, il quale fornisce mappe di produzione delle colture georeferenziate.

Si è deciso di servirsi di immagini ad alta definizione fornite dalla missione satellitare "Copernicus Sentinel-2" perché considerate le migliori date la risoluzione spettrale, il numero di immagini disponibili per stagione e l'elevata risoluzione spaziale (10m x 10m).

I fotogrammi sono stati ricavati dalla piattaforma virtuale Google Earth Engine (GEE) sulla quale è stato possibile calcolare direttamente gli IV ed infine esportati in formato .dbf per l'analisi statistica.

Capitolo 2

SATELLITI IN AGRICOLTURA

2.1 Uso di dati da remoto per il monitoraggio delle colture.

Il monitoraggio delle colture rappresenta una delle attività chiave per un agricoltore, al fine di garantire il miglior risultato produttivo.

Controllare la crescita e lo sviluppo delle colture agrarie in campo, prevenire la manifestazione di stress ed identificare i fattori biotici ed abiotici causali, nonché prevedere la produzione dell'annata, sono alcune tra le risposte che un'attenta attività di monitoraggio dovrebbe fornire.

Tale attività può essere svolta in campo attraverso la supervisione delle colture ed eventuale campionamento ed analisi dei tessuti vegetali, può limitarsi alla semplice deduzione delle condizioni colturali previa attenta osservazione degli operatori, o sfruttando strumenti elettronici che generalmente forniscono un risultato da rielaborare e da interpretare. Alcuni esempi possono essere lo Spad 502 Chlorophyll Meter, il quale restituisce valori indicativi sul contenuto di clorofilla dei tessuti fogliari dei vegetali, oppure camere multispettrali (come il GreenSeeker), grazie alle quali è possibile calcolare vari IV che identificano a loro volta lo stato nutrizionale e salutare delle colture.

Sono noti gli innumerevoli strumenti e sensori utilizzati in frutticoltura per l'analisi qualitativa dei prodotti: sia in pre-raccolta, sia in post-raccolta.

La necessità di automatizzare e rendere economico il monitoraggio delle colture, soprattutto in aziende di grandi dimensioni, aventi colture diversificate e frazionate, ha spesso trovato risposta nel "remote sensing", o telerilevamento (Jinru et al. 2017).

Remote sensing (RS) viene identificato come un'arte, una scienza e una tecnologia con la quale le caratteristiche degli oggetti e degli obiettivi situati sulla superficie terrestre, ma anche al di sotto, possono venire identificati, misurati ed analizzati senza che avvenga un contatto diretto tra il sensore, nonché l'operatore, e gli oggetti, od eventi, osservati (Lillesand et al., 2010).

Il RS oggi viene utilizzato su larga scala come strumento per il controllo dei dati ambientali e lo sviluppo di macro e micro aree geografiche come:

- monitoraggio delle aree forestali, al fine di identificare e misurare il danno causato da incendi o dal disboscamento illegale, o al contrario l'espansione di queste aree

a causa dell'abbandono dei terreni limitrofi e quindi misurare l'avanzamento della rinaturalizzazione delle aree antropomorfizzate;

- Monitoraggio delle aree urbane, per studiare lo sviluppo e la geometria dei centri abitati, calcolare la percentuale di superficie impermeabilizzata e stimare la percentuale di verde urbano (gestione del territorio);
- Monitoraggio di aree naturali, per lo studio della biodiversità di un territorio e controllarne lo sviluppo ovvero salvaguardare le stesse aree da attività antropiche che potrebbero comprometterne l'ecosistema;
- Monitoraggio delle aree agricole, vaglio delle stesse da aree naturali, foreste o verde urbano e quindi conoscenza dell'entità della superficie agricola su larga scala, identificazione delle colture in atto, con la possibilità di ricavare informazioni importanti riguardanti colture avvenute in anni passati, o alla coltura dell'annata stessa, in tempo reale o con soli pochi giorni di ritardo (nel secondo caso).

Gran parte dei progressi scientifici sono attribuibili all'introduzione del telerilevamento, in particolare in materie come: geologia, glaciologia, cartografia idrologia, intelligence militare e climatologia.

Le informazioni ricavate grazie al RS derivano per la maggior parte dei casi da due tipologie di sensori: ottici o radar. Possiamo distinguerli ulteriormente in:

- sensori attivi, queste tipologie di sensori emettono una radiazione elettromagnetica come fonte energetica per il telerilevamento; ne sono un esempio le tecnologie radar e Lidar (light detection and ranging);
- sensori passivi, i quali si affidano all'energia solare come unica fonte energetica e alle radiazioni emesse dai corpi fluorescenti, misurando quindi l'entità della radiazione riflessa od emessa dalla superficie terrestre (camere).

I sensori radar restituiscono informazioni tridimensionali della superficie analizzata.

I sensori ottici riportano dati riguardo alle radiazioni elettromagnetiche emesse o riflesse dagli oggetti bersaglio, il range di bande misurato in ambito agricolo è solitamente compreso tra 400nm e 1100nm; esistono sensori multispettrali con risoluzione spettrale (differenza minima tra due bande) di circa 20 nm, e iperspettrali che raggiungono anche 0.1nm.

Ultimo componente indispensabile al RS è la piattaforma che supporta il sensore.

Nell'odierno scenario agricolo sono 4 le tipologie di supporto sul quale vengono applicati i sensori.

- Macchine agricole. Il sensore rileva in diretta i dati colturali mediante l'avanzamento in campo delle macchine agricole, spesso in contemporanea ad altre lavorazioni (preparazione del letto di semina, concimazione, raccolta...); l'intero costo del telerilevamento è da attribuire al prezzo dello strumento utilizzato e dall'utilizzo nel contesto aziendale, in quanto la piattaforma è già ammortizzata dalle altre attività che svolge in campo.
- Aeromobile a pilotaggio remoto (APR), notoriamente conosciuto come "drone" (in anglosassone unmanned aerial vehicle "UAV"). Piccoli aeromobili pilotati a distanza sui quali viene installato il tipo di sensore desiderato, permette di ricavare dati ad alta definizione grazie alla sua prossimità al suolo durante il volo (altezza massima consentita dalla legge Italiana in vigore ammette 70m per voli amatoriali e 120 m per voli effettuati da piloti con apposito attestato, fonte ENAC). Questo sistema permette di ottenere i dati nel momento del bisogno e consente di ovviare al problema dell'ombra causato dalle nuvole in giornate particolarmente coperte, tuttavia la durata dei voli è limitato dalla capacità delle batterie. Il costo in questo caso va attribuito sia alla piattaforma, sia al sensore, o al canone da pagare se il servizio di monitoraggio viene affidato a terzi.
- Aeromobile. Aerei sui quali è possibile installare sensori di ottici o radar e grazie a voli prossimi alla superficie terrestre ricavano immagini e dati. Il costo è da attribuire al prezzo del servizio, che pare essere proibitivo se adoperato nel solo contesto agricolo (Jinru et al., 2017).
- Satelliti. Piattaforme che orbitano attorno al pianeta restituendo con una certa frequenza immagini e dati delle aree in esame, la frequenza è determinata dal numero di satelliti presenti in orbita e dalla loro velocità di rotazione. La maggior parte dei dati a media e bassa definizione sono gratuiti, per accedere a dati ad alta definizione viene attribuita una tariffa per kmq e per immagine.

Al fine di scegliere il sistema di telerilevamento più adatto alle proprie esigenze, quindi l'esatta combinazione sensore-piattaforma, è importante valutare alcune caratteristiche degli elementi misurati.

- Risoluzione spaziale: è l'area superficiale analizzata dal sensore rappresentata dall'ampiezza dei pixel dell'immagine ottenuta.
- Risoluzione spettrale: rappresenta l'entità delle bande che un sensore è in grado di discriminare, in particolare sono importanti il numero e la loro ampiezza (espressa in nm).

- Risoluzione radiometrica: indica il numero di livelli in cui è possibile scomporre il segnale captato ed ottenere quindi immagini con maggiore o minore definizione (espressa in bit).
- Risoluzione temporale: intervallo di tempo che intercorre tra due rilevazioni, dipende dal tipo di piattaforma di supporto. Per macchine agricole e droni è teoricamente possibile effettuare rilevamenti a piacere, per le altre vie di acquisizione è opportuno attendere il giorno e l'ora in cui sarà possibile accedere alle informazioni.
- Tipologia di dati ai quali si desidera accedere (immagini 3d, rilevazioni termiche, rilevazioni del solo intervallo visibile, infrarosso...).
- Costo-beneficio della pratica di telerilevamento, influenzato anche dalla capacità di conservare, elaborare e gestire la mole di dati raccolti, nonché dall'eventuale acquisto e formazione per l'utilizzo di software accessori.

2.2 Integrazione dei dati da remoto all'agricoltura

Nel presente studio verrà approfondito l'utilizzo dei satelliti in ambito agricolo, contestualizzato nell'agricoltura di precisione (AP).

L'AP può essere definita come un approccio standardizzato, innovativo e integrato, su scala internazionale, volto ad aumentare l'efficienza dell'uso delle risorse in agricoltura e che vuole minimizzare l'incertezza nella gestione della variabilità delle aree agricole (Liaghat et al., 2010).

L'AP è il sistema di produzione di derrate alimentari che fa uso della maggiore quantità di dati, informazioni, nonché il metodo che sfrutta in campo i più sofisticati strumenti tecnologici per la gestione delle colture e delle aziende agricole; ad oggi è il sistema che permette, in assoluto, di produrre con il minor impatto ambientale per unità di prodotto agricolo, assicurandone allo tempo stesso la salubrità (Tellaeche et al., 2008).

Il telerilevamento tramite satellite svolge un ruolo fondamentale all'interno dell'AP, in quanto:

- Si tratta di un'analisi di tipo "non distruttiva";
- È possibile raccogliere dati provenienti da vaste aree geografiche, quindi analizzare contemporaneamente più appezzamenti;
- Si eliminano completamente errori commessi in fasi di campionamento in campo da parte degli operatori (Jensen, 1996);

- È possibile ottenere immagini storiche degli appezzamenti da confrontare con quelle odierne;
- La maggior parte dei dati a risoluzione medio bassa (>5m) sono a libero accesso, mentre il costo di immagini ad alta risoluzione (<5m) è in continua diminuzione (Burke et al., 2017).

In particolare, grazie alle immagini raccolte dai sensori ottici applicati ai satelliti in orbita, è possibile: stimare la superficie agricola di una macro area geografica (Jin et al., 2019), riconoscere alcune tra le colture in atto (frumento, orzo, colza, mais) (Jarman et al., 2018); stimare la produzione di alcune colture su vaste aree geografiche ancora prima della raccolta (Sun et al., 2019), monitorare le colture agrarie calcolando gli indici vegetazionali per ogni coltura e appezzamento in qualsiasi periodo dell'anno ed è possibile, inoltre, studiare la forma tridimensionale di chiome, superfici alberate, seminativi e frutteti, nonché calcolare la biomassa vegetale di superfici agrarie o naturali integrando alle immagini dati ricavati da sensori radar (Zhang et al., 2019; Moreau et al., 2003).

Sensori ottici passivi di tipo multispettrali, o iperspettrali, intercettano e filtrano le radiazioni elettromagnetiche solari riflesse dalle chiome delle colture e restituiscono valori di assorbanza delle diverse bande. Il calcolo degli indici vegetazionali (IV) di colture consiste in diverse operazioni matematiche tra i valori di assorbanza delle diverse bande, i risultati variano al variare dei rapporti tra i valori di assorbanza registrati tra le diverse frequenze.

Gli IV più consoni all'analisi da svolgere vengono selezionati in base allo spettro di emissione delle colture e dallo scopo dell'analisi stessa.

La clorofilla presente nei tessuti verdi delle specie vegetali assorbe la luce blu (465nm) e la luce rossa (665nm), riflettendo la luce verde e l'infrarosso; la quantità di luce riflessa nelle varie bande (riflettanza) viene rilevata dal sensore ottico e la distribuzione del segnale, fra le varie frequenze captate, varia in base alla composizione chimica dei tessuti vegetali (specie vegetale, stadio fenologico, contenuto di acqua, pigmenti sintetizzati...). In ambito botanico è stata ampiamente studiata la regione del medio-vicino infrarosso, la quale mostra la massima variabilità di luce riflessa al variare dello stato fenologico e salutare degli organismi vegetali (Foley et al., 1998).

Considerando che organi "vigorosi", in perfetto stato nutrizionale, salutare e di sufficiente apporto idrico, sono caratterizzati da un elevato tasso di assorbimento della luce rossa (elevata concentrazione di clorofilla nei tessuti fotosintetizzanti) e da un'elevata riflettanza delle radiazioni appartenenti al vicino infrarosso (NIR) (Taylor et al., 1997), basandosi sul

contrasto tra assorbanza della luce rossa e dispersione del NIR è possibile stimare lo stato salutare di un vegetale.

Scendendo nello specifico, cambiamenti fisiologici che regolano la composizione cellulare dei tessuti verdi (distruzione di pigmenti, sintesi di sostanze, danni fisici), causati dalla proliferazione di organismi patogeni, manifestazione dei sintomi legati ad una malattia od a stress abiotici, come carenze nutrizionali, modificano lo spettro della luce riflessa dalla superficie fogliare (Delalieux et al., 2007; Mahlein et al., 2013; Moshou et al., 2004; Zhang et al., 2012). In figura 2.1 vengono illustrati lo spettro di assorbimento di clorofilla estratta da tessuti di soia e il corrispettivo spettro di riflettanza, misurati in laboratorio. Dalla comparazione dei grafici (a) e (b), in figura 2.2, possiamo evincere che la dispersione della luce ricavata da prove di laboratorio ricalca lo stesso spettro di riflettanza rilevato in campo da Sentinel-2.

Oltretutto si sa che l'entità dell'emissione di bande appartenenti alle short wave infrared (SWIR), comprese tra 1000nm e 2500nm, è particolarmente correlato al contenuto in acqua di un organo, se integrate al classico spettro visibile-infrarosso (VIS-NIR), è possibile stimare il profilo spettrale di una coltura in stress, noti gli agenti causali (Xu et al., 2007; Zhang et al., 2013).

Al fine di geolocalizzare le aree manifestanti stress, è sufficiente eseguire un'analisi statistica di correlare tra l'entità del danno misurato in campo e la risposta rilevata con il RS, ad esempio può essere impiegata l'analisi della varianza (ANOVA) e calcolato il fattore di correlazione di Pearson tra: i valori di assorbanza di un sensore ottico, come gli IV, ed il danno (Zhang et al., 2012).

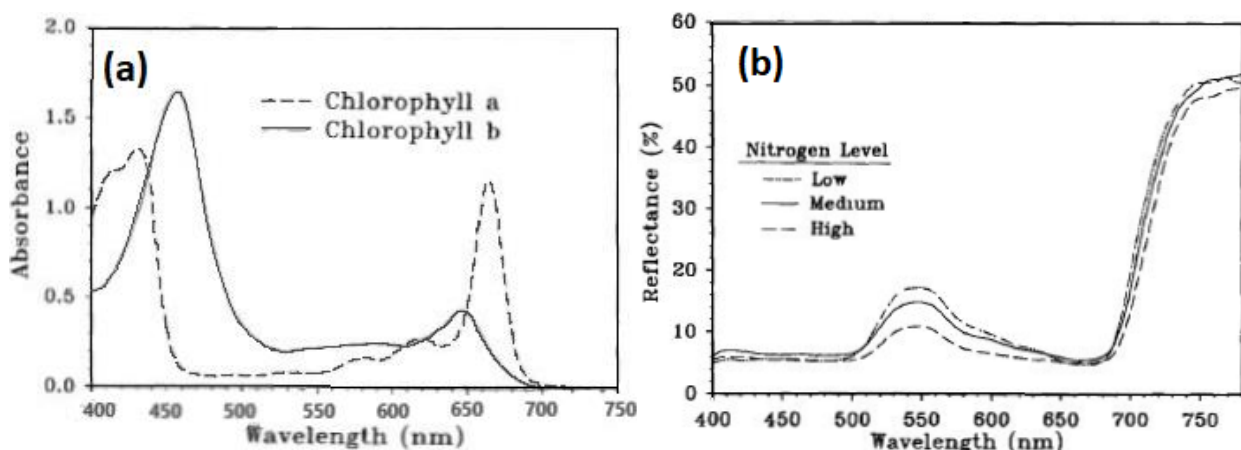


Figura 2.1: Spettro di assorbimento (a) di clorofilla estratta da tessuti fogliari di soia con DMSO, alla concentrazione di 1×10^{-1} g/M e rispettivo spettro di riflettanza (b), (Chappelle et al., 1992, modificata).

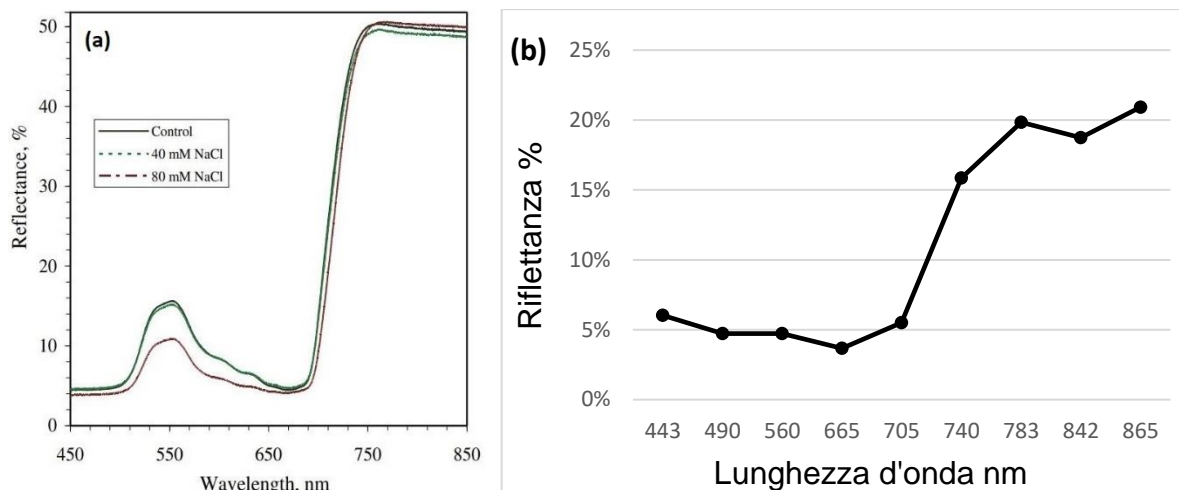


Figura 2.2: (a) Spettro di riflettanza percentuale di tessuti di soia misurato in laboratorio attraverso uno spettrometro a fibra-ottica (USB2000): controllo, stress salino indotto da trattamento con acqua di irrigazione a 40mM di NaCl e 80 mM NaCl (Krezhova, 2011, modificata). (b) Spettro di riflettanza percentuale di un'area coltivata a soia rilevata il 28 giugno 2018 da Sentinel-2.

Se la correlazione IV/danno risulta elevata è possibile stimare e geolocalizzare su micro e macro aree zone che manifestano sintomi legati ad un probabile fattore di stress (Oumar e Mutanga, 2013).

È inoltre possibile stimare la carenza nutrizionale, quindi il fabbisogno di nutrienti da apportare in una coltura, calcolando la regressione lineare tra la carenza di uno specifico nutriente e la rispettiva risposta nella luce riflessa dai tessuti (Ranjan et al., 2012; Mahajan et al., 2014).

Il grafico in figura 2.1(b) infatti focalizza le differenze di riflettanza in tre spettri di soia allevata con tre dosaggi di azoto differenti, mentre il grafico in figura 2.2(a) mostra come varia lo spettro di riflettanza di soia sottoposta ad uno stress abiotico indotto dalla salinità dell'acqua di irrigazione utilizzata.

In conclusione, possiamo affermare che grazie al RS è possibile collezionare l'intero spettro di riflettanza di una coltura con una certa cadenza ed a basso costo, ciò permette di identificare e geolocalizzare eventuali focolai di patogeni od aree manifestanti sintomi di stress di tipo abiotico: maggiore sarà la risoluzione delle immagini analizzate, maggiore sarà la precisione nell'identificare e monitorare i fattori di stress di una coltura (Zhang et al., 2019).

Al fine di discriminare la risposta del reale fattore causale dello stress nelle colture, da altri fattori di disturbo, è raccomandabile analizzare più immagini (3-5) rilevate in date diverse (Zhang et al., 2019).

Tutto ciò gioca un ruolo fondamentale nell'AP per poter distinguere e gestire zone con diverse caratteristiche nelle aree agricole. L'identificazione di zone omogenee, nonché aree agricole facilmente delineabili perché mostrano caratteristiche (tessitura del terreno, sostanza organica, carenze di nutrienti, concentrazione di malerbe...) simili al loro interno, ma diverse dal resto dell'appezzamento, permette di organizzare le lavorazioni agricole in base alla variabilità spaziale intrinseca all'area agricola. L'applicazione della tecnologia (VRT) permette quindi di dosare gli input agricoli per ogni singola zona omogenea aumentando l'efficienza dell'utilizzo dei fattori produttivi, rispetto ad una distribuzione standardizzata sull'intera area agricola: poter ricavare mappe di prescrizione (mappe virtuali che identificano le zone omogenee di un appezzamento), grazie al RS, ed eseguire lavorazioni VRT è una pratica che permette di aumentare il profitto degli agricoltori nel rispetto dell'ambiente (De Benedetto et al., 2013).

Il grafico in figura 2.3 dimostra il fatto che, le aziende che investono nell'AP veicolano la maggior parte dei loro investimenti nella mappatura delle produzioni e nel monitoraggio delle colture.

Altri parametri ottici misurabili tramite RS sono basati sul rilevamento dello spettro di emissività delle superfici foto sintetizzanti. Ciò rappresenta la radiazione termica emessa dai tessuti a causa dell'inefficienza dei processi biochimici coinvolti nella fotosintesi (effetto non fotochimico) e dal fenomeno di fluorescenza legato al funzionamento del foto sistema PSII (effetto fotochimico). Diversi fattori sono correlati allo spettro di emissività, in particolare l'efficienza dei processi di fotosintesi e la regolazione dell'evapotraspirazione, a loro volta questi parametri possono variare in presenza di stress biotici o abiotici (Nicolas, 2004): la misurazione della fluorescenza risulta essere uno probabile strumento per la diagnosi precoce di patogeni o stress abiotici nelle colture agrarie (Murchie e Lawson, 2013). Sebbene sia una tecnica di monitoraggio precisa e promettente vi sono due principali fattori che limitano l'estensione al monitoraggio di vaste aree agricole: gli strumenti presenti sul mercato sono molto costosi ed adatti ad effettuare misurazioni in prossimità della coltura, la maggior parte di essi funziona al buio od in presenza di sorgenti di luce controllata al fine di scorporare eventuali radiazioni luminose provenienti da altri oggetti (Zhang et al., 2019).

Le tecnologie SAR (Synthetic Aperture Radar) e LIDAR (Light Detection and Ranging) sono costituite da sensori di tipo attivo in grado di fornire informazioni anche ad elevata presenza di nuvole e foschia nell'atmosfera. SAR misura il grado di polarizzazione che la superficie al suolo ripercuote nelle onde inviate dal sensore; è stato applicato nella stima

del contenuto in acqua di specie vegetali (Capodici et al., 2017) e nell'identificazione di specie infestanti all'interno di un appezzamento agricolo (Singh et al., 2007).

LIDAR permette di ottenere informazioni riguardo alla struttura tridimensionale degli oggetti al suolo, è possibile stimare l'incremento di biomassa durante l'accrescimento dei vegetali o la perdita causata da patogeni, fitofagi o calamità naturali (Zhang et al., 2019). Entrambe queste tecnologie non sono ancora sfruttate su vaste aree agricole (Zhang et al., 2019).




Figura 2.3: L'aerogramma identifica a quali scopi sono stati destinati gli investimenti in AP avvenuti nell'anno 2016 (www.grandviewresearch.com, modificata).

2.3 Uso di dati da remoto come strumento previsionale della produttività

Perfezionare le tecniche colturali in zone considerate diverse tra loro all'interno di aree agricole, dipende dall'accuratezza con la quale esse vengono mappate e da come vengono stabiliti i fattori responsabili della variabilità in esse. Il monitoraggio della produzione fornisce ulteriori informazioni al fine di rendere più efficiente la gestione sito-specifica delle aree coltivate (Birrell et al., 1996).

Tramite il RS è possibile prevedere la variabilità della produzione che si otterrà alla raccolta, data la correlazione tra IV misurati in loco e la produttività sito-specifica. Un organismo vegetale produttivo e in piena salute assorbirà molta luce rossa data l'elevata concentrazione di clorofilla nei suoi tessuti verdi, vige quindi una correlazione negativa tra l'assorbanza di luce rossa rilevata da sensori ottici su colture agrarie e la loro produttività (Maestrini e Basso, 2018). Come raffigurato in figura 2.1(b) è possibile constatare come venga modificato lo spettro di riflettanza al solo variare della disponibilità di nutrienti.

Diversi fattori condizionano la produttività di una coltura: meteo, caratteristiche del suolo, tecniche agronomiche, patogeni... Alcuni sono prevedibili e manipolabili nel tempo (tecniche colturali), altri sono imprevedibili (meteo). Se si volesse considerare un solo fattore per la zonazione di aree agricole, il più affidabile risulterebbe essere il confronto dello storico delle mappe di produzione raccolte anche per colture diverse in annate differenti, tuttavia per avere un dato affidabile dell'annata in corso si può fare affidamento a determinati indici vegetazionali, come il normalized difference vegetation index (NDVI) (Maestrini e Basso, 2018). Utilizzando dati provenienti da immagini satellitari a risoluzione medio-bassa è possibile monitorare sia lo stato di salute di una coltura, sia stimarne variabilità e produttività (Gaadi et al., 2016).

Per poter stimare la produttività di un appezzamento, basandosi solo su dati satellitari, è necessario stabilire a priori un modello che restituisca dati inerenti alla variabilità della produzione. Nell'esecuzione di questo studio si è voluto prendere spunto dal modello descritto in altri progetti affini (Schwalbert et al., 2018; Bolton e Friedl, 2013; Gaadi et al., 2016; Kayad et al., 2016).

Secondo questi lavori è necessario disporre di dati satellitari dai quali calcolare gli IV e dati georeferenziati relativi alla resa ad ettaro, queste informazioni possono derivare dalle rese medie per appezzamento, da campionamenti in loco o raccolti da un sistema di rilevamento elettronico "on the go" della resa ad ettaro montato direttamente su macchine raccogliatrici.

Le procedure non prevedono di acquisire immagini ad elevata risoluzione (<10m), neppure nel caso in cui i dati di produzione provengano da mappe di produzione fornite dalle mietitrebbie, infatti essi vengono raccolti da moderne macchine che possono montare testate di dimensioni superiori ai 10m. La prassi prevede di calcolare il coefficiente di correlazione lineare (R^2) tra la produttività registrata e gli IV calcolati: l'IV raccolto nella data che mostra il valore di correlazione più alto indicherà il periodo temporale nel quale sarà possibile stimare la produzione per quella coltura in esame, come illustrato in figura 2.4. È importante testare diversi IV e non è possibile adattare lo stesso modello per colture diverse, in quanto esse danno risposte, in termini di riflettanza, differenti data la diversa composizione cellulare di specie diverse e durante la loro crescita (Bolton e Friedl, 2013).

Le figure 2.4(a) e 2.4(b) confrontano due modelli calcolati rispettivamente per mais e soia: è palese come due colture, sebbene entrambe estive, mostrino risultati di correlazione in periodi diversi.

L'intervallo di tempo viene identificato come “giorni dopo l'emergenza” o “giorni dopo la fioritura” e non con date specifiche, dato che i cicli colturali variano di anno in anno (Bolton e Friedl, 2013), figure 2.4 (c) e 2.4(d).

Determinati i migliori IV e il periodo ideale dal quale campionare le immagini satellitari, è possibile estrapolare un modello lineare, il quale permette di calcolare la produzione prevista inserendo nell'equazione i valori di un IV. Per far ciò va considerato l'IV che mostri sia la maggior correlazione con la produttività, sia equazioni della retta di regressione simili tra due o più appezzamenti. Per verificare l'efficacia del modello è possibile stimare la correlazione e la significatività tra produzione reale e produzione stimata, disponendo di altre mappe dove la produzione è nota, figura 2.5.




Figura 2.4: (a,b) Media dei coefficienti di correlazione tra produzione e tre IV ricavati in più anni, (a) calcolo per il mais, (b) per la soia; (c,d) coefficiente di correlazione tra produzione ed EVI calcolato in soia in annate differenti: (c) il risultato è espresso in giorni dell'anno, (d) in giorni trascorsi dopo l'emergenza. (Bolton e Friedl, 2013, modificata).

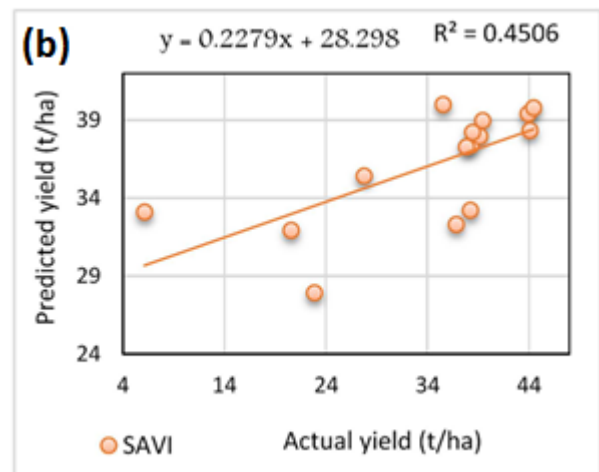
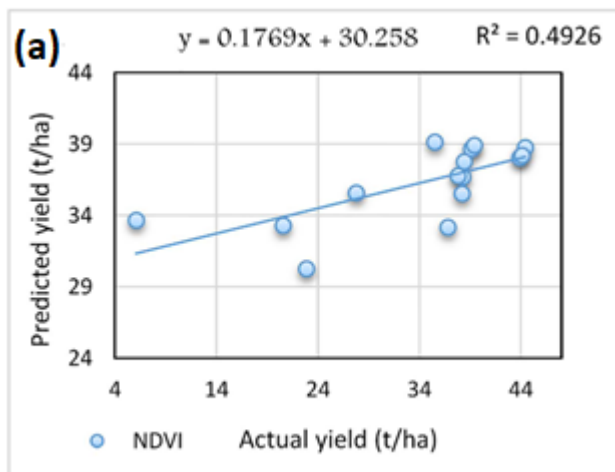


Figura 2.5: I grafici illustrano la retta di regressione calcolata tra la produzione reale in campo con NDVI (a) e SAVI (b). NDVI mostra un coefficiente di correlazione maggiore rispetto a SAVI, ciò significa che è un indice più affidabile rispetto a SAVI nella stima della produzione. (Gaadi et al., 2016, modificata).

Capitolo 3

MATERIALI E METODI

3.1 Sentinel-2

Nel presente studio è stato scelto come fonte di immagini satellitari la missione “Copernicus Sentinel-2”. Si tratta di un progetto avviato dall’Agenzia Spaziale Europea (ESA) con lo scopo di rilevare dati ed immagini dagli ambienti naturali del pianeta al fine di garantire il completo monitoraggio ambientale e della sicurezza. Sentinel-2 è composto da due satelliti identici, lanciati il 23 giugno 2015 ed il 7 marzo 2017, orbitano attorno al pianeta con due traiettorie sfalsate di 180° , così da garantire una frequenza di sorvolo dello stesso punto ogni 5 giorni all’equatore e ogni 2-3 giorni alle medie latitudini; le informazioni raccolte dalla missione sono a libero accesso. Nei due satelliti è presente un sensore ottico passivo multibanda: raccoglie immagini georeferenziate con ampiezza di 290km (superficie terrestre), rileva uno spettro che comprende visibile, vicino infrarosso (NIR) e infrarosso ad onde corte (SWIR); inoltre, è in grado di identificare 13 bande delle quali quattro con risoluzione di 10m, sei a 20m e tre a 60m. Le bande ed il range di onde captato è illustrato in tabella 3.1.

Il sensore fornisce immagini della superficie terrestre che si presentano corrette rispetto all’inquinamento luminoso generato dall’atmosfera; è in grado, inoltre, di individuare strati ritraenti neve o nuvole rispetto al suolo. Il set di bande rilevate dai sensori risulta molto utile per lo studio di aree naturali ed agricole, infatti è possibile stimare parametri biofisici di queste superfici come: l’indice di superficie fogliare (LAI) ed il contenuto di clorofilla; inoltre, permette di calcolare svariati IV (Delegido et al., 2011). Date le precedenti caratteristiche e l’elevata specializzazione nel cernere le bande tra la luce rossa ed il SWIR, Sentinel-2 sembra essere la fonte più adatta per lo studio di micro aree agricole. Dato che il primo satellite è in funzione dal 2015 e il secondo dal 2017, nel periodo che intercorre tra le due date la frequenza di rilievo delle immagini è di 10 giorni all’equatore anziché 5: è impossibile ottenere immagini da Sentinel-2 antecedenti all’anno 2015.

Tabella 3.1: Bande captate dal sensore ottico di Sentinel-2 e relativa risoluzione spaziale sulla terra, (www.satimagingcorp.com/, modificata).

Bande Sntinel-2	Lunghezza d'onda centrale (nm)	Risoluzione (m)
Band 1 - Coastal aerosol	443	60
Band 2 - Blue	490	10
Band 3 - Green	560	10
Band 4 - Red	665	10
Band 5 - Vegetation Red Edge	705	20
Band 6 - Vegetation Red Edge	740	20
Band 7 - Vegetation Red Edge	783	20
Band 8 - NIR	842	10
Band 8A - Vegetation Red Edge	865	20
Band 9 - Water vapour	945	60
Band 10 - SWIR - Cirrus	1.375	60
Band 11 - SWIR	1.610	20
Band 12 - SWIR	2.190	20

3.2 Indici vegetazionali

Un IV fornisce indicazioni riguardanti alcune proprietà correlate al colore della vegetazione e si concretizza in un'operazione matematica tra la misurazione dell'assorbanza di due o più bande ricavate dallo spettro di riflettanza degli organismi vegetali. Negli anni sono stati proposti vari metodi di calcolo ed ognuno identifica un IV, ogni operazione ha funzionalità e obiettivi differenti ma, tutti gli indici servono a fornire informazioni supplementari e paragonabili tra loro riguardo all'attività fotosintetica degli organismi vegetali. Le tre mappe riportate in figura 3.2 raffigurano il medesimo appezzamento dell'immagine satellitare raccolta in data 23 luglio 2018, è possibile apprezzare anche ad occhio nudo alcune sottili differenze grazie alla distribuzione della scala cromatica, tuttavia analizzando in profondità i diversi valori di assorbanza tra le bande considerate nei calcoli, risaltano differenze importanti tra IV diversi.

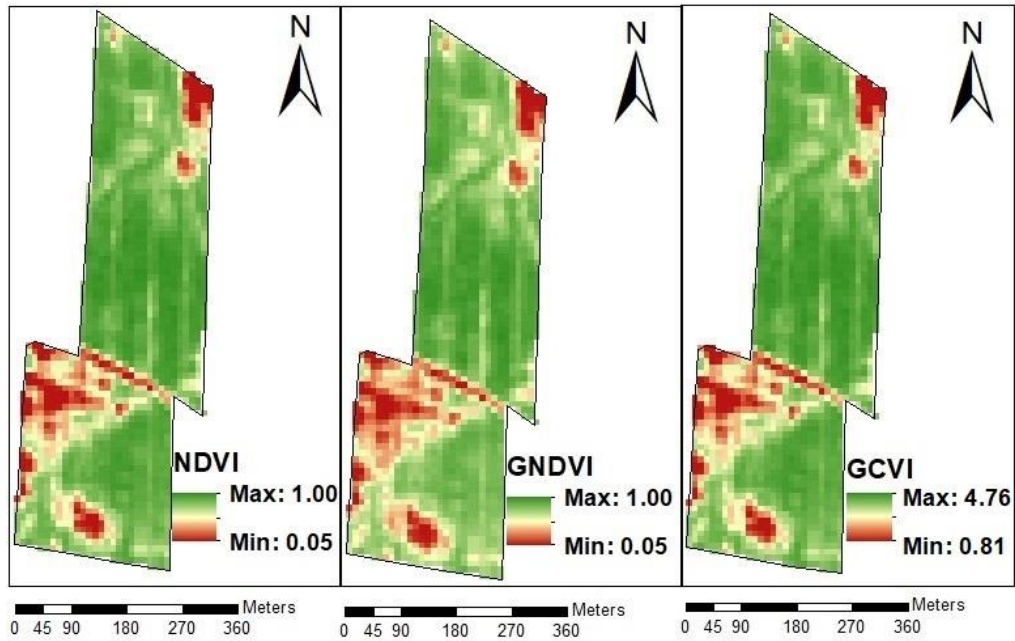


Figura 3.2: Tre mappe di un appezzamento in esame rappresentate con tre IV diversi campionati il 23 luglio 2018, rispettivamente da sinistra verso destra: NDVI, GNDVI, GCVI.

In questo lavoro sono stato calcolati otto IV per ogni mappa ad ogni telerilevamento.

$$\text{NDVI} = \frac{B8 - B4}{B8 + B4} \quad (1)$$

$$\text{NDRE} = \frac{B8 - B5}{B8 + B5} \quad (2)$$

$$\text{GNDVI} = \frac{B8 - B3}{B8 + B3} \quad (3)$$

$$\text{GARVI} = \frac{B8 - (B3 - B1 - B5)}{B8 - (B3 + B1 - B5)} \quad (4)$$

$$\text{EVI} = \frac{B8 - B4}{B8 + 6B4 - 7,5B1 + 1} \quad (5)$$

$$\text{WDRVI} = \frac{\alpha * B8 - B4}{\alpha * B8 + B4} \quad (6)$$

$$\text{GCVI} = \frac{B8}{B3} - 1 \quad (7)$$

$$\text{mWDRVI} = \begin{cases} \text{NDVI} & \text{NDVI} \leq 0.6 \\ \text{WDRVI} & \text{NDVI} > 0.6 \end{cases} \quad (8)$$

Le sigle presenti nelle equazioni (1÷8), fanno riferimento alle bande di Sentinel-2 riportate in tabella 3.1.

Normalized difference vegetation index (NDVI), la cui formula matematica è descritta dell'equazione (1), è il primo IV ad essere stato proposto da Rouse et al. nel 1973 (Rouse et al., 1973). Questo indice vuole marcare la differenza tra la luce rossa assorbita dalla clorofilla e la dispersione di radiazione NIR, riflessa per lo più dalla parete delle cellule (Edward et al., 2008). L'NDVI, è indubbiamente l'IV più studiato perché fornisce informazioni chiare sul contenuto in clorofilla dei tessuti vegetali grazie al quale è possibile stimare altri parametri biofisici: biomassa vegetale, LAI, contenuto in acqua, stato salutare di un organismo (Tucker, 1979).

Normalized Difference Red Edge (NDRE), descritto nell'equazione (2), facilita l'interpretazione dei livelli di clorofilla relazionando la luce riflessa NIR alla banda di confine tra il rosso visibile e l'infrarosso (Fitzgerald et al., 2010).

Green Normalized Difference Vegetation Index (GNDVI), descritto nell'equazione (3), è particolarmente sensibile al contenuto in clorofilla e risulta più efficace, rispetto all'NDVI, riguardo colture in fase di sviluppo avanzato (Gitelson et al., 1996).

Green Atmospherically Resistant Vegetation Index (GARVI) è descritto nell'equazione (4), mentre Enhance Vegetation Index (EVI) viene descritto nell'equazione (5), quest'ultimo contiene alcuni parametri che permettono di correggere il disturbo generato dalla luce riflessa dal suolo e dall'atmosfera (Huete et al., 2002; Xue e Su, 2017); nel presente studio è stato aggiunto un ulteriore fattore di correzione di 10000 allo scopo di ottenere risultati compresi in una scala da -1 a +1, come illustrato nell'equazione (9).

$$EVI = \frac{B8 - B4}{B8 + 6B4 - 7,5B1 + 10000} \quad (9)$$

Wide Dynamic Range Vegetation Index (WDRVI), descritto nell'equazione (6), restituisce migliori informazioni rispetto all'NDVI nella situazione in cui il LAI di una coltura supera il valore 2, nonché quando l'elevata biomassa prodotta da una coltura potrebbe interferire con il reale valore di clorofilla in essa contenuta (Gitelson et al., 2004; Xue e Su, 2017). Ponderando la misura del NIR con un valore σ compreso tra 0 e 1, si considera maggiormente la misurazione della banda B4; in questo lavoro è stato prescelto come valore $\sigma=0,20$ (Gitelson, 2004).

Green Chlorophyll Vegetation Index (GCVI), descritto nell'equazione (7), (Gitelson et al., 2003), ed infine mixed Wide Dynamic Range Vegetation Index (mWDRVI), descritto nell'equazione (8), quest'ultimo comprende valori di NDVI quando esso è minore di 0,6: a bassi valori fornisce indicazioni più accurate sul contenuto di clorofilla dei vegetali, al contrario del corrispettivo WDRVI, più accurato a valori elevati.

3.3 Software ausiliari

Nel presente studio sono stati utilizzati quattro software per processare i dati: Google Earth Engine (GEE), Arcmap 10.3.1, Microsoft Office Excel e AgLeader SMS basic.

3.3.1 Google Earth Engine

GEE è un servizio gratuito di Google LLC, si tratta di una piattaforma virtuale di calcolo presente nel cloud, la quale:

- Fornisce gratuitamente vari set di dati geospaziali raccolti da missioni satellitari come Sentinel, EROS (USGS/NASA) Landsat, Modis, NAIP e CHIRPS permette di effettuare calcoli ed esportare gli stessi dati;
- Permette di caricare sulla piattaforma dati personali in vari formati;
- Fornisce diversi algoritmi nei quali inserire i dati spaziali ed effettuare calcoli su di essi;
- Permette di esportare grafici, file e mappe in diversi formati come risultato dell'elaborazione delle informazioni dal cloud;

Nella piattaforma non è presente una vera e propria interfaccia di lavoro, ma presenta una finestra di dialogo chiamata "Script" nella quale inserire il "code editor" nel linguaggio API JavaScript. Questo linguaggio permette di concepire un algoritmo personalizzato in base alle esigenze di ogni singolo utente, concede inoltre di salvare e condividere con altri utenti l'algoritmo generato.

In questo lavoro, GEE, è stato di fondamentale importanza per il calcolo e l'esportazione di una serie cronologica di mappe che riportano gli IV per tutto il periodo in cui la coltura era in campo e per ogni appezzamento studiato.

3.3.2 ArcGis

ArcMap10.3.1 è un software GIS (Geographic information system) componente del programma a pagamento ArcGis fornito da Esri ed utilizzato nell'elaborazione dei dati spaziali:

1. Filtrazione delle mappe di resa da dati poco rappresentativi;
2. Tracciatura dei confini degli appezzamenti;
3. Supervisione ed esportazione in estensione .dbf (formato dBase) delle mappe ricampionate in GEE.

3.3.3 SMS basic

SMS basic è un prodotto della compagnia AgLeader, il quale è stato utilizzato al fine di esportare le mappe di raccolta dal monitor della macchina raccogliitrice e convertirle in formato “shape file” (.shp).

3.3.4 Excel

Excel è stato sfruttato per la visualizzazione dei dati, per ricavare ed analizzare vari grafici ed infine per il calcolo dei fattori di correlazione tra produzione e IV, nonché analisi della varianza (ANOVA). Il processo è automatizzabile in GEE, ma si è preferito procedere tramite Arcmap ed Excel, potendo visualizzare e supervisionare i dati originali è possibile trarre eventuali conclusioni alternative od ulteriori informazioni in merito al fenomeno.

3.4 Mappe di produzione

3.4.1 Aree studio

Come aree studio sono stati ricercati appezzamenti coltivati a soia: essendo una coltura estiva è più probabile che Sentinel-2 fornisca immagini nitide, con poca nuvolosità rispetto a colture autunno vernine. Gli appezzamenti sono di superficie piuttosto ampia, maggiori di 10ha, compatti e di forma poligonale, ciò per poter discriminare al meglio eventuali zone omogenee al loro interno e per poter ottenere il maggior numero di pixel ben raggruppati. È inoltre importante analizzare aree provenienti dalla stessa area geografica, al fine di scorporare dal risultato l'eventuale variabilità causata dall'angolo di ricezione della luce tra la superficie terrestre ed il satellite. Utilizzando immagini Sentinel-2 non è stato possibile considerare raccolti avvenuti prima dell'anno 2015.

Le aree considerate, figura 3.3 e tabella 3.2, sono localizzate nella Pianura Padana a sud della regione Veneto in provincia di Rovigo, nello specifico comprese nel fuso UTM zone 32N, (codice EPSG: 25832). I terreni sono di origine alluvionale e di tessitura tendenzialmente argillosa, l'agricoltore impiega le classiche tecniche agronomiche dettate dall'agricoltura convenzionale.




Figura 3.3: Mappa delle 4 aree studio considerate, la tabella riporta ulteriori informazioni riguardo a: nome che identifica ogni appezzamento e relativo colore nella mappa, superficie coltivata espressa in ha, coltura in atto, data di semina e raccolta.

Tabella 3.2: Caratteristiche degli appezzamenti e relativo colore con le quali vengono identificate in figura 3.3.

Nome Appezzamento	Area ha	Coltura	Data semina	Data raccolta
CNS 2018	18,4	Soia	20-mag-18	18-set-18
RFS 2018	12,5	Soia	20-mag-18	18-set-18
PVS 2017	10,8	Soia	12-mag-18	17-set-17
AFS 2017	9,4	Soia	11-mag-17	23-set-17
PAS 2017	11,4	Soia	25-apr-17	21-set-17
RZS 2016	15,1	Soia	15-mag-16	16-set-16
BDS 2016	10,5	Soia	8-mag-16	13-set-16

3.4.2 Raccolta dati satellitari

Le immagini satellitari sono state raccolte grazie a GEE e gli IV sono stati calcolati sfruttando la medesima piattaforma.

Le operazioni eseguite su GEE sono le seguenti:

1. Caricamento sulla piattaforma dei confini dell'appezzamento in esame in formato shape file;
2. Caricamento sulla piattaforma della mappa di resa interpolata, tramite operazione di kriging, in formato GeoTIFF;

3. Selezione della collezione di immagini dal data set di Sentinel-2, filtrate per il periodo desiderato e scartando immagini con elevato numero di pixel coperti da nubi (>20%);
4. Calcolo di 8 IV per ogni immagine fornita da Sentinel-2;
5. Codifica di un grafico che relaziona il valore di ogni IV alla data di raccolta al fine di scartare manualmente eventuali immagini anomale (ad esempio nel caso in cui pochi pixel coperti da nubi fossero condensati sopra l'area agricola);
6. Esportazione di un file in formato GeoTIFF, nel quale viene ri-campionata la resa in campo con tutti gli IV calcolati per ogni data disponibile.

Di seguito viene riportato il link che riconduce direttamente ad una scheda di GEE con lo stesso script utilizzato nel calcolo degli IV, le voci "table" e "prod" indicano rispettivamente lo shape file dei confini e il file GeoTIFF della produzione:
<https://code.earthengine.google.com/5a101b71acde4f33d68e9861d6710e00>

3.4.3 Raccolta dati di produzione

I dati di produzione sono stati forniti dalla ditta agromeccanica "Mantovani Lino & Loris", che opera in una vasta area tra la provincia di Rovigo e quella di Ferrara. I dati sono raccolti da una mietitrebbia semovente modello "Case IH AXIAL-FLOW 9230", grazie alla tecnologia "AFS Harvest Command™" il monitor "AFS Pro 700" restituisce mappe di resa degli appezzamenti mietuti georeferenziate. Il sistema rileva i dati di resa ad ettaro ad intervalli di un secondo: considerando che la macchina monta una testata di raccolta da 9 m di capacità utile e che esegue le lavorazioni di raccolta ad una velocità media di circa 7 Km/h, ogni mappa contiene almeno 570 rilievi di resa ad ettaro, ognuno integrato con specifiche coordinate geografiche. Il numero di rilievi è generalmente molto maggiore, se consideriamo il fatto che raramente la testata lavora alla piena capacità, inoltre vanno considerati i rallentamenti in fase di manovra e svolta: minore sarà la superficie coltivata, maggiore sarà il numero di rilievi ad ettaro, a causa dei numerosi episodi di manovra e doppie passate.

Oltre ai dati di resa il monitor restituisce altre importanti informazioni tra cui: umidità e frazione proteica del prodotto raccolto, volume e massa delle granelle, larghezza di lavoro della testata, velocità di avanzamento ed altre specifiche della macchina. L'azienda ha fornito numerosi dati di raccolta di appezzamenti di proprietà o in affitto, sono stati selezionati quelli di dimensione maggiore e di forma poligonale. Le uniche informazioni reperite dalla ditta per ogni appezzamento sono: coltura, data di semina, data di raccolta, mappa di produzione, caratteristiche dei terreni e superficie. Vari parametri, come varietà

di soia coltivata, concimazione e irrigazione, sono stati ignorati perché: si disponeva di troppi pochi appezzamenti per poter categorizzare e confrontare aree coltivate nello stesso modo, si voleva verificare l'esistenza di un risultato trasversale e applicabile a tutte le aree purché coltivate a soia.



Figura 3.4: Macchine raccogliatrici appartenenti alla ditta “Mantovani Lino&Loris” in campo.

3.4.4 Elaborazione dei dati

Le mappe “grezze” di produzione sono state convertite in formato .shp con il software SMS basic e rielaborate con ArcMap. In ArcMap le mappe grezze sono state filtrate, in particolare sono state ripulite da dati ritenuti poco reali e poco rappresentativi dell'intera area coltivata, al fine di evitare che tali dati compromettessero l'identificazione delle zone omogenee. La filtrazione consiste nelle seguenti operazioni:

1. Eliminazione di tutti i dati posizionati a meno di 10m dal confine dell'area coltivata, questo per cancellare le testate e punti nei quali con elevata probabilità la macchina raccogliatrice è passata più volte, commettendo probabilmente errori nella raccolta del dato, in aggiunta restringendo i bordi si evita che colture od alberature lungo i confini vengano campionate dai foto rilievi satellitari;
2. Eliminazione di dati che mostravano produzioni eccessivamente basse od eccessivamente elevate, causate da doppi passaggi nell'appezzamento; è facile riconoscere queste aree, perché solitamente sono spot o brevi strisciate ravvicinate e contornate da zone con produttività completamente differente;
3. Eliminare tutti i dati distribuiti a \pm tre deviazioni standard rispetto alla media di produzione del campo, perché considerati valori anomali che possono interferire nel processo di zonazione dell'area (Amidan et al., 2005; Cordoba et al., 2016).

In ArcMap è stata inoltre eseguita un'interpolazione dei dati spaziali tramite un processo di regressione gaussiana denominato “kriging”, il comando restituisce un raster omogeneo delimitato dai confini dell'appezzamento. È stata infine ridotta la risoluzione della mappa a 10m x 10m, la stessa delle immagini di Sentinel-2; il procedimento è rappresentato dalla figura 3.5.

La mappa ri-campionata da GEE è stata supervisionata nuovamente con ArcMap ed esportata in formato .dbf al fine di eseguire l'analisi statistica su un foglio elettronico di Excel.

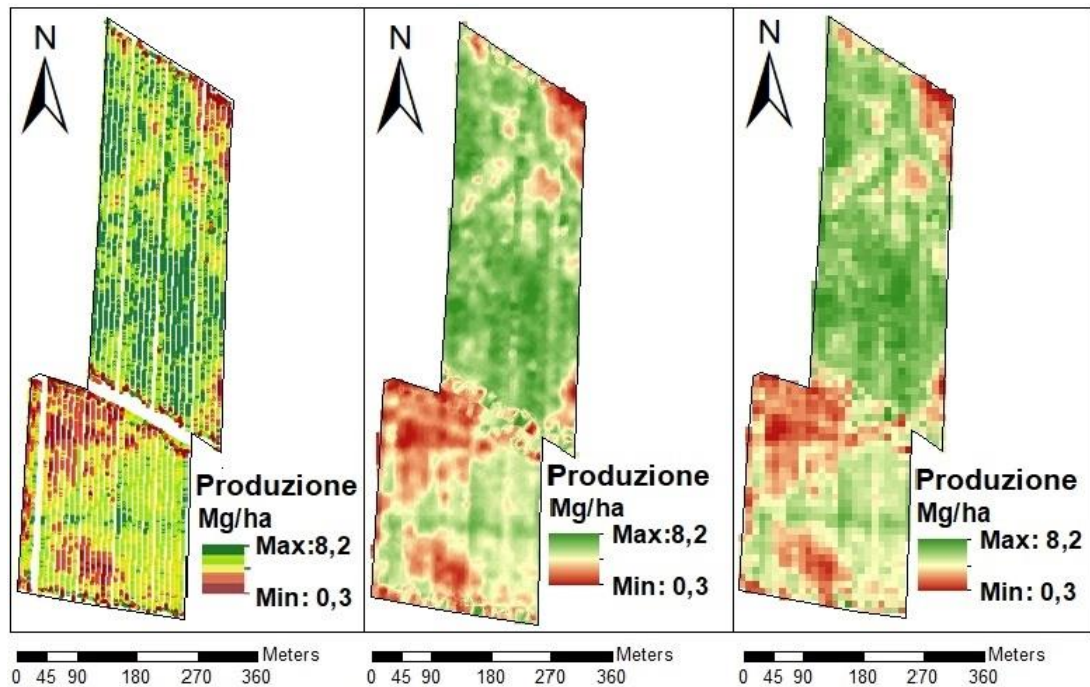


Figura 3.5: a) Mappa di produzione “filtrata”. b) Kriging raster, risoluzione ad 1m. c) Raster ri-campionato a 10m.

Capitolo 4

CASO STUDIO

4.1 Analisi della correlazione

L'analisi della correlazione è stata formulata confrontando i dati di produzione ad ogni IV, per ogni rilievo satellitare, sfruttando i fogli di calcolo in Microsoft Excel. I calcoli hanno restituito come risultati: il valore del coefficiente di correlazione (R^2) tra le due serie di dati, l'equazione della retta di regressione tra le variabili e la significatività della correlazione (tramite ANOVA).

Di seguito, figura 4.1, possiamo osservare i grafici riferiti alle quattro aree studiate che illustrano l'evoluzione del coefficiente di correlazione (R^2) durante tutta la stagione: è interessante notare come la correlazione tra IV e produttività mostri i valori massimi in un periodo abbastanza comune a tutti i grafici. La variabile "tempo" è espressa in giorni dopo la semina (in anglosassone days after sowing, DAS), è stata scelta questa espressione per mantenere delle indicazioni di tipo predittivo rispetto alla raccolta, ciononostante poter disporre di informazioni riguardo al periodo nel quale si manifesta un preciso stadio fenologico della coltura (ad esempio l'emergenza, il raggiungimento di un determinato numero di foglie, la fioritura...) fornirebbe sicuramente risultati più accurati, in quanto la sola data di semina è un dato aleatorio rispetto alla durata di un ciclo colturale. Infatti, considerando la variabile tempo in giorni prima della raccolta (in anglosassone days before harvesting DBH), il periodo di massima correlazione confrontato fra tutte le aree si restringe a circa 10 giorni rispetto ai 25 se espresso in DAS.

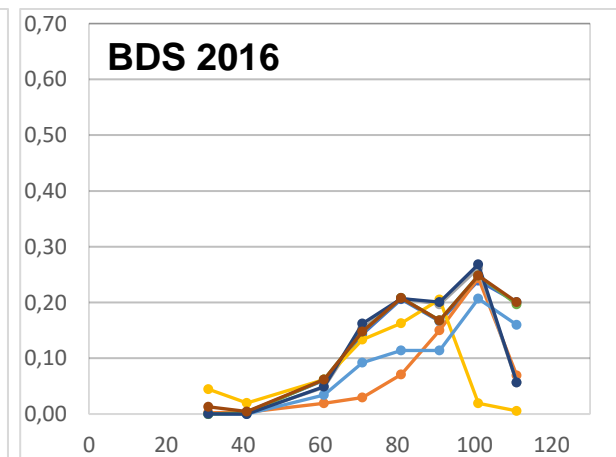





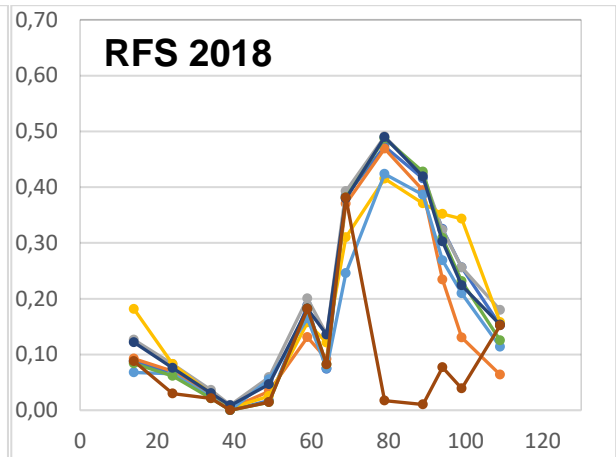



Figura 4.1: Sette grafici riferiti ad ognuna delle aree analizzate, rispettivamente: CNS 2018, RFS 2018, PVS 2017, AFS 2017, PAS 2017, RZS 2016, BDS 2016. Nell'asse delle ascisse vengono riportati i giorni dopo la semina "days after sowing" (DAS), nell'asse delle ordinate compare il fattore di correlazione (R^2) tra la produttività ed ogni IV.

Inoltre, vengono proposti i grafici di dispersione come confronto della relazione tra produttività e IV, dai quali è possibile ricavare il valore di R^2 oltre all'equazione della retta di regressione; i dati appaiono "tagliati" all'estremità destra della distribuzione a causa della filtrazione operata in fase di elaborazione dei dati di produzione. Tutti i grafici, (figura 4.2-4.8) sono stati ricavati dal confronto tra la produttività verificata in campo e l'IV, nella data in cui mostrava la massima correlazione. Sono stati riportati i tre indici che, mediamente, risultano i migliori per valori di R^2 in tutte le aree, oltre a l'NDVI, riportato come termine di paragone essendo l'IV più studiato e conosciuto. I coefficienti di correlazione delle rette risultano essere maggiori a 0,40 in un periodo indicativo da 80 a 105 DAS in quasi tutte le aree, ad eccezione del caso RZS 2016 dove la correlazione è generalmente più bassa. In tabella 4.1 sono riassunte tutte le rette di correlazione tra tutti gli IV calcolati, il coefficiente di correlazione ed il risultato dell'analisi statistica eseguita al fine di valutare la significatività della correlazione.

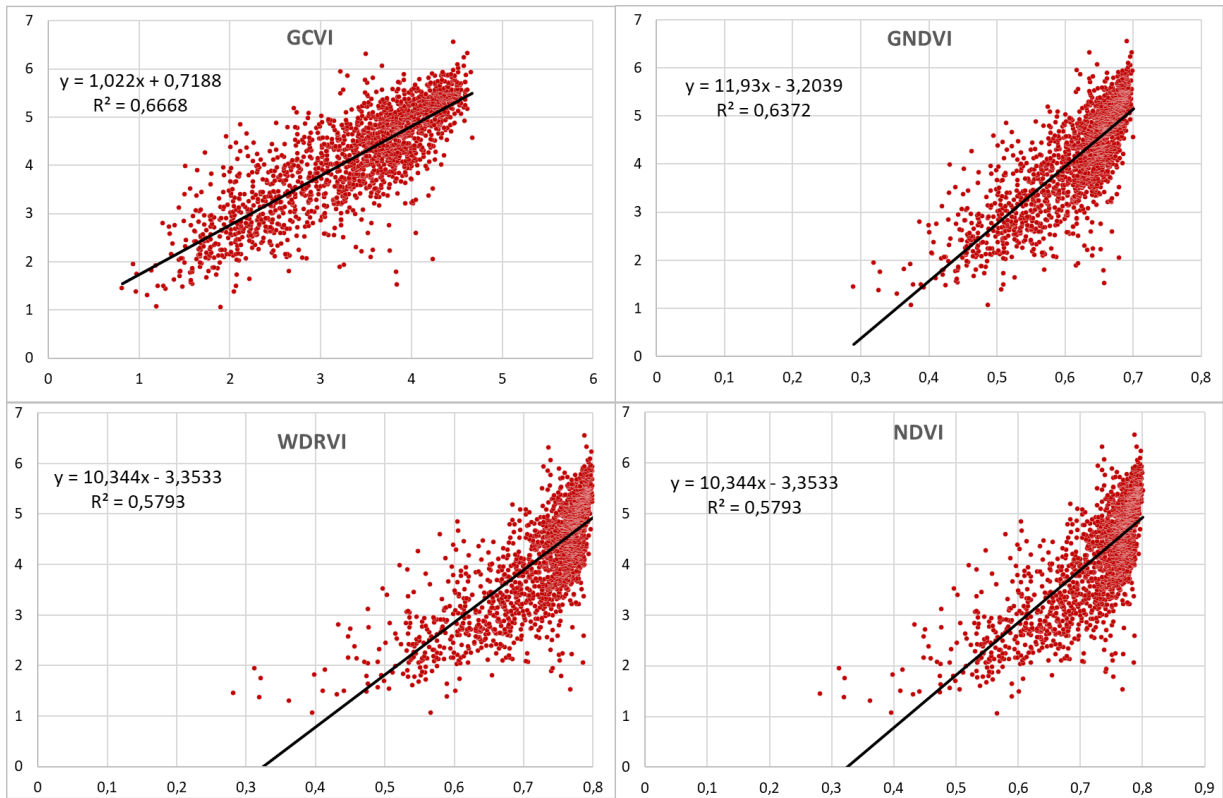


Figura 4.2: Correlazione tra IV e produzione per l'area CNS 2018, data 22 agosto 2018, nell'asse delle ascisse vengono riportati i valori di IV, nell'asse delle ordinate la produzione in Mg/ha

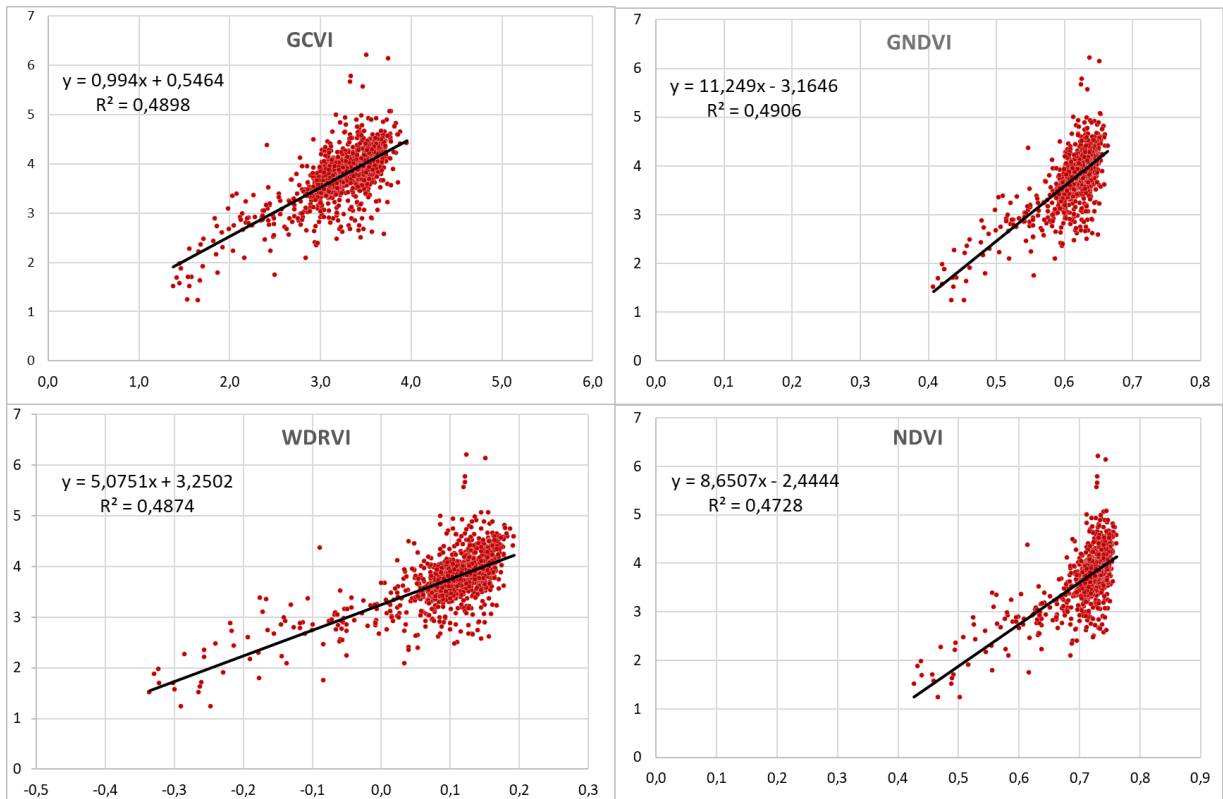


Figura 4.3: Correlazione tra IV e produzione per l'area RFS 2018, data 7 agosto 2018, nell'asse delle ascisse vengono riportati i valori di IV, nell'asse delle ordinate la produzione in Mg/ha.

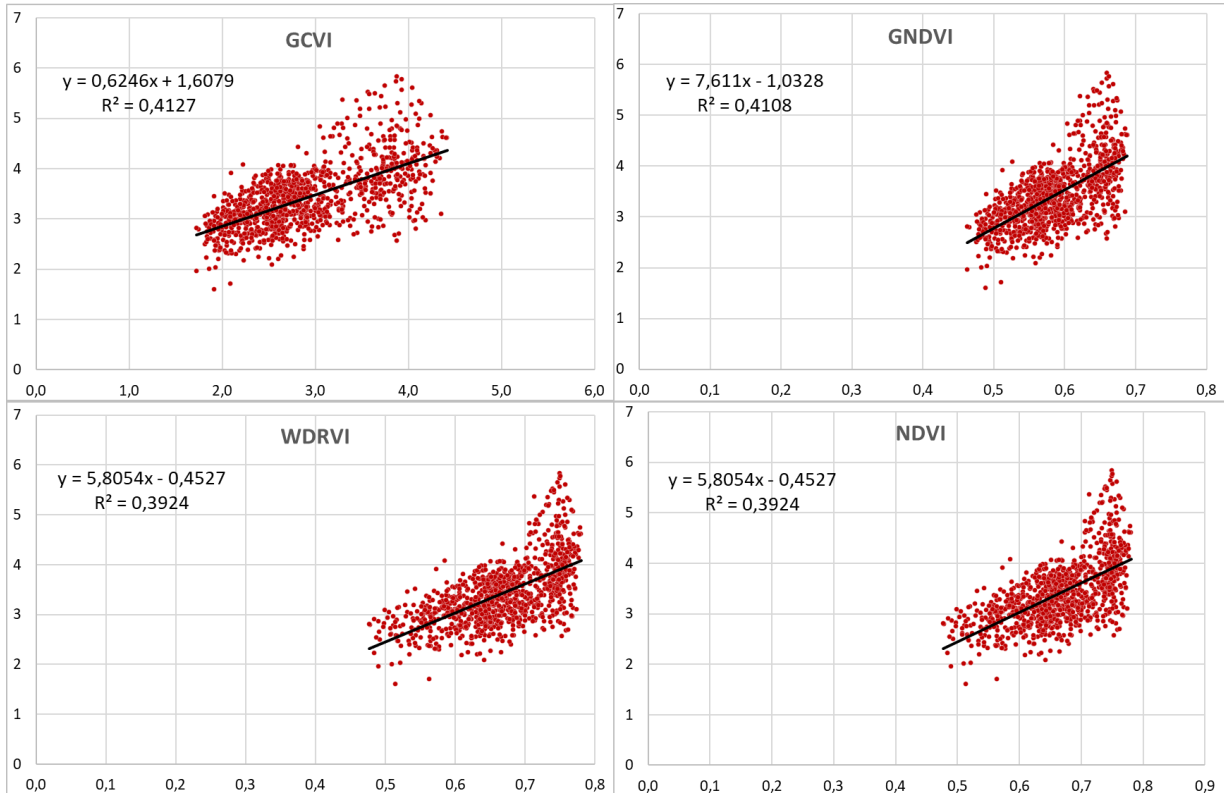


Figura 4.4: Correlazione tra IV e produzione per l'area PVS 2017 data 22 agosto 2017, nell'asse delle ascisse vengono riportati i valori di IV, nell'asse delle ordinate la produzione in Mg/ha.




Figura 4.5: Correlazione tra IV e produzione per l'area AFS 2017 data 22 agosto 2017, nell'asse delle ascisse vengono riportati i valori di IV, nell'asse delle ordinate la produzione in Mg/ha.

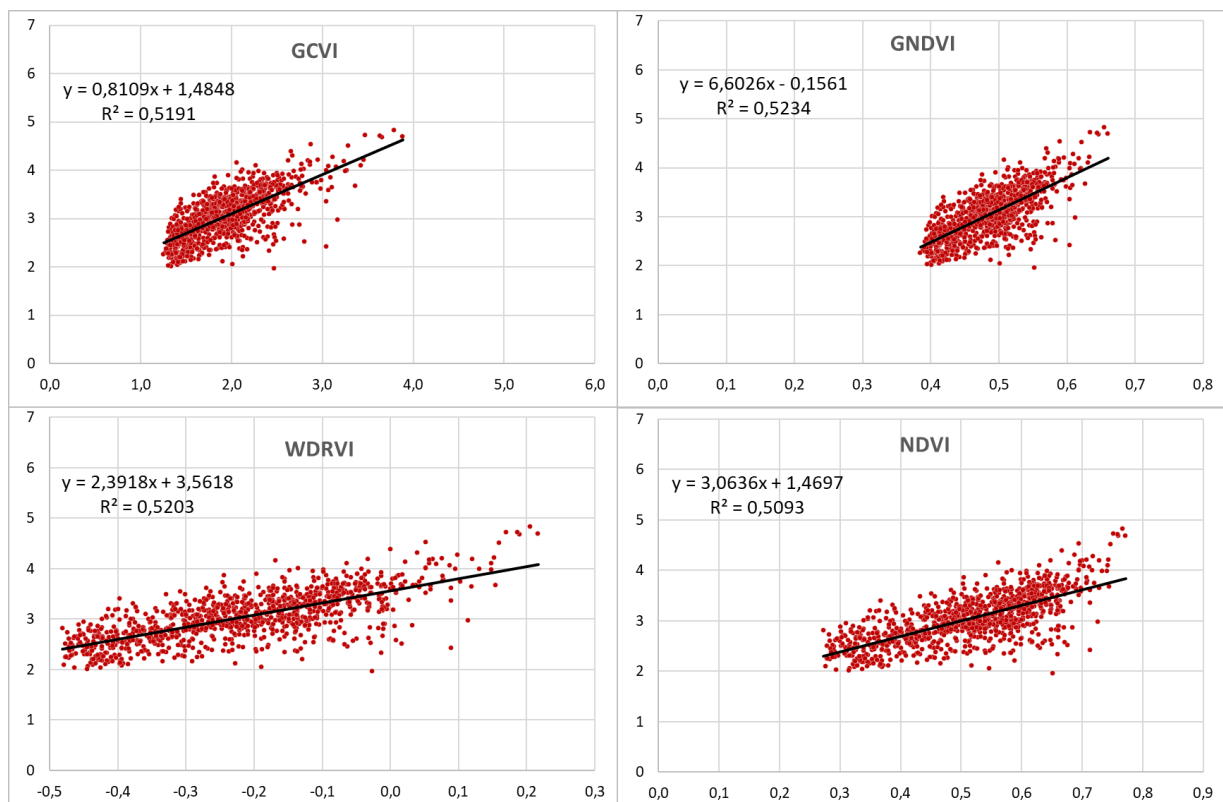


Figura 4.6: Correlazione tra IV e produzione per l'area PAS 2017 data 22 agosto 2017, nell'asse delle ascisse vengono riportati i valori di IV, nell'asse delle ordinate la produzione in Mg/ha.

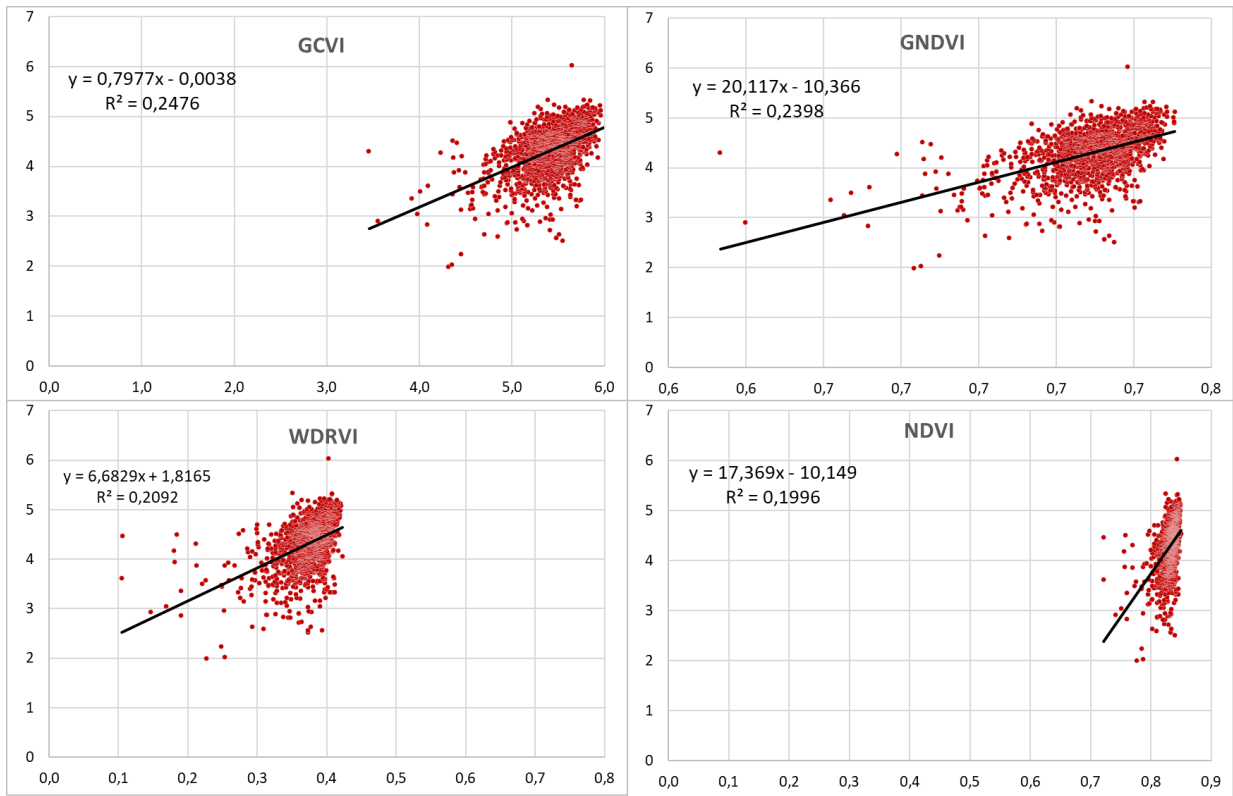


Figura 4.7: Correlazione tra IV e produzione per l'area RZS 2016 data 7 agosto 2016, nell'asse delle ascisse vengono riportati i valori di IV, nell'asse delle ordinate la produzione in Mg/ha.




Figura 4.8: Correlazione tra IV e produzione per l'area BDS 2017 data 22 agosto 2016, nell'asse delle ascisse vengono riportati i valori di IV, nell'asse delle ordinate la produzione in Mg/ha.

Il modello lineare è stato calcolato sfruttando l'equazione della retta di regressione tra GCVI, in data 22 agosto 2018 e produzione di CNS 2018, (10) e verificato per tutte le altre aree nella utilizzando i valori dello stesso indice calcolato nella data in cui mostra la massima correlazione con la resa dei rispettivi appezzamenti. Si è optato per questa equazione perché nessun'altra combinazione IV ed area mostra valori più alti di R^2 , inoltre l'equazione che descrive la retta di regressione è abbastanza simile tra tutte le aree.

$$\text{Produzione attesa} = 1,022\text{GCVI} + 0,7188 \quad (10)$$

In figura 4.9 viene illustrata la relazione tra produzione reale e produzione prevista con il modello lineare. Oltre all'analisi ANOVA si è calcolata la deviazione standard degli scarti, (in anglosassone, Root Mean Square Error, RMSE), al fine di quantificare l'errore sulla stima della produzione ad ettaro, equazione (11).

$$\text{RMSE} = \sqrt{\frac{\sum_{i=1}^n (y_i - x_i)^2}{n}} \quad (11)$$

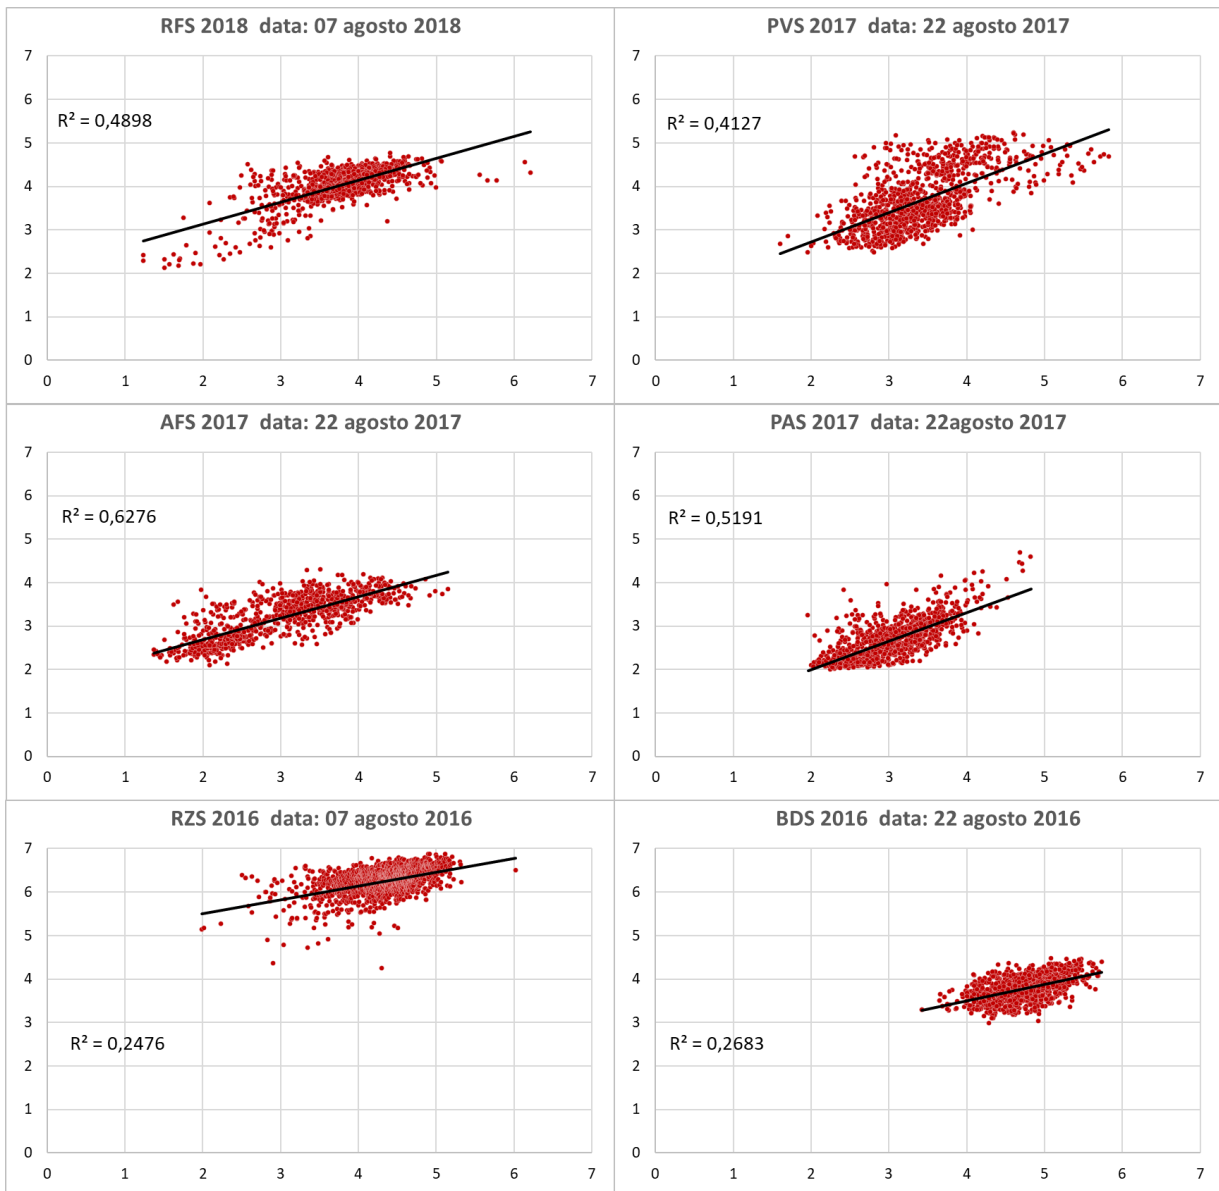


Figura 4.9: I sei grafici di dispersione illustrano la relazione tra produzione reale, asse delle ascisse, e produzione prevista dal modello lineare, asse delle ordinate. Viene riportata l'equazione della retta di correlazione ed il valore del coefficiente di correlazione (R^2) per ogni area. La data indica il giorno nel quale sono stati raccolti i dati da Sentinel-2 per il calcolo del GCVI. L'analisi statistica conferma l'evidenza della correlazione anche con valore di $P \leq 0.01$.

Tabella 4.1: Equazioni delle rette di regressione tra IV e resa, coefficiente di correlazione (R²); ** significa che è stata dimostrata la significatività nella correlazione con valore P ≤ 0.01.

IV	Equazione retta di regressione	R ²		IV	Equazione retta di regressione	R ²	
CNS 2018				RFS 2018			
NDVI	y=10,344x - 3,3533	0,58	**	NDVI	y=8,6507x - 2,4444	0,47	**
NDRE	y=9,5454x - 1,6783	0,63	**	NDRE	y=7,8432x - 1,0184	0,47	**
GNDVI	y=11,93x - 3,2039	0,64	**	GNDVI	y=11,249x - 3,1646	0,49	**
GARVI	y=-0,1822x + 2,8102	0,54	**	GARVI	y=-3,0117x + 10,034	0,42	**
EVI	y=3,785x + 0,0192	0,58	**	EVI	y=3,0627x + 0,3614	0,42	**
WDRVI	y=10,344x - 3,3533	0,58	**	WDRVI	y=5,0751x + 3,2502	0,49	**
GCVI	y=1,022x + 0,7188	0,67	**	GCVI	y=0,994x + 0,5464	0,49	**
mWDRVI	y=10,344x - 3,3533	0,58	**	mWDRVI	y=-0,8031x + 3,846	0,02	**
PVS 2017				AFS 2017			
NDVI	y=5,8054x - 0,4527	0,39	**	NDVI	y=7,9548x - 1,9553	0,67	**
NDRE	y=4,723x + 1,0639	0,42	**	NDRE	y=8,8545x - 0,9595	0,62	**
GNDVI	y=7,611x - 1,0328	0,41	**	GNDVI	y=12,141x - 3,5497	0,63	**
GARVI	y=-2,8528x + 8,7525	0,23	**	GARVI	y=-3,0376x + 9,2277	0,52	**
EVI	y=5,3997x + 1,2582	0,38	**	EVI	y=7,9147x + 0,1617	0,65	**
WDRVI	y=5,8054x - 0,4527	0,39	**	WDRVI	y=5,0878x + 3,3167	0,68	**
GCVI	y= 0,6246x + 1,6079	0,41	**	GCVI	y=1,3049x - 0,1294	0,63	**
mWDRVI	y=5,8054x - 0,4527	0,39	**	mWDRVI	y=-2,0704x + 3,4518	0,39	**
PAS 2017				RZS 2016			
NDVI	y=3,0636x + 1,4697	0,51	**	NDVI	y=17,369x - 10,149	0,20	**
NDRE	y=4,6623x + 1,4917	0,54	**	NDRE	y=8,7711x - 1,8768	0,14	**
GNDVI	y=6,6026x - 0,1561	0,52	**	GNDVI	y=20,117x - 10,366	0,24	**
GARVI	y=-1,7771x + 6,659	0,52	**	GARVI	y=-4,5477x + 11,646	0,26	**
EVI	y=4,3991x + 1,9773	0,52	**	EVI	y=1,7792x + 3,4086	0,01	**
WDRVI	y=2,3918x + 3,5618	0,51	**	WDRVI	y=6,6829x + 1,8165	0,21	**
GCVI	y=0,8109x + 1,4848	0,45	**	GCVI	y=0,7977x - 0,0038	0,25	**
mWDRVI	y=-0,6277x + 3,2655	0,10	**	mWDRVI	y=6,6651x + 1,8231	0,21	**
BDS 2016							
NDVI	y=5,2595x + 0,9713	0,24	**				
NDRE	y=4,7621x + 2,4473	0,24	**				
GNDVI	y=8,8799x - 0,5754	0,26	**				
GARVI	y=-0,9738x + 6,4469	0,02	**				
EVI	y=4,7347x + 2,9091	0,21	**				
WDRVI	y=2,6653x + 4,4769	0,25	**				
GCVI	y=0,7294x + 2,5537	0,27	**				
mWDRVI	y=2,6653x + 4,4769	0,25	**				

4.2 Risultati principali

Dall'osservazione dei grafici in figura 4.1, possiamo dedurre che: GCVI, GNDVI e WDRVI sono i tre indici maggiormente correlati alla produzione in tutte le aree, il periodo in cui si verifica la massima correlazione tra IV e produttività è stimato a circa 85-105 giorni dopo la semina, nonché circa 30-20 giorni prima della raccolta del prodotto secco. L'area CNS 2018 è indubbiamente quella che dimostra la massima correlazione tra produttività ed IV, in particolare GCVI, GNDVI e WDRVI mostrano i più alti coefficienti di correlazione nel periodo 71-101 DAS. Lo si può notare anche ad occhio nudo nel paragone tra la produzione e tre IV, proposto in figura 4.10, ed è matematicamente dimostrato dalle rette di correlazione descritte nei grafici in figura 4.2.

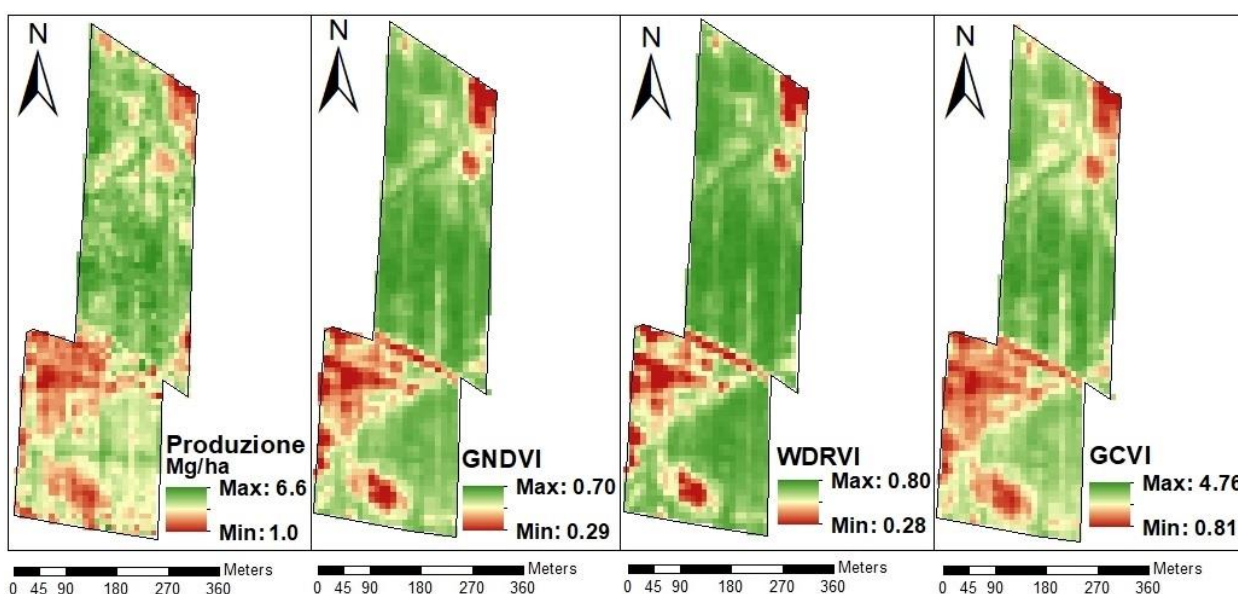


Figura 4.10: Da sinistra verso destra: mappa di produzione di soia dell'area CNS 2018, NDVI, GCVI e WDRVI. I raster sono stati ottenuti per interpolazione gaussiana (kriging) ed hanno una risoluzione di 10m per lato dei pixel. L'immagine satellitare da cui sono stati calcolati gli IV è datata 22 agosto 2018, nonché 86 DAS o 27 giorni prima della raccolta.

Il modello previsionale è apparso molto valido, mostrando valori di R^2 compresi tra 0.41 e 0.63 in quattro aree su sei, tabella 4.2, le due aree dalle quali i dati provengono dall'anno 2016 mostrano entrambe bassa correlazione (R^2 di 0.25 verificato in RZS 2016 e R^2 di 0.27 in BDS 2016). Tuttavia la significatività della correlazione è stata testata anche con valori di $P \leq 0,01$. Il calcolo dell'indice RMSE ha confermato che i valori sono paragonabili tra gli anni 2018 e 2017, mentre sono da ritenersi eccessivi nell'anno 2016.

Tabella 4.2: Valori di deviazione standard degli scarti (RMSE), coefficiente di correlazione (R^2) e significatività della correlazione dimostrata per valori di $P \leq 0,01$.

	RFS 2018	PVS 2017	AFS 2017	PAS 2017	RZS 2016	BDS 2016
RMSE Mg/ha	0,47	0,61	0,53	0,49	2,07	1,02
R^2	0,49	0,41	0,63	0,52	0,25	0,27
Significatività	**	**	**	**	**	**

4.3 Discussione

Le motivazioni per cui GCVI, GNDVI e WDRVI dimostrano un maggior grado di correlazione rispetto agli altri IV, possono essere in parte spiegate dal fatto che essi sono maggiormente sensibili alla concentrazione di clorofilla nei tessuti verdi quando le colture appaiono particolarmente dense, (Gitelson et al., 1996), l'indice di superficie fogliare supera il valore 2, (Gitelson et al., 2004), oppure l'indice di superficie fogliare supera il valore 3 (Viña et al., 2011).

Cinque grafici su sette, figura 4.1, mostrano una notevole correlazione nei primissimi giorni di sviluppo della coltura, quando il suolo è ancora spoglio ed è presente solo soia nei primi stadi di accrescimento. Possiamo dedurre che quelle zone in cui la coltura ha potuto accrescere in modo rapido e vigoroso, fin dai primi stadi di sviluppo, hanno ottenuto produzioni elevate; viceversa aree in cui la coltura ha avuto un accrescimento stentato, fin dal post-emergenza, hanno mantenuto bassi livelli di produzione.

Il periodo ottimale per il telerilevamento coincide con il mese di agosto, in questo arco di tempo la soia si trova nella fase più delicata del ciclo colturale, ovvero la formazione ed il riempimento dei semi: stadio R5. In questo periodo stress di qualsiasi genere, in particolare carenza idrica, possono compromettere in modo marcato la produzione, mentre un adeguato approvvigionamento idrico e nutrizionale permette di ottenere le massime rese (Giardini e Baldoni, 2001). Le buone pratiche agronomiche prevedono di irrigare, se necessario, la coltura proprio nel mese di agosto ed è addirittura comune la pratica di distribuire concimi a base di azoto in copertura, proprio per far fronte all'elevato fabbisogno nutrizionale riscontrato in questo periodo. Dal grafico in figura 4.11 è evidente quale sia l'accumulo di sostanza secca ed azoto nella coltura tra gli stadi R5 e R7, compresi generalmente nel mese di agosto alle nostre latitudini, in particolare come l'azoto assimilato venga destinato per lo più alla composizione dei semi.

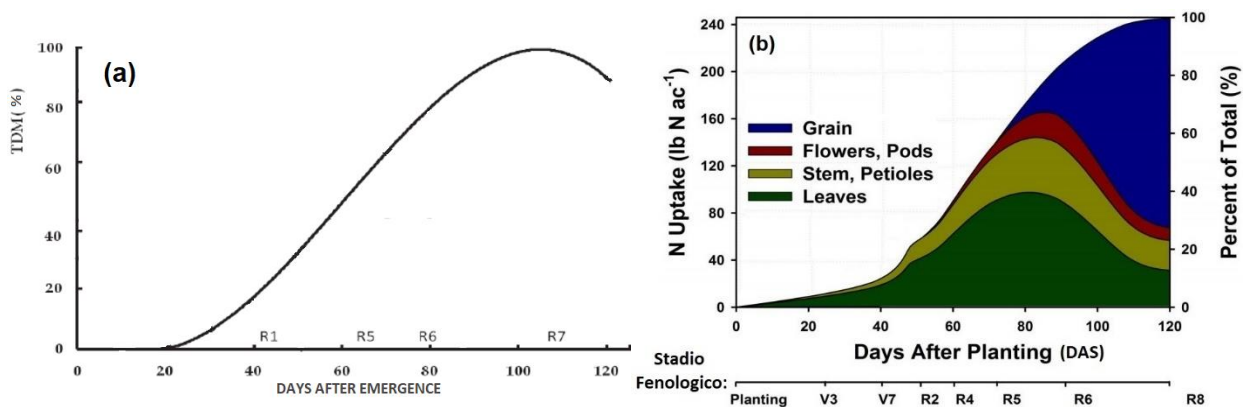


Figura 4.11: (a) curva di accrescimento di soia in sostanza secca % accumulata (TDM %),(Board e Kahlon, 2011, modificata); (b) curve di assorbimento dell'azoto (N) in soia, ripartito nei diversi organi: Grain = Semi; Flowers, Pods= infiorescenze e baccelli; Stem, Petioles = Fusto e Piccioli; Leaves = Foglie (Bender et al., 2015, modificata). Nell'asse verticale di sinistra è indicato l'azoto prelevato in libbre per acro, nell'asse verticale di destra la percentuale di ripartizione nei vari organi rispetto al totale assimilato.

Nella maggior parte delle aree la correlazione rimane elevata sino a circa 105 DAS. Due aree, in particolare, PVS 2017 e RZS 2016, mostrano un picco molto basso di correlazione proprio in questo periodo, per poi salire sino ai valori di massimo: questo è causato dal disturbo generato da ombreggiatura, nuvolosità o foschia non rilevato dal filtro. La piattaforma GEE è in grado di filtrare immagini in base al numero di pixel occupati da nuvolosità, identificata da Sentinel-2 nelle bande: B2, B10, B11, B12. Purtroppo, deboli disturbi causati da foschia ed ombre generate dalle nuvole possono passare inosservate dal filtro, compromettendo la qualità e la veridicità delle immagini Sentinel-2 rispetto alla situazione reale. In questo caso, sia in data 2 agosto 2017, sia 17 agosto 2016, sono stati identificati cumuli di foschia ed ombre al suolo dai rilievi satellitari. La figura 4.12 mette a confronto due rilievi della stessa area in anni diversi: nel 2017 i colori sono molto più nitidi, in particolare il verde chiaro delle aree coltivate e il blu intenso dell'acqua dei fiumi, mentre nel 2016, oltre ad essere presenti evidenti formazioni nuvolose, il mese di agosto è stato caratterizzato da una costante foschia che ha guastato la qualità delle immagini. Per ovviare a ciò è sufficiente analizzare più immagini distribuite nell'arco di tempo 30-20 DBH e scartare quelle in cui gli IV mostrano picchi di correlazione molto bassi, quando invece il trend è piuttosto elevato; oppure è possibile ricavare a priori un grafico che illustri l'evoluzione dell'indice NDVI durante la stagione: cadute improvvise dell'indice identificano disturbi nel rilievo. È possibile eseguire questo monitoraggio direttamente su GEE.



Figura 4.12: Confronto tra due rilievi fotografici Sentinel-2 in date differenti: 7 agosto 2017 a sinistra e 17 agosto 2016 a destra.

Nell'area CNS 2018 la variabilità è evidente e ben distribuita in zone omogenee in tutto l'appezzamento: significa che pixel con valori simili di produzione sono raggruppati e ravvicinati, componendo ampie aree monocromatiche sulla mappa. Al contrario nell'area RZS 2016 i pixel "omologhi" sono distribuiti in maniera casuale e caotica: risulta difficile discriminare zone omogenee. Nella fase di ri-campionamento possono presentarsi delle discrepanze o errori nell'assegnazione ad ogni pixel di "produzione" I valori degli IV, in generale se la variabilità non è distribuita in vaste sub aree è difficile ottenere elevati valori di correlazione. Per giunta, in questa area la variabilità è molto bassa, considerando che la media di produzione è pari a 4,3 Mg/ha e che la deviazione standard dalla media dei valori di produzione vale 0,741, sappiamo che il 68,2 % dei valori di produzione campionati nell'area è compreso in un intervallo di 1,5 Mg/ha, valore piuttosto basso e non replicato in altre aree. In conclusione, possiamo affermare che la correlazione verificata in RZS 2016 è influenzata da: bassa variabilità dei dati, difficoltà nell'identificare zone omogenee, scarsa qualità delle immagini campionate nel mese di Agosto 2016. In figura 4.13 viene proposto un confronto tra la variabilità delle aree CNS 2018 e RZS 2016. Tuttavia, sebbene la correlazione in RZS 2016 e BDS 2016 sia molto bassa, i picchi massimi vengono raggiunti solo nello stesso periodo comune alle altre aree, ovvero circa 85-105 DAS e 30-20 DBH, informazione che convalida ancor più le conclusioni formulate dalle altre aree.

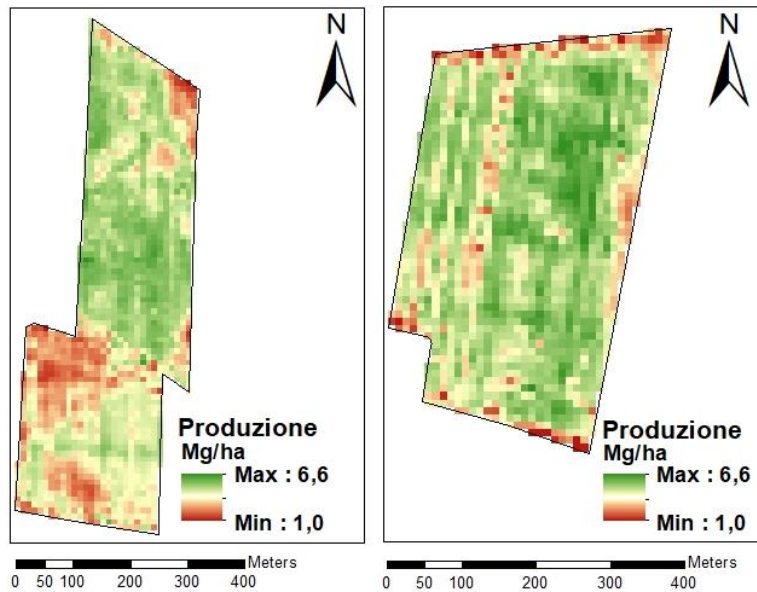


Figura 4.13: A sinistra il raster della mappa di produzione interpolato tramite funzione di kriging di CNS 2018 con risoluzione 10m, a destra quello di RZS 2016.

Per quanto riguarda la ristretta validità del modello proposto ai soli anni 2018 e 2017, possiamo affermare che le condizioni climatiche divergenti tra i tre anni a confronto, figura 4.14 e tabella 4.3, potrebbero aver influito sulla regressione; risulta difficile estendere un modello lineare tra anni diversi soprattutto in termini di precipitazioni e temperature estive. Secondo le testimonianze dell'agricoltore nel 2016 la coltura ha sicuramente sofferto di uno stress idrico nel mese di luglio, a causa dei soli 3,6mm di pioggia registrati e di elevati sbalzi di temperatura che hanno messo a dura prova la soia nella delicata fase di fioritura (stadio fenologico R1 e R2); mentre, nel 2018 è più probabile che lo stress si sia manifestato nel mese di agosto: ciò ha probabilmente contribuito a modificare il tipo di correlazione tra IV e produzione nei due anni. Inoltre va considerato che entrambe le mappe analizzate nel 2016 mostrano a priori bassa correlazione tra GCVI e resa, probabilmente la combinazione tra siccità e improvvisi innalzamenti della temperatura tra fine giugno e luglio, possono aver causato aborti fiorali, sebbene la coltura sia stata irrigata e abbia proseguito il suo sviluppo, la produzione è stata comunque compromessa in quelle aree dove lo stadio R2 coincideva con i giorni in cui si sono manifestati i picchi di temperatura massima.

I valori di RMSE ottenuti sono da considerarsi accettabili per gli anni 2018 e 2017, dove il modello commette un errore di stima pari circa 0.52 Mg/ha (media tra gli RMSE), ma eccessivi nelle aree coltivate nell'anno 2016.




Figura 4.14: Il grafico riassume le temperature medie giornaliere registrate nei mesi da giugno ad agosto: nel 2016 (TM2016), nel 2017 (TM2017) e nel 2018 (TM2018), (dati arpav).

Tabella 4.3: Piovosità totale in mm registrata da giugno ad agosto negli anni: 2016, 2017, 2018,(dati arpav).

	2016	2017	2018
Giugno	85,6	43,2	82,8
Luglio	3,6	17,8	79
Agosto	37,8	45	18

Capitolo 5

CONCLUSIONI

L'aumento della domanda di beni di origine agricola, generata dall'accrescimento della popolazione mondiale e dall'aumento del grado di benessere delle popolazioni, potrebbe mettere a dura prova l'intero sistema agricolo. L'agricoltura di precisione giocherà un ruolo fondamentale al fine di rendere le aree agricole più produttive, ma soprattutto più efficienti con lo scopo di contenere l'impatto ambientale che questa attività può causare: emissioni di gas serra, contaminazione di acque superficiali con fertilizzanti e prodotti fitosanitari, effetto deriva causato dalla distribuzione dei prodotti fitosanitari sono solo alcune tra le più gravi conseguenze dovute alle attività agricole. L'aumento degli investimenti in nuove tecnologie, in particolare nella sensoristica, sia da parte delle case costruttrici, sia da parte degli agricoltori, è un segnale che decreta l'attuale avvicinamento dell'agricoltura al mondo dell'elettronica e dell'automatizzazione. L'unione tra le teorie di base dell'agricoltura di precisione e il mondo della sensoristica, permette già di ottenere validi risultati attraverso le lavorazioni VRT. Tutto ciò è possibile solamente se si dispone di strumenti per la raccolta di informazioni accurate e georeferenziate riguardo alle aree agricole: il RS è una valida opzione offerta dal mercato attuale. Grazie al RS è possibile ricavare informazioni preziose e dettagliate riguardo agli appezzamenti, oltretutto le ultime missioni satellitari, come Sentinel-2, forniscono immagini gratuite ad alta risoluzione spaziale (10m) ed elevata risoluzione temporale (cinque giorni all'equatore) dalle quali è possibile monitorare i propri raccolti. Attualmente molti studi sono focalizzati su come il RS possa identificare stress sia di origine abiotica che biotica in base al fotorelevamento od analisi della superficie terrestre attraverso sensori LIDAR o SAR, od addirittura integrando più dati da fonti diverse. Un traguardo in grado di rivoluzionare l'intero sistema agricolo mondiale, verrà raggiunto quando, grazie al RS, potremo localizzare in anticipo probabili eventi di stress al fine di prevenire gli effetti negativi sulla produzione o sulla qualità dei prodotti agricoli ricavati dalle aree così monitorate (Zhang et al., 2019). Prima che tutto ciò avvenga è indispensabile la creazione di un consistente database, nel quale siano categorizzati e misurati tutti i probabili eventi di stress verificabili in campo e la risposta della coltura letta attraverso il RS.

Nel presente studio sono state adoperate tecnologie affini al RS, al fine di studiare la variabilità in aree coltivate a soia, in particolare si è voluto verificare l'ipotesi per cui ricavando vari IV da immagini satellitari ad elevata definizione, fornite dalla missione Sentinel-2, sia possibile prevedere la variabilità nella produzione negli appezzamenti.

Sono stati ricavati 8 IV in sette appezzamenti situati in provincia di Rovigo durante il periodo vegetativo della soia (giugno-agosto) e confrontati con le rispettive mappe di produzione fornite da una mietitrebbia. Dallo studio della correlazione tra IV e produzione è risultato che gli indici GCVI, GNDVI e WDRVI sono i migliori perché mediamente mostrano un coefficiente di correlazione maggiore rispetto agli altri.

Il periodo compreso tra 85 e 105 giorni dopo la semina, che corrispondono a circa 30 e 20 giorni prima della raccolta, sembra essere il migliore arco di tempo dal quale ricavare le immagini satellitari, in questa finestra temporale gli indici mostrano la massima correlazione con la produzione. Sebbene le immagini satellitari siano state filtrate per escludere i rilievi in giornate nuvolose, alcune date mostravano valori anomali di correlazione: ciò è spiegato dal fatto che foschia, ombre e deboli formazioni nuvolose possono interferire con la qualità delle immagini, in termini di assorbanza, senza venire cernite dal filtro. Infine è stato dedotto che: in aree dove la variabilità non si propone come ampie zone omogenee, ma assume una disposizione caotica, la correlazione IV e produzione risulta bassa.

Si è provato a ricavare un modello lineare dall'area che mostrava la migliore correlazione tra IV e produzione al fine di poter prevedere la variabilità anche in altre aree. Il modello ha dato in genere risultati esaustivi in aree coltivate nel 2018 e 2017, ma non in aree coltivate nel 2016: molto probabilmente le condizioni climatiche che caratterizzano i diversi anni hanno condizionato la correlazione tra IV e resa, correlazione che era già scarsa a priori tra IV e resa delle singole aree. Il calcolo del RMSE ha fornito risultati apprezzabili e confrontabili per gli anni 2018 e 2017, ma mostra un errore eccessivo nelle aree del 2016. Possiamo inoltre dedurre che esistono dei vincoli ai quali non si può ovviare con il solo RS: eventi atmosferici violenti, condizioni climatiche estreme ed altri fattori imprevedibili dal RS, possono destabilizzare il monitoraggio delle colture a distanza e tutte le possibili attività di studio che si basano su queste informazioni.

Grazie a questo studio sono stati determinati quali indici calcolare e in che periodo ricavare i dati satellitari, al fine di mappare la variabilità in aree coltivate a soia secondo le tecniche di agricoltura convenzionale nel nord-est Italia. Il contributo di tecnologie quali le immagini ad elevata risoluzione di Sentinel-2, le mappe di produzione e la piattaforma

virtuale GEE, è stato essenziale per completare il lavoro in breve tempo ed a costi contenuti.

Poter prevedere la variabilità di una coltura così importante nel panorama agricolo italiano, come la soia, permette agli operatori del settore di poter approfondire lo studio della variabilità negli appezzamenti considerando solo, od in aggiunta ad altri fattori noti, gli IV ricavati gratuitamente da rilievi satellitari. Lo studio della variabilità costituisce una tappa obbligatoria per gli agricoltori che vogliono approcciarsi all' AP: in primis per quantificare l'effettiva convenienza sull'applicazione di questa metodologia nelle aziende ed in secondo luogo come strumento indispensabile per adattare le tecniche di AP ai propri appezzamenti. In sintesi, maggior variabilità è riscontrata in un'area agricola, maggiore sarà la convenienza nell'attuare l'AP, quanto e perché le aree omogenee identificate sono diverse permette di programmare le tipologie di lavorazioni.

La metodologia attuata in questo studio permette di prevedere la variabilità sia in anticipo rispetto alla data di raccolta, sia in annate passate; il modello lineare permette di ottenere informazioni riguardo alla variabilità in termini di resa ad ettaro a partire da un IV, anche senza disporre di mappe di resa. Unendo le informazioni di più colture in più anni è possibile ricavare una mappatura chiara e realistica della variabilità degli appezzamenti (Ali et al., 2019). Oltre agli agricoltori questo modello potrà essere utile a tutti coloro che vogliono indagare sulla storicità di aree agricole, ad esempio: ricercatori, compagnie assicurative, possibili acquirenti di nuove aree agricole... Ulteriori sviluppi potrebbero portare alla messa a punto di un modello previsionale più complesso il quale, interpolando le informazioni satellitari nel periodo decretato da questo studio a molti altri fattori come clima, tecniche agronomiche, monitoraggio degli stress colturali... possa dare risultati validi sulla produzione attesa delle colture. Ciò sarebbe uno strumento molto importante nell'ambito dell'agribusiness, produttori, economisti e politici potrebbero conoscere in anticipo e con elevata affidabilità eventuali sovra o sotto produzioni.

BIBLIOGRAFIA

Documenti scientifici

- AL-Gaadi, K.A., Hassaballa, K.A., Tola, E., Kayad, A.G., Madugundu, R., Ablewi, B., Assiri, F., 2016. Prediction of Potato Crop Yield Using Precision Agriculture Techniques PLOS ONE- e0162219.
- Al-Gaadi, K.A., Tola, K.A., Madugundu, E., Zeyada, R., Chariton, K.A., 2016. Assessing the Spatial Variability of Alfalfa Yield Using Satellite Imagery and Ground-Based Data 10.1371/journal.pone.0157166.
- Amidan, B. G., Ferryman, T. A., & Cooley, S. K., 2005. Data outlier detection using the Chebyshev theorem. In Aerospace Conference, IEEE (pp. 3814e3819).
- Ali, A., Martelli, R., Lupia, F., Barbanti, L., 2019. Assessing Multiple Years' Spatial Variability of Crop Yields Using Satellite Vegetation Indices. Remote Sens. 11(20), 2384;
- Bender, R. R., Haegele, J. W., Below, F. E., 2015. Modern soybean varieties' nutrient uptake patterns. Better Crops/Vol. 99 (No. 2).
- Birrell, S.J., Sudduth, K.A., Borgelt, S.C., 1996. Comparison of sensors and techniques for crop yield mapping. Computers and Electronics in Agriculture, Volume 14, Issues 2–3, Pages 215-233, ISSN 0168-1699
- Board, E. J., Kahlon, S. C., 2011. 1. Soybean yield formation: what controls it and how it can be improved. Soybean: Physiology and Biochemistry. Doi:10.5772/17596.
- Bolton, D.K., Friedl, M.A., 2013. Forecasting crop yield using remotely sensed vegetation indices and crop phenology metrics. Agricultural and Forest Meteorology, Volume 173, Pages 74-84, ISSN 0168-1923.
- Burke, M., Lobell, D.B., 2017. Satellite-based assessment of yield variation and its determinants in smallholder African systems. Proc. Natl. Acad. Sci. 114, 2189–2194.
- Capodici, F., Maltese, A., Ciraolo, G., D'Urso, G., La Loggia, G., 2017. Power sensitivity analysis of multi-frequency, multi-polarized, multi-temporal SAR data for soil-vegetation system variables characterization. Remote sens. 9, 677.
- Chappelle, E.W., Kim, M.S., McMurtrey, J.E., 1992. Ratio analysis of reflectance spectra (RARS): An algorithm for the remote estimation of the concentrations of chlorophyll A, chlorophyll B, and carotenoids in soybean leaves. Remote Sensing of Environment, Volume 39, Issue 3. Pages 239-247, ISSN 0034-4257.

Cordoba, M. A., Bruno, C. I., Costa, J. L., Peralta, N. R., & Balzarini, M. G., 2016. Protocol for multivariate homogeneous zone delineation in precision agriculture. *Biosystems Engineering*, 143, 95e107.

De Benedetto, D., Castrignanò, A., Rinaldi, M., Ruggieri, S., Santoro, F., Figorito, B., Gualano, S., Diacono, M., Tamborrino, R., 2013. An approach for delineating homogeneous zones by using multi-sensor data. *Geoderma*, volume 199, Pages 117-127, ISSN 0016-7061.

Delalieux, S., Van Aardt, J., Keulemans, W., Schrevens, E., Coppin, P., 2007. Detection of biotic stress (*Venturia inaequalis*) in apple trees using hyperspectral data: non-parametric statistical approaches and physiological implications. *Eur. J. Agron.* 27,130–143.

Delegido, J., Verrelst, J., Alonso, L., Moreno, J., 2011. Evaluation of Sentinel-2 Red-Edge Bands for Empirical Estimation of Green LAI and Chlorophyll Content. *Sensors* 2011, 11, 7063-7081; ISSN 1424-8220.

Edward, G.P., Alfredo, H.R., Pamela, N.L., Stephen, N.G., 2008. Relationship Between Remotely-sensed Vegetation Indices, Canopy Attributes and Plant Physiological Processes: What Vegetation Indices Can and Cannot Tell Us About the Landscape. *Sensors*, 8(4), 2136-2160.

Ferencz, C., Bogнар, P., Lichtenberger, J., Hamar, D., Tarscai, G., 2004. Crop yield estimation by satellite remote sensing. *International Journal of Remote Sensing*. 25: 4113–4149.

Fitzgerald, G., Rodriguez, D., O'Leary, G., 2010. Measuring and predicting canopy nitrogen nutrition in wheat using a spectral index – the canopy chlorophyll content index (CCCI). *Field Crops Res.*, 116, pp. 318-324.

Foley, W. J., McIlwee, A., Lawler, I., Aragonés, L., Woolnough, A. P., Berding, N., 1998. Ecological applications of near infrared reflectance spectroscopy - A tool for rapid, cost-effective prediction of the composition of plant and animal tissues and aspects of animal performance. *Oecologia*, vol. 116, no. 3, pp. 293–305.

Giardini, L., Baldoni, R., 2001. *Coltivazioni erbacee*. Bologna, Pàtron Editore.

Gitelson, A. A., 2004. Wide dynamic range vegetation index for remote quantification of biophysical characteristics of vegetation. *Journal of Plant Physiology*, vol. 161, no. 2, pp. 165–173.

Gitelson, A. A., Kaufman, Y. J., Merzlyak, M.N., 1996. Use of a green channel in remote sensing of global vegetation from EOS-MODIS. *Remote Sensing of Environment*, 58 pp. 289-298.

Hoboken J., Jensen, J. R., 1996. *Remote sensing of the environment: An Earth Resource Perspective*. 3th Edn., Prentice Hall, USA.

Huete, A. R., Didan, K., Miura, T., Rodriguez, E.P., Gao, X., Ferreira, G., 2002. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. *Remote Sensing of Environment*, 83, 195–213.

Hunt, M.L., Blackburn, G.A., Carrasco, L., Redhead, J.W., Rowland, C.S., 2019. High resolution wheat yield mapping using Sentinel-2, *Remote Sensing of Environment*. Volume 233, 111410, ISSN 0034-4257.

Jin, Z., Azzari, G., You, C., Di Tommaso, S., Aston, S., Burke, M., Lobell, D. B., 2019. Smallholder maize area and yield mapping at national scales with Google Earth Engine. *Remote Sensing of Environment*, Volume 228.

Krezhova, D., 2011. *Soybean: Genetics and Novel Techniques for Yield Enhancement*. eBook (PDF) ISBN: 97-953-51-5156-2

Lillesand, T., Kiefer R., Chipman J., 2010. *Remote sensing and image interpretation*. USA. John Wiley & Sons.

Maestrini, B., Basso, B., 2018. Predicting spatial patterns of within-field crop yield variability. *Field Crops Research*, Volume 219, Pages 106-112, ISSN 0378-4290.

Mahajan, G.R., Sahoo, R.N., Pandey, R.N., Gupta, R.N., Kumar, D., 2014. Using hyperspectral remote sensing techniques to monitor nitrogen, phosphorus, sulphur and potassium in wheat (*Triticum aestivum* L.). *Precision Agric* 15: 499.

Mahlein, A., Rumpf, T., Welke, P., Dehne, H., Plümer, L., Steiner, U., Oerke, E., 2013. Development of spectral indices for detecting and identifying plant diseases. *Remote sens. Environ.* 128, 21–30.

Moreau, S., Le Toan, T., 2003. Biomass quantification of Andean wetland forages using ERS satellite SAR data for optimizing livestock management. *Remote Sensing of Environment* 84(4):477-492.

Moshou, D., Bravo, C., West, J., Wahlen, S., McCartney, A., Ramon, H., 2004. Automatic detection of yellow rust in wheat using reflectance measurements and neural networks. *Comput. Electron. Agr.* 44, 173–188.

Murchie, E.H., Lawson, T., 2013. Chlorophyll fluorescence analysis: a guide to good practice and understanding some new applications, *Journal of Experimental Botany*. Volume 64, Issue 13, Pages 3983–3998.

Nicolas, H., 2004. Using remote sensing to determine of the date of a fungicide application on winter wheat. *Crop Prot.* 23, 853–863.

Oumar, Z., Mutanga, O., 2013. Using WorldView-2 bands and indices to predict bronze bug (*Thaumastocoris peregrinus*) damage in plantation forests. *Int. J. Remote Sens.* 34,2236–2249.

Rouse, J., Hass, R., Schell, J., Deering, D., 1973. Monitoring vegetation systems in the great plains with ERTS. Third ERTS Symposium, NASA, SP-351 I, 309-317.

Schwalbert, R.A., Amado, T.J.C., Nieto, L., Varela, S., Corassa, G.M., Horbe, T.A.N., Rice, C.W., Peralta, N.R., Ciampitti, I.A., 2018. Forecasting maize yield at field scale based on high-resolution satellite imagery, *Biosystems Engineering*, Volume 171 Pages 179-192, ISSN 1537-5110.

Singh, D., Sao, R., Singh, K.P., 2007. A remote sensing assessment of pest infestation on sorghum. *Adv. Space Res.* 39, 155–163.

Srbinovska, M., Gavrovski, C., Dimcev, V., Krkoleva, A., Borožan, A., 2015. Environmental parameters monitoring in precision agriculture using wireless sensor networks. *Journal of Cleaner Production*, Volume 88, Pages 297-307, ISSN 0959-6526. <https://doi.org/10.1016/j.jclepro.2014.04.036>.

Sun J., Di L., Sun Z Shen Y., Lai Z., 2019 . County-Level Soybean Yield Prediction Using Deep CNN-LSTM Model. *Sensors (Basel)*. pii: E4363.

Taylor, J.C., Wood, G.A., Thomas, G., 1997. Mapping yield potential with remote sensing. *Precis. Agric.*, 1, 713-720.

Tellaèche, A., Burgos Artizzu, X.P., Pajares, G., Ribeiro, A., Quintanilla, C.F., 2008. A new vision-based approach to differential spraying in precision agriculture. *Comput. Elect. Agric.*, 60: 144-155.

Toulios, L., Pateras, D., Zerva, G., Gemtos, T.A., Markinos, T.H., 1998. Combining satellite images and cotton yield maps to evaluate field variability in precision farming. *Proceedings of the World Cotton Research Conference*. Athens, Greece. 534–539.

Tucker, C.J., Vanpraet, C.L., Sharman, M.J., Van Ittersum, G., 1985. Satellite remote sensing of total herbaceous biomass production in the Senegalese Sahel:1980–1984. *Remote Sensing of Environment*. 233–249.

Tucker, C., 1979. Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sensing of Environment*, 8, 127-150.

Wardlow, D.B., Egbert, S. L., 2008. Large-area crop mapping using time-series MODIS 250 m NDVI data: An assessment for the U.S. Central Great Plains. *Remote Sensing of Environment*, Volume 112, Issue 3. ISSN 0034-4257. <https://doi.org/10.1016/j.rse.200.07.019>.

Xu, H.R., Ying, Y.B., Fu, X.P., Zhu, S.P., 2007. Near-infrared spectroscopy in detecting leaf miner damage on tomato leaf. *Biosyst. Eng.* 96, 447–454.

Xue, J., and Su, B., 2017. Significant Remote Sensing Vegetation Indices: A Review of Developments and Applications. *Journal of Sensors*, vol.2017, Article ID 1353691, 17 pages, 2017.

Zhang J., Huang, Y., Pu, R., Gonzalez-Moreno, P., Yuan, L., Wu, K., Huang, W., 2019. Monitoring plant diseases and pests through remote sensing technology: A review. *Computers and Electronics in Agriculture*, Volume 165, , 104943, ISSN 0168-1699.

Zhang, J., Pu, R., Huang, W., Yuan, L., Luo, J., Wang, J., 2012. Using in-situ hyperspectral data for detecting and discriminating yellow rust disease from nutrient stresses. *Field Crop. Res.* 134, 165–174.

Zhang, J., Pu, R., Yuan, L., Huang, W., Nie, C., Yang, G., 2013. Integrating remotely sensed and meteorological observations to forecast wheat powdery mildew at a regional scale. *IEEE J. Sel. Top. Appl. Earth Obs.* 7, 4328–4339.

Siti web

Enciclopedia multimediale “Wikipedia”; (consultato a novembre 2019).

projectblue.blob.core.windows.net/media/Default/Imported%20Publication%20Docs/SatellitesForAgriculture1825_181217_WEB.pdf ; (consultato a novembre 2019).

dati.istat.it/; (consultato a novembre 2019).

www.soymeal.org/ ; (consultato a novembre 2019).

www.enac.gov.it/ ; (consultato a novembre 2019).

www.arpa.veneto.it/bollettini/storico/ ; (consultato a novembre 2019).

www.grandviewresearch.com ; (consultato a novembre 2019).

