UNIVERSITÁ DEGLI STUDI
DI UDINE

Corso di Laurea in
Viticoltura ed Enologia
Dipartimento di Scienze Agroalimentari, Ambientali ed Animali

Elaborato per il conseguimento della
Laurea in Viticoltura ed Enologia
(L-25)

VALUTAZIONE DI INDICI VEGETATIVI PER IL MONITORAGGIO DI STRESS IDRICO E MAL DELL'ESCA DELLA VITE TRAMITE L'IMPIEGO DI UN DRONE

RELATORE: Prof. Paolo Sivilotti
CORRELATORI: Dott. Alessandro Pichierri
Dott. Davide Mosetti

LAUREANDO: Luca GOVERNO

ANNO ACCADEMICO 2021/2022

LISTA ABBREVIAZIONI

AI	Intelligenza artificiale
Chl_{a+b}	Pigmenti clorofilliani
$\boldsymbol{E_{A(\lambda)}}$	Energia assorbita
$\boldsymbol{E_{I(\lambda)}}$	Energia incidente
$\boldsymbol{E_{R(\lambda)}}$	Energia riflessa
$\boldsymbol{E_{T(\lambda)}}$	Energia trasmessa
ED	Complesso del mal dell'esca
EMR	Radiazione elettromagnetica
HS	Iperspettrale
HSI	*Imaging* iperspettrale
NIR	Vicino infrarosso
RE	*Red-edge*
ROI	Regione di interesse
RS	*Remote sensing*
SAPR	Sistema Aeromobile a Pilotaggio Remoto
SI	*Imaging* spettrale
SWIR	*Short wave infrared*
VIS	Visibile (400-685 nm)
MI	*Imaging* multispettrale
MS	Multispettrale
PCA	*Principal component analysis*
VI	Indici vegetativi
VNIR	Radiazione visibile e vicino infrarosso
ρ	Riflettanza
λ	Lunghezza d'onda
Ψ	Potenziale idrico
Ψ_{leaf}	Potenziale idrico fogliare
Ψ_{pd}	Potenziale idrico *pre-dawn*
Ψ_{stem}	Potenziale idrico *stem*

INDICE

1 Riassunto 1

2 INTRODUZIONE 3

2.1 ELEMENTI FISICI DEL TELERILEVAMENTO 3

2.1.1 Caratteristiche della radiazione elettromagnetica 3

2.1.2 Interazione della radiazione luminosa con la materia 4

2.2 PROPRIETÀ OTTICHE DELLE SUPERFICI VEGETALI 7

2.2.1 Comportamento nel visibile 8

2.2.2 Comportamento nell'infrarosso 9

2.2.3 Comportamento nel red edge 11

2.3 PIATTAFORME PER L'OSSERVAZIONE TERRESTRE 12

2.3.1 Risoluzione spaziale 13

2.3.2 Altitudine 15

2.3.3 Risoluzione temporale 17

2.4 IMAGING SPETTRALE 19

2.4.1 Imaging iperspettrale 19

2.4.2 Imaging multispettrale 22

2.5 APPROCCIO ALL'ANALISI DEI DATI SPAZIALI 24

2.6 INDICI VEGETATIVI 26

2.6.1 Classificazione degli indici vegetativi 28

2.6.2 Validazione degli indici vegetativi 29

2.6.3 Normalized Difference Vegetation Index 30

2.6.4 Limiti all'utilizzo degli indici vegetativi 32

2.6.5 Indici vegetativi composti 32

2.7 APPLICAZIONI DEGLI INDICI VEGETATIVI 33

2.7.1 Monitoraggio fattori di stress 37

2.7.2 Monitoraggio del mal dell'esca della vite 38

2.7.3 Monitoraggio dello stress idrico 42

3 SCOPO DEL LAVORO 48

4 MATERIALI E METODI 49

4.1 Acquisizione dei dati 49

4.1.1 Siti sperimentali 49

4.1.2 Acquisizione dei dati di campo 50

4.1.3 Acquisizione dei dati aerei e pre-elaborazione 51

4.2 Elaborazione e analisi dei dati 52

4.2.1 Selezione e calcolo degli indici vegetativi 52

4.2.2 Estrazione delle aree vegetative 53

4.2.3 Analisi statistiche 53

5 RISULTATI 55

5.1 Misura dei parametri di potenziale idrico 55

5.2 Valutazione dello stato sanitario 58

5.3 Valutazione di VI per il monitoraggio dello stato idrico 58

5.3.1 Confronto delle relazioni tra VI e Ψ_{pd}, Ψ_{leaf}, Ψ_{stem} 58

5.3.2 Relazioni tra VI e Ψ_{stem} 59

5.3.3 Selezione degli VI meglio correlati a Ψ_{stem} 64

5.3.4 Impiego di VI per la discriminazione di diversi livelli di stato idrico 68

5.4 Valutazione di VI per il monitoraggio del mal dell'esca della vite 68

6 CONCLUSIONI 69

7 BIBLIOGRAFIA 71

8 ALLEGATO 1 101

1 Riassunto

In un contesto di progressiva riduzione degli input esogeni, tempestività di intervento e conoscenza della variabilità intra-parcellare rappresentano elementi chiave nella gestione dei fattori di stress della vegetazione. A tale fine, la valutazione di indici vegetativi (VI), calcolati a partire da immagini acquisite da sistemi aeromobili a pilotaggio remoto (SAPR) è stata considerata. A partire da immagini multispettrali (MS) ed RGB, un totale di 45 variabili è stato analizzato per valutarne la fattibilità di impiego nel monitoraggio di stato idrico e mal dell'esca della vite (ED) in due vigneti rispettivamente coltivati a Pinot Grigio e Glera (*Vitis vinifera* L.). Modelli lineari e non lineari sono stati impiegati per definire il grado di dipendenza statistica tra i VI oggetto di analisi e tre indicatori di stato idrico i.e. potenziale idrico *pre-dawn* (Ψ_{pd}), potenziale idrico *stem* (Ψ_{stem}), e potenziale idrico fogliare (Ψ_{leaf}).

I VI che incorporano l'informazione di riflettanza nel NIR sono risultati generalmente più adatti al monitoraggio dello stato idrico della vegetazione. Le variabili Gitelson Cl1 e Gitelson Cl2 hanno prodotto i migliori risultati di correlazione rispetto a Ψ_{stem}.

I risultati ottenuti dimostrano la potenzialità dell'utilizzo di immagini ad alta risoluzione ottenute da SAPR per il monitoraggio dello stato idrico delle piante di vite. Nonostante ulteriori approfondimenti si rendano necessari per validare i risultati ottenuti e testarne la riproducibilità, dall'ampio numero di variabili considerate è possibile trarre indicazioni utili ad indirizzare la scelta dei VI da valutare per gli scopi di monitoraggio dello stato idrico delle piante di vite tramite immagini MS ad alta definizione acquisite da SAPR.

Relativamente alla possibilità di monitoraggio di ED, dall'analisi delle variabili considerate non sono emerse differenze significative tra individui sintomatici e non sintomatici; un'accurata discriminazione di piante affette da ED non è stata possibile. Nonostante i risultati ottenuti, non si esclude l'impiego di immagini MS ad alta definizione ottenute da SAPR con fini di monitoraggio di ED, ma sarebbe più interessante cercare degli altri indici utilizzando immagini a più alta risoluzione spettrale, ossia le immagini iperspettrali.

Parole chiave: *remote sensing*, viticoltura di precisione, mal dell'esca, stress idrico, indici vegetativi

2 INTRODUZIONE

2.1 ELEMENTI FISICI DEL TELERILEVAMENTO

Pur assumendo un'accezione piuttosto ampia, si accetta la possibilità di definire il telerilevamento o *Remote Sensing* (*RS*) come "*l'acquisizione di dati relativi ad un oggetto, senza entrare in contatto fisico con lo stesso*" (Elachi & Van Zyl, 2021); data tale definizione, si può comprendere come la semplice osservazione di un oggetto e la correlata possibilità di trarne informazioni di vario tipo (e.g. dimensioni, colore, forma) possa considerarsi una forma di *RS* (Barton, 2011).

Il *RS* è spesso utilizzato per ottenere dati in ambito agricolo e forestale, ricorrendo all'impiego di sensori passivi in grado di misurare la radiazione elettromagnetica risultante dall'interazione con una superficie vegetale (Xue & Su, 2017).

Con l'ausilio di tali dispositivi diviene possibile sviluppare gli studi in merito a caratteristiche della superficie e fenomeni ad essa associati, anche al di fuori dello spettro di lunghezze d'onda compreso tra 380 e 700 nm che si ritiene indicativo della capacità di percezione dell'occhio umano (Calderón et al., 2015; di Gennaro et al., 2016; Hatfield et al., 2019; Mahlein, 2016; Maimaitiyiming et al., 2017).

2.1.1 Caratteristiche della radiazione elettromagnetica

Nelle logiche del *RS* la radiazione elettromagnetica (EMR) può essere definita come il mezzo attraverso il quale l'informazione spettrale viene trasmessa da una sorgente ad un sensore in grado di misurare le proprietà che codificano la stessa, tra cui frequenza e intensità (Elachi & Van Zyl, 2021).

Come reso noto dall'esperimento del prisma di Isaac Newton del 1666, un fascio di luce bianca può essere per dispersione separato nell'insieme delle sue componenti fondamentali; successivi studi hanno tuttavia dimostrato che la luce visibile rappresenta un intervallo di lunghezze d'onda limitato, nel contesto di un ben più ampio spettro ovvero quello elettromagnetico (Kemp, 1991).

In natura esistono onde elettromagnetiche di qualsiasi frequenza nell'ambito di un *continuum* che viene definito spettro elettromagnetico (Jones & Vaughan, 2010) (Fig. 1).

Sebbene lo spettro elettromagnetico sia convenzionalmente suddiviso in regioni differenti, la maggior parte dei sistemi impiegati nel telerilevamento ottico della vegetazione opera

nell'intervallo compreso tra 350 nm e 2500 nm (Liu et al., 2020) e quindi fondamentalmente nelle regioni spettrali seguenti (Mishra et al., 2020; Sankaran et al., 2010):

- Visibile (*VIS*, 400-685 nm);
- *Red-edge* (*RE*, 690-730 nm);
- Vicino infrarosso (*near-infrared*, *NIR*, 730-1000 nm);
- *Short wave infrared* (*SWIR*, 1000-2500 nm).

In queste regioni dello spettro è possibile ricavare le maggiori informazioni riguardanti le caratteristiche biochimiche e biofisiche delle superfici vegetali (Mishra et al., 2020; Susič et al., 2018).

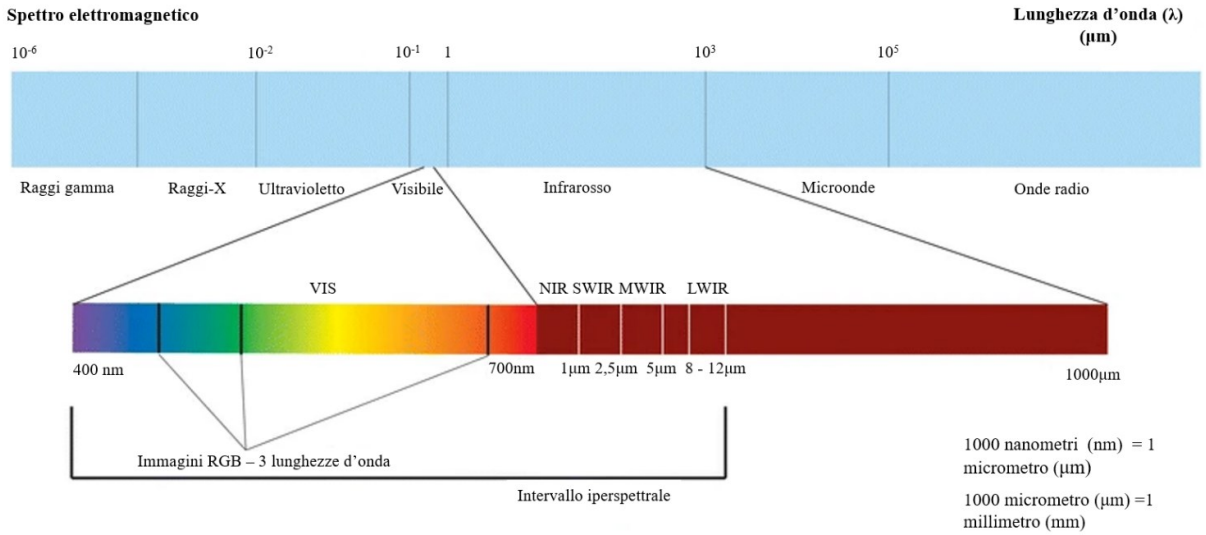

Fig. 1. Lo spettro elettromagnetico (rielaborato da Lowe et al. 2017)

2.1.2 Interazione della radiazione luminosa con la materia

Ogni entità chimica riflette e assorbe la EMR in modo preferenziale a specifiche lunghezze d'onda (tab. 1), pertanto, conoscendo le caratteristiche di riflessione ed assorbimento della luce di una determinata molecola è possibile, attraverso tecniche spettroscopiche, valutarne quantitativamente la presenza a partire da dati di tipo spettrale (Curran et al., 1992; van der Meer, 2004).

La EMR si propaga da una sorgente ad un sensore in modo diretto, attraverso il vuoto, (Elachi & Van Zyl, 2021) oppure indirettamente tramite processi di (i) assorbimento, (ii) trasmissione, (iii) riflessione, dovuti all'interazione della stessa EMR con particelle e molecole (Walter-Shea & Norman, 1991);

Le tecniche di *RS* ottico della vegetazione si basano proprio sull'interazione della EMR con le superfici vegetali. In particolare, le tecniche maggiormente impiegate si basano su misure di riflettanza (ρ) (Mulla, 2013; Weiss et al., 2020), grandezza adimensionale definita dal rapporto tra l'intensità di luce riflessa da una superficie e l'intensità di luce incidente rispetto alla stessa superficie (Ray, 1994).

Tab. 1 Caratteristiche di assorbimento di alcune entità molecolari nel VIS e nell'IR; in parentesi vengono indicate le lunghezze d'onda meno significative (rielaborato da Jones & Vaughan et al. 2010)

Lunghezza d'onda (µm)	Specie chimica	Transizione elettronica o moto vibrazionale
0,43; 0,46; 0,64; 0,66	Chl_{a+b}	Transizioni elettroniche
0,97; 1,20; 1,40; 1,94	Acqua	O-H stretching
1,51; 2,18 (0,91; 1,02; 1,69; 1,94; 1,98; 2,06; 2,13; 2,24; 2,30; 2,35)	Proteine, azoto	N-H stretching e bending, C-H stretching
2,31 (0,93; 1,02)	Oli	C-H stretching e bending
1,69 (1,12; 1,42; 1,94)	Lignina	C-H stretching e bending
1,78	Cellulosa e zuccheri	

Attraverso i processi di assorbimento l'energia luminosa viene convertita in energia interna delle molecole coinvolte nei processi medesimi di assorbimento (Horvath, 1993); ciò avviene in accordo con il primo principio della termodinamica per il quale l'energia non si crea né si distrugge, ma subisce bensì delle trasformazioni (Wisniak, 2008); inoltre, in un dato momento l'energia può essere presente in diverse forme (Wisniak, 2008).

Avendo considerato ciò si può desumere come l'energia totale, nonché la quantità di luce incidente $\boldsymbol{E_{I(\lambda)}}$, debba necessariamente risultare equivalente alla somma delle componenti assorbite $\boldsymbol{E_{A(\lambda)}}$, trasmesse $\boldsymbol{E_{T(\lambda)}}$ e riflesse $\boldsymbol{E_{R(\lambda)}}$ che si generano in seguito all'impatto con la superficie vegetale (Bowers & Hanks, 1971; Jones & Vaughan, 2010) (eq. 1).

$$E_{I(\boldsymbol{\lambda})} = E_{R(\boldsymbol{\lambda})} + E_{A(\boldsymbol{\lambda})} + E_{T(\boldsymbol{\lambda})} \qquad \text{(Eq. 1)}$$

Dove $E_{I(\boldsymbol{\lambda})}$ = energia incidente, $E_{R(\boldsymbol{\lambda})}$ = energia riflessa, $E_{A(\boldsymbol{\lambda})}$ = energia assorbita, $E_{T(\boldsymbol{\lambda})}$ = energia trasmessa (Jones & Vaughan, 2010). Si noti che tutti i parametri riportati in Eq. 1 vengono espressi come funzione della lunghezza d'onda (λ) in altre parole, la quantità di energia che viene riflessa, assorbita o trasmessa è diversa a seconda della lunghezza d'onda considerata (Jones & Vaughan, 2010).

Ogni superficie, in funzione della propria natura chimico-fisica, interagisce con la luce generando per ciascuna lunghezza d'onda, informazioni di riflettanza caratterizzanti (Hsu, 2007). È quindi possibile associare ad ogni superficie un profilo di riflessione in grado di identificare la stessa in modo specifico (Fig. 2) (Ozdemir et al., 2020).

La radiazione riflessa osservata su un range continuo di lunghezze d'onda è definita firma spettrale (https://www.esa.int/SPECIALS/Eduspace_IT/SEMT8VZRA0G_0.html).

Secondo Campbell & Wynne (2011) la firma spettrale di una superficie non va considerata in modo rigido ma piuttosto dinamico, potendo quest'ultima facilmente variare in risposta ad alterazioni delle caratteristiche della superficie medesima (fig. 2).

Per questo motivo, l'analisi dei dati spettrali può essere proposta per scopi di classificazione (Maxwell et al., 2018) ma anche per valutare l'entità di determinati fenomeni o condizioni che riguardano la superficie di interesse tra cui si citano, a titolo di esempio, le valutazioni relative a variazioni dell'umidità superficiale del suolo (Mohanty et al., 2017), così come dello stato idrico (Clevers et al., 2010), nutrizionale (Knyazikhin et al., 2013) e sanitario della vegetazione (Bendel et al., 2020).

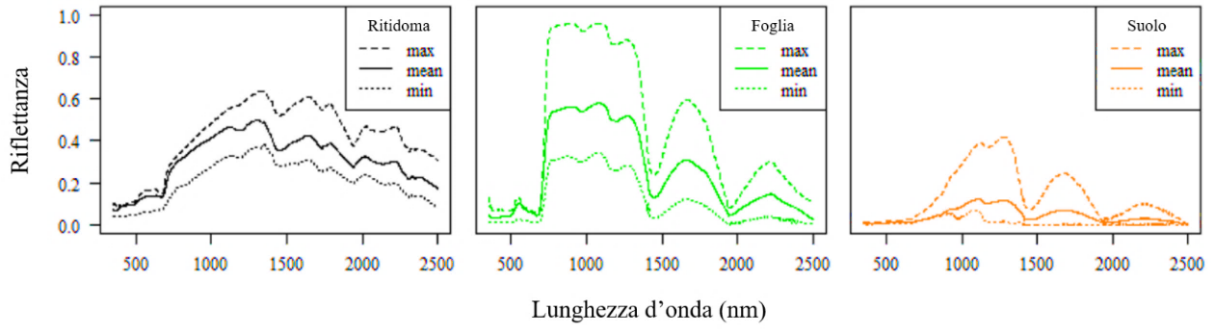

Fig. 2. Firma spettrale di ritidoma, foglia e suolo nell'intervallo di lunghezze d'onda compreso tra 0,4-2,5 µm (rielaborato da Clasen et al. 2015).

2.2 PROPRIETÀ OTTICHE DELLE SUPERFICI VEGETALI

Le conoscenze in merito alle interazioni tra EMR e superficie vegetale vengono considerate propedeutiche per l'interpretazione e la gestione dei dati telerilevati (Knipling, 1970).

Tutte le piante verdi presentano nel range di lunghezze d'onda compreso tra 350-2500 nm, simili caratteristiche di assorbimento della luce potendo distinguere uno spettro di riflettanza caratteristico (Bruning et al., 2020) (fig. 3).

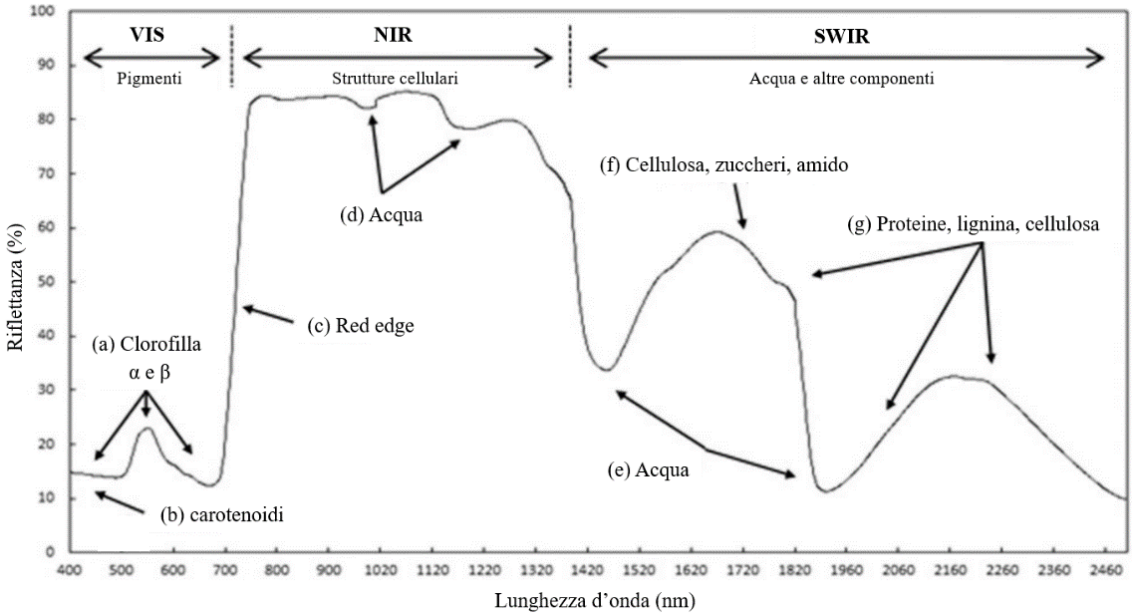

Fig. 3. Generico spettro di riflettanza di un organo fogliare in condizioni fisiologiche normali (rielaborato da Bruning et al. 2020)

Nonostante le analisi in riflettanza operate a livello fogliare possano essere di grande valore informativo, quando l'attenzione si sposta sulla valutazione del comportamento spettrale dell'intera chioma occorre considerare che le caratteristiche spettrali della superficie vegetale possono essere influenzate da numerosi fattori esogeni tra cui effetto di ombre, riflettanza del suolo, riflettanza e trasmittanza da vegetazione limitrofa (Petri & Galvão, 2019).

Dunque, il sensore spettrale riceve l'effetto combinato di tutti i fattori in grado di interferire con la vegetazione, più che la risposta spettrale pura della vegetazione stessa (Liu et al., 2020). Tale considerazione ha delle ricadute sui criteri che guidano l'interpretazione dei dati telerilevati, i quali spesso devono essere analizzati non solo nei termini delle variazioni spettrali che si verificano in modo specifico a livello fogliare ma anche alle differenze nella superficie fogliare in grado di riflettere la radiazione luminosa in direzione del sensore. Ad

esempio, nel NIR una caduta dei valori di riflettanza può dipendere da alterazioni verificatesi a livello fogliare, da una riduzione dell'area fogliare così come da semplici variazioni della geometria di orientamento fogliare o ancora ad uno sviluppo vegetativo ridotto a tal punto da esporre la copertura del suolo (Knipling, 1970).

2.2.1 Comportamento nel visibile

In generale, a livello fogliare la riflettanza nel VIS è controllata dalla concentrazione di pigmenti con particolare riferimento a quelli clorofilliani (Chl_{a+b}) (fig. 3a), infatti altri pigmenti (i.e. carotenoidi e antociani) presentano picchi di assorbimento che vanno parzialmente a sovrapporsi a quelli dei Chl_{a+b} stessi (fig.4).

Tuttavia, l'elevata concentrazione di pigmenti clorofilliani tende ad oscurare il contributo spettrale di queste altre classi di pigmenti, al punto da renderne complicata la determinazione (Sims & Gamon, 2002).

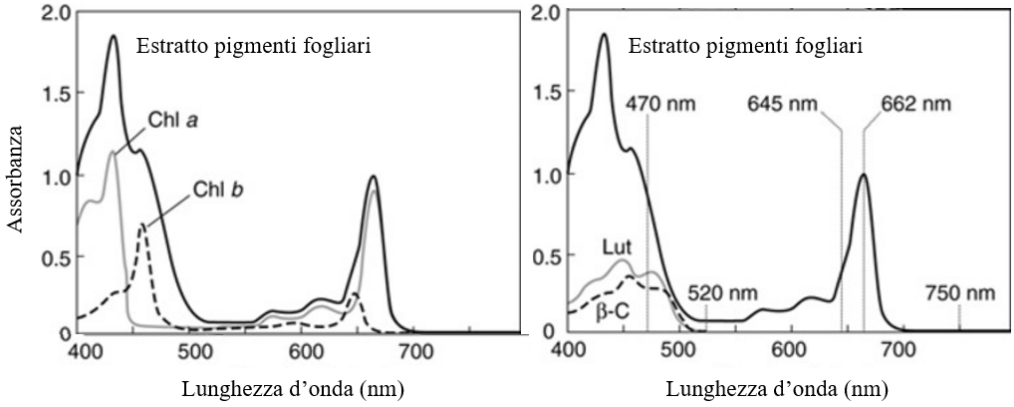

Fig. 4. Spettro di assorbimento di alcuni pigmenti fogliari i.e. clorofilla a (Chl a), clorofilla b (Chl b), luteina (Lut), beta-carotene (β-C) (rielaborato da Lichtenthaler & Buschmann, 2001).

La presenza di Chl_{a+b} determina ad ogni modo una riflessione prevalente della luce verde (Terashima et al., 2009) assorbendo viceversa dal 70 al 90% della radiazione luminosa totale nel blu e nel rosso (Blackburn, 2007; Campbell & Wynne, 2011).

La stima dei Chl_{a+b} è importante in quanto permette l'identificazione di situazioni di stress della pianta; infatti, questi ultimi sono universalmente associabili alla perdita di Chl_{a+b} (Hendry et al., 1987). Di conseguenza l'identificazione di vari fattori di stress viene genericamente ricercata attraverso la caduta della riflettanza nel VIS (Carter, 1993). In questi termini occorre tuttavia considerare che il forte assorbimento dei Chl_{a+b} nel rosso determina, già a concentrazioni limitate, importanti effetti di saturazione rendendo questi canali spettrali

insensibili al decremento iniziale di Chl_{a+b}, pertanto, l'informazione spettrale ricavabile in questo range dello spettro diviene di reale valore informativo solo dopo una certa latenza risultando quindi inadatta all'identificazione degli stessi stress in fasi precoci (Carter & Knapp, 2001).

2.2.2 Comportamento nell'infrarosso

Se nella regione del VIS prevalgono fenomeni di assorbimento, nel NIR si rilevano, in condizioni normali, forti incrementi nei valori di riflettanza; questi sono causati in maniera prevalente dai fenomeni di dispersione della luce che si verificano nell'interfaccia tra le strutture cellulari e gli spazi d'aria presenti nel mesofillo lacunoso (Harold, 1974) (fig. 5). Il mesofillo disperde e riflette fino al 60% di tutte le radiazioni NIR incidenti (Campbell & Wynne, 2011), differenze di riflettanza nel NIR indicano pertanto cambiamenti nell'organizzazione strutturale del mesofillo fogliare (Slaton et al., 2001).

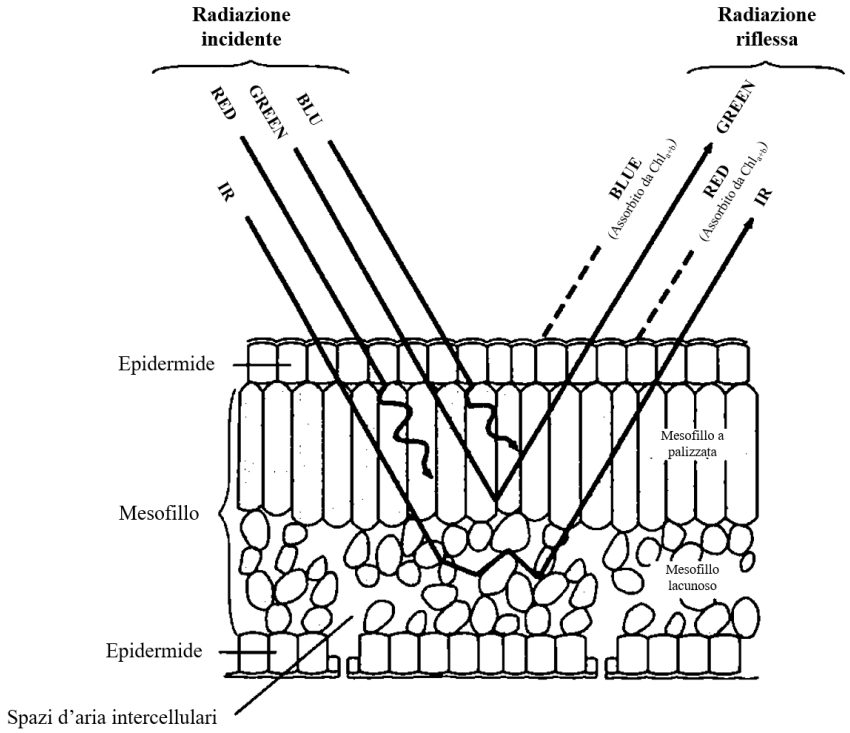

Fig. 5. Interazione della radiazione elettromagnetica a livello fogliare (rielaborato da Sabins, 1997).

Ad esempio, è possibile impiegare il NIR per valutare fenomeni di senescenza fogliare (Roberts et al., 1998), disorganizzazione delle strutture cellulari correlata all'azione tossica di alcuni patogeni (Chen et al., 2019) o collasso strutturale delle cellule fogliari (fig. 6) in conseguenza a condizioni di deficienza idrica (Sinclair et al., 1973).

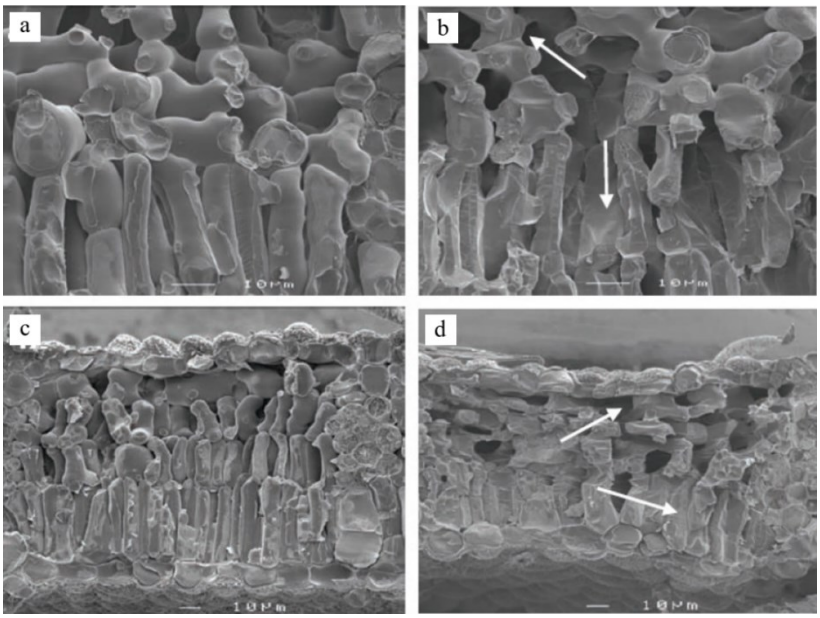

Fig. 6. Collasso strutturale del mesofillo dopo 1 ora dallo stress (a), (c) e dopo 24 ore dallo stress (b), (d); le frecce indicano alcuni punti nei quali si rendono evidenti gli effetti dovuti alla perdita di elasticità della parete cellulare (Istiak Sobhan, 2007).

Oltre alle relazioni con le proprietà strutturali, diverse zone del NIR sono influenzate dalle caratteristiche di assorbimento del legame O-H delle molecole di H_2O (fig. 3d) (Clevers et al., 2008), facendo rilevare un calo della riflettanza in questa regione dello spettro (Knipling, 1970).

Nonostante ciò, queste lunghezze d'onda non sempre si adattano ad un contesto di telerilevamento dello stato idrico della vegetazione, essendo questa regione spettrale influenzata, con le medesime modalità, dalle caratteristiche di assorbimento del vapor d'acqua atmosferico. Questa peculiarità potrebbe alterare la risposta spettrale della vegetazione, originando un rilevante effetto di rumore, soprattutto nei casi di misurazioni effettuate con piattaforme satellitari (Clevers et al., 2008; Tucker, 1980).

I valori di riflettanza nel NIR vengono infine considerati come indicatori di biomassa (Poley & McDermid, 2020).

Sempre nell'infrarosso (*IR)*, ma per lunghezze d'onda superiori, la riflettanza torna a subire un calo significativo imputabile alla presenza di acqua nei tessuti, in maniera particolarmente evidente tra 1450 nm e 1950 nm (fig. 3e) (Clevers et al., 2008). In particolar modo, i sistemi ottici di *RS* si limitano all'analisi dello *SWIR* dove la riflettanza è influenzata, oltre che dalla

presenza di acqua, anche da altre componenti di tipo non fotosintetico come azoto, amido, lignina e cellulosa (Peña-Barragán et al., 2011).

Infine, con il *medium-wave infrared* (MWIR) si esce dal dominio ottico, le lunghezze d'onda maggiori sono di pertinenza della zona termica dello spettro elettromagnetico, informativa di caratteristiche temperatura dipendenti, tra cui contenuto idrico ed evapotraspirazione (Berger et al., 2010).

2.2.3 Comportamento nel red edge

Nella transizione che si verifica tra le lunghezze d'onda del *RED* e quelle del *NIR*, nonché nell'intervallo di lunghezze d'onda indicativamente individuato tra 680-750 nm, la forte pendenza che la curva di riflettanza assume generalmente una distinta caratteristica spettrale identificata come *red edge (RE)* (Horler et al., 2007) (fig. 3c). Questa regione viene citata per essere particolarmente adatta alla valutazione di Chl_{a+b} (Hunt & Daughtry, 2017) dimostrando una sensibilità maggiore alle variazioni di tale componente, rispetto a quella ottenibile ad altre lunghezze d'onda comunemente impiegate a tale scopo quali quelle del rosso o del verde (Eitel et al., 2010).

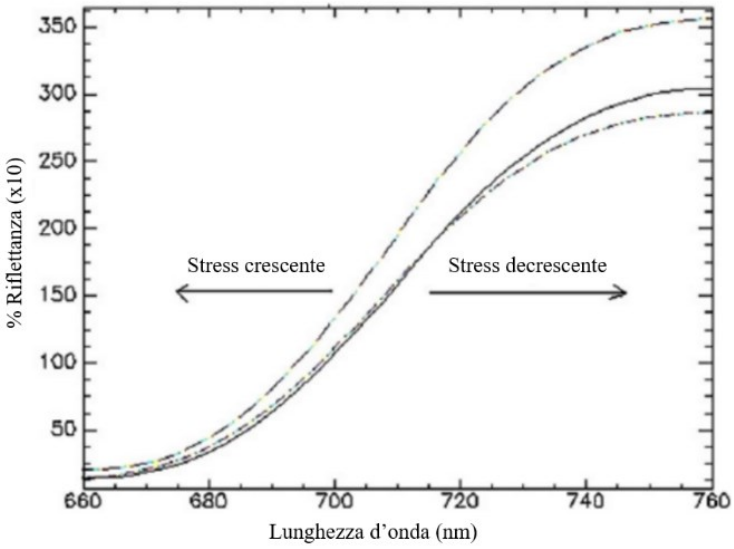

Fig. 7. Spostamento della curva della prima derivata dei valori di riflettanza nel RE verso lunghezze d'onda più corte (blue shift) in presenza di diversi livelli di stress (rielaborato da Cho et al., 2012).

Per questi motivi l'analisi del *RE* è ritenuta informativa di quei tratti cui le variazioni di Chl_{a+b} possono essere associate; per esempio, siccome la carenza idrica influenza il processo di fotosintesi (Moya et al., 2004), il *red edge* può fornire indicazioni sullo stato idrico della

vegetazione (Baranoski & Rokne, 2007) nonostante l'acqua non mostri caratteristiche di assorbimento nella regione del *VIS* (Jacquemoud et al., 2000; Pôças et al., 2015); allo stesso modo l'analisi di questa regione spettrale può essere correlata ad altri tratti clorofilla dipendenti tra cui l'indice di area fogliare (*leaf area index,* LAI) (Delegido et al., 2013). In particolare secondo Filella & Peñuelas (2007) ampiezza e posizione del valore di massimo nel *RE* (dalla funzione derivata), trovano significativa correlazione con concentrazione di Chl_{a+b} e LAI sebbene in quest'ultimo caso l'area della curva del *RE* sia in grado di fornire le migliori stime; lo stato idrico della pianta è anche correlabile all'ampiezza del *RE* tuttavia in modo significativo solo in condizioni di stress idrico avanzato.

Infine il *RE* viene anche considerato nell'identificazione precoce di fattori di stress biotici (Eitel et al., 2011; Horler et al., 2007); in questo ultimo caso la derivata prima dei valori di riflettanza consente di rilevare lo spostamento del punto di flesso tipico della caratteristica spettrale del *red edge* verso le lunghezze d'onda del blu (*blue shift*) fenomeno che, potendo essere associato alla precoce perdita di Chl_{a+b}, può rappresentare un elemento di identificazione della situazione di stress anche in fasi precedenti la visualizzazione dei sintomi (Junges et al., 2020; Rock et al., 1988) (fig. 7); tale fenomeno, tuttavia, si verifica senza specificità rendendo quindi difficile la discriminazione di stress differenti (Junges et al., 2018) essendo in effetti la perdita di Chl_{a+b} considerata una risposta fisiologica molto comune e quindi aspecifica (Carter & Knapp, 2001).

2.3 PIATTAFORME PER L'OSSERVAZIONE TERRESTRE

Le tecnologie di *RS* possono essere impiegate per raccogliere dati sulla vegetazione utilizzando una varietà di piattaforme che agiscono su più livelli, a partire dalle misurazioni prossimali fino a quelle aeree e satellitari (Gamon et al., 2019); è comune categorizzare le attività di RS in funzione della piattaforma impiegata (Toth & Jóźków, 2016), distinguendo per ciascuna una serie di parametri che delineano le possibilità di utilizzo delle stesse piattaforme tra cui si citano risoluzione spaziale, risoluzione temporale e altitudine di acquisizione (Mulla, 2013).

I differenti sistemi di RS non devono necessariamente essere considerati in modo indipendente; alcuni autori suggeriscono infatti la possibilità di integrare le informazioni ottenute da diversi strumenti di RS nell'ambito di un unico sistema di osservazione colturale guadagnando, dall'impiego coordinato di varie piattaforme, una migliore efficacia di monitoraggio ed intervento (Hoff & Christopher, 2012; McKellip et al., 2005).

2.3.1 Risoluzione spaziale

La risoluzione spaziale viene definita dall'area del più piccolo pixel identificabile (fig. 8): all'aumentare della risoluzione spaziale diminuisce l'estensione di superficie dell'unità minima dell'immagine (pixel) ottenendo un aumento del livello di omogeneità delle caratteristiche della superficie analizzata all'interno di un dato pixel; al contrario una bassa risoluzione spaziale, ovvero una maggiore dimensione dei pixel, va ricondotta ad un incremento dell'eterogeneità delle caratteristiche per quel pixel (Mulla, 2013). L'alta risoluzione spaziale è ottenibile con sistemi come SAPR che si distinguono per livelli di risoluzione spaziale quantificabili nell'ordine dei centimetri (Matese et al., 2015; Ouédraogo et al., 2014; Morgan et al., 2022).

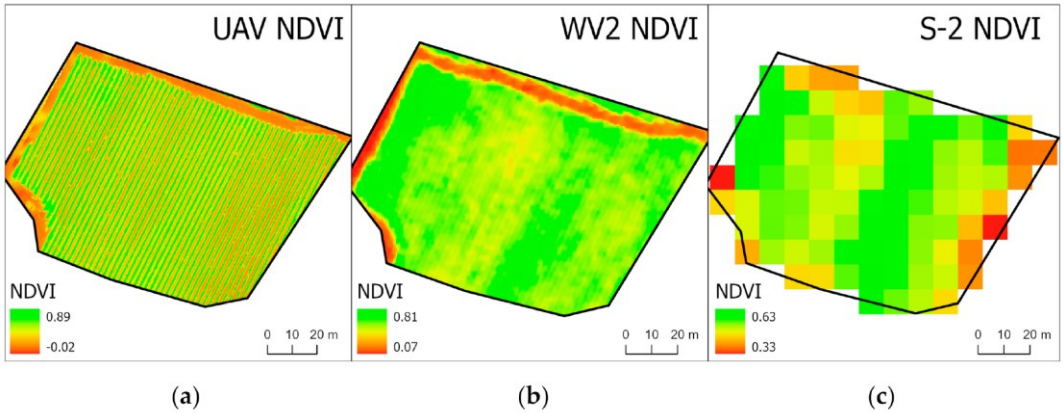

Fig. 8. Mappa di vigore vegetativo (NDVI) visualizzata con tre differenti risoluzioni spaziali ottenute con: (a) SAPR, (b) Worldview-2, (c) Sentinel-2 (Giovos et al., 2021).

Le immagini ad alta risoluzione spaziale sono in grado ampliare il livello di informazione spettrale acquisibile andando a rappresentare con maggiore dettaglio l'eterogeneità spettrale associata alla struttura epigea della pianta (Zhang et al., 2006); questo permette di ampliare il numero di possibili applicazioni potendo investigare caratteristiche della superficie altrimenti non distinguibili (Brook et al., 2020).

Ulteriori vantaggi sono ottenibili in termini di segmentazione dell'immagine, di interesse ad esempio in un contesto di coltivazioni a filare dove, diversamente da colture a seminativi, può sorgere la necessità di adottare tecniche di classificazione di pixel in modo tale da distinguere la chioma presente sul filare da elementi di disturbo presenti nell'interfilare (Sun et al., 2017) il che si ritiene possibile solo attraverso una sufficiente risoluzione spaziale (Campos et al., 2021) ed è facilmente realizzabile, ad esempio, con il metodo "*maximum value composite*" (McKellip et al., 2005) oppure tramite la definizione di una regione di interesse (*region of*

interest, ROI) da cui poter estrarre l'informazione di riflettanza pura della chioma; nel caso di colture a filare il ROI può essere identificato con il centro del filare stesso (Zarco-Tejada et al., 2013) (fig. 9).

Con sistemi a media o bassa risoluzione al contrario l'informazione spettrale pura della chioma non viene distinta dai segnali spettrali associati a classi di diversa natura (e.g. suolo o copertura vegetale) presenti nell'interfilare (Campos et al., 2021; Kaur et al., 2019), così i valori di riflettanza rilevati per un determinato pixel diventano rappresentativi non dell'informazione spettrale pura della chioma ma piuttosto di una media delle informazioni di entrambi gli elementi presenti sulla fila e tra le file (Matese et al., 2015). Sebbene pixel misti, cioè pixel il cui valore di riflettanza trova relazione spettrale con elementi appartenenti a classi diverse, siano presenti anche in immagini ad alta risoluzione in queste esiste la possibilità di distinguere e riclassificare gli stessi tramite procedure di *unmixing* (Kaur et al., 2019).

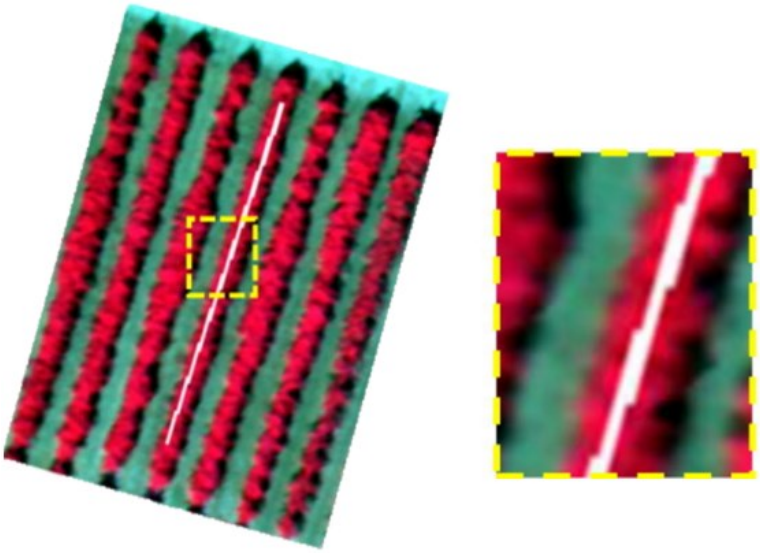

Fig. 9. Identificazione della regione di interesse (linea bianca) per l'estrazione di pixel contenenti l'informazione spettrale pura della chioma (Zarco-Tejada et al., 2013).

A fianco dei vantaggi ottenibili da immagini ad alta risoluzione, difficoltà nella gestione dei dati possono concretizzarsi in quanto ad alti livelli di risoluzione spaziale vengono resi evidenti anche segnali spettrali in grado di complicare le operazioni di elaborazione dei dati tra cui variazioni di riflettanza imputabili a caratteristiche strutturali della chioma (e.g. diverso angolo di inserzione delle foglie) in grado di influenzare il segnale spettrale dei singoli pixel

(Lopatin et al., 2017); all'aumentare della risoluzione spettrale, aumenta inoltre la quantità di pixel contenenti dati di riflettanza significativamente affetti dalla presenza di ombre (Milas et al., 2017), essendo queste determinate da un effetto di ostruzione della luce e quindi del segnale che può essere raccolto dal sensore determinano una perdita parziale o pressoché totale del segnale di riflettanza (Leblon et al., 1996) potendo influenzare negativamente l'accuratezza dei risultati ottenibili (de Sá et al., 2018; Zhang et al., 2015); non necessariamente una superiore risoluzione spaziale conduce ad una maggiore accuratezza e per determinati fini applicativi un aumento della dimensione dei pixel può contribuire ad ottenere risultati più accurati, la risoluzione spaziale va calibrata in funzione del tipo di applicazione (Zhang et al., 2015).

2.3.2 Altitudine

Una modalità di classificazione delle piattaforme di *RS* prende in considerazione la distanza dal target a cui le stesse sono in grado di operare (Mulla, 2013) potendo distinguere: (i) piattaforme terrestri, tra cui vengono inclusi vari sistemi fissi o mobili ma anche dispositivi portatili (Jin et al., 2020), (ii) piattaforme a bassa altitudine, con particolare riferimento a Sistemi Aeromobili a Pilotaggio Remoto (SAPR), i quali sono in grado di garantire una buona flessibilità in termini di altitudine potendo operare a diversi livelli di quota, compresi indicativamente tra 30-100 m (Zhou et al., 2021), (iii) piattaforme ad alta altitudine, nonché dirigibili o aeromobili che lavorano nella troposfera, ad una altitudine superiore a 20 km (D'Oliveira et al., 2016), (iv) piattaforme satellitari spesso operanti a livelli di altitudine compresi tra 250-700 km (Hoff & Christopher, 2012).

In accordo con la legge dell'inverso del quadrato, l'intensità luminosa diminuisce all'aumentare della distanza tra sorgente e ricevente secondo una relazione quadratica (Born & Wolf, 2013; Brownson, 2014); tale principio fisico trova validità in ambito di *RS* nella descrizione degli effetti della distanza di lavoro nonché nella definizione della quantità di dettagli spettrali che il sensore è in grado di ricevere; ad esempio a lunghe distanze (e.g. telerilevamento satellitare) l'influenza di caratteristiche strutturali e biofisiche della chioma è pressoché nulla mentre queste possono divenire rilevanti quando la scala di rilevamento si riduce (e.g. telerilevamento prossimale) potendo quindi ottenere risultati differenti a seconda della piattaforma utilizzata (fig. 10) (Liu et al., 2020).

Inoltre, i dati di riflettanza raccolti dal sensore non dipendono unicamente dalle caratteristiche della superficie oggetto di studio infatti, in un sistema reale, la radiazione luminosa non

interagisce unicamente con l'obiettivo dell'osservazione ma anche con l'atmosfera in cui essa si muove, le cui caratteristiche (e.g. umidità, temperatura) possono avere influenza non trascurabile sulla misurazione (Acorsi et al., 2020; Dave, 1980); le componenti atmosferiche (e.g. aerosol e gas atmosferici) interagiscono sia con la luce diretta verso il target, sia con la componente da esso riflessa, fondamentalmente tramite processi di assorbimento e dispersione (Horvath, 1993); i sistemi di *RS* che operano ad alta altitudine e quindi basati su piattaforme aeree e satellitari sono significativamente affetti dalle condizioni atmosferiche ed in particolare da nuvolosità che può rendere in taluni casi inutilizzabili le immagini ottenute (Adão et al., 2017; Finger et al., 2019; Moran et al., 1997).

Al contrario, l'effetto di tali condizioni sulla raccolta dei dati è meno rilevante nell'impiego di piattaforme associate a rilevamento prossimale (Mulla, 2013) così come per piattaforme aeree in grado di operare a bassa altitudine (SAPR) (Fiorucci et al., 2018; Xue & Su, 2017); in tale situazione la vegetazione viene raggiunta da una radiazione diffusa ottenendo un effetto di riduzione delle ombre dovute a caratteristiche strutturali della chioma e, particolarmente per piattaforme terrestri, anche imputabili alla presenza stessa di veicoli impiegati ai fini di raccolta dei dati spettrali (Liu et al., 2020); la presenza di ombre è generalmente associata ad una minore accuratezza dei risultati (Furukawa et al., 2021), in un contesto di rilevamento prossimale o a bassa altitudine (e.g. SAPR) la presenza di una completa copertura nuvolosa è quindi preferibile (Duffy et al., 2018); se contrariamente, il rilevamento avviene in situazioni di cielo sereno o poco nuvoloso, la geometria solare andrà considerata (Liu et al., 2020).

Nel caso di SAPR, per i quali l'altitudine risulta essere un parametro facilmente modulabile, occorre considerare i diversi effetti che si possono ottenere per voli a quote diverse (Gómez-Candón et al., 2014); ad una diminuzione della quota di volo si ottiene un proporzionale aumento della risoluzione spaziale (dimensione dei pixel) (fig. 10) da cui deriva la possibilità di catturare immagini con un maggiore dettaglio spettrale, la diminuzione della quota di volo può essere quindi proposta per ottenere una maggiore accuratezza (Peña et al., 2015); Al contrario tuttavia, l'area visualizzata dalle singole immagini diminuisce il che trova come diretta conseguenza un incremento del tempo utile a coprire l'intera area di studio e parallelamente una crescita dei costi (de Castro et al., 2015); infine l'impiego di velivoli a bassa altitudine può aumentare la complessità delle procedure di elaborazione comportando spesso la necessità di unire diversi *frame* video (*mosaicking*) al fine di ottenere un'ortofoto comprensiva dell'intera area di studio (Avola et al., 2020).

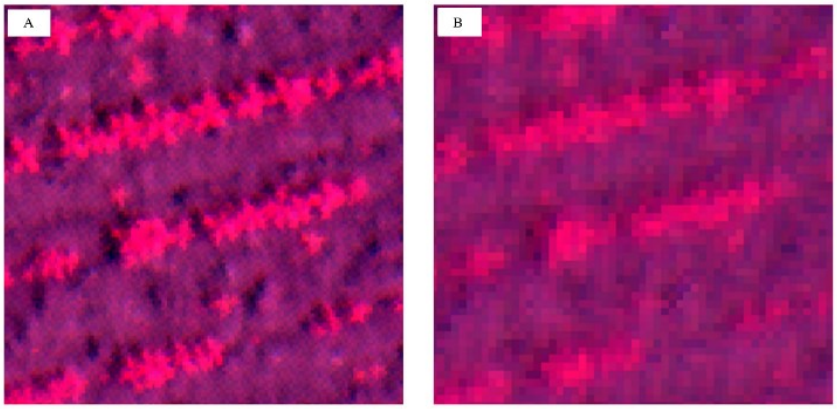

Fig. 10. Dettagli della risoluzione spaziale ottenuti da un sensore e multispettrale a diversi livelli di quota: (A) 40 m di altitudine (B) 100 m di altitudine (Peña et al., 2015).

2.3.3 *Risoluzione temporale*

La risoluzione temporale è identificata dalla frequenza con la quale, per un dato sito, è possibile ottenere delle immagini (Mulla, 2013). Nel caso delle piattaforme satellitari, la risoluzione temporale è associata al relativo tempo di rivisitazione, parametro che, essendo rigidamente definito, va a escludere la possibilità di prevedere dei voli in funzione di eventi specifici (Lechner et al., 2020); nonostante ciò occorre considerare che se per piattaforme satellitari quali quelle appartenenti alla serie *Landsat*, il relativo tempo di rivisitazione di 16 giorni, può essere considerato troppo ampio per determinate applicazioni (McCabe et al., 2017) la tendenza alla realizzazione di costellazioni satellitari, gruppi satellitari coordinati, ha permesso il raggiungimento di una migliore copertura temporale (Lechner et al., 2020); a titolo di esempio, la costellazione di nanosatelliti *CubeSat* lanciati dalla società *Planet labs,* è in grado di garantire un tempo di rivisitazione prossimo ad 1 giorno (fig. 11) insieme ad una risoluzione spaziale fino a 3 metri, superando almeno teoricamente le problematiche legate ad un troppo lungo tempo di rivisitazione (Junqueira et al., 2021);

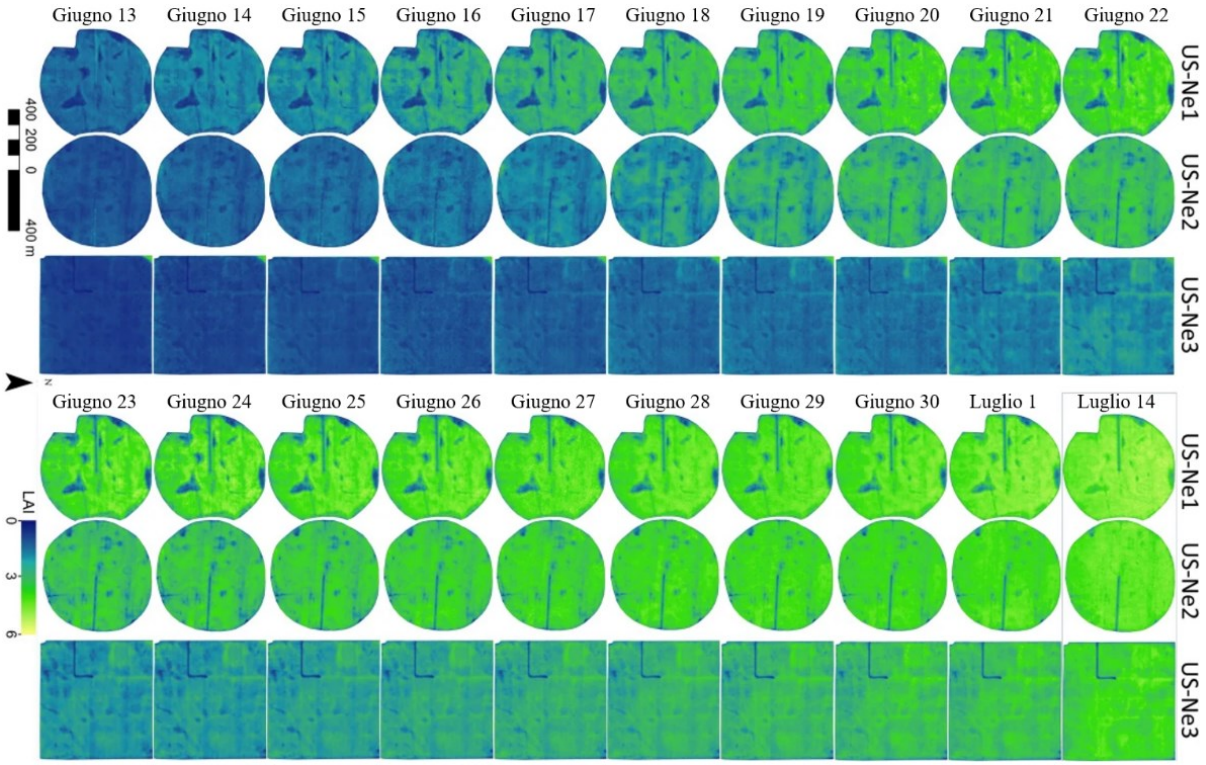

Fig. 11. Serie giornaliera di 19 giorni, delle mappe dell'indice di area fogliare (LAI) ottenuta dai dati della costellazione CubeSat, durante un periodo della stagione vegetativa (13 giugno – 1° luglio 2019) ed un giorno selezionato (14 luglio) con valori LAI di picco, di due appezzamenti irrigati (US-Ne1, US-Ne2) ed un controllo non irrigato (US-Ne3) (rielaborato da Johansen et al., 2022).

Tuttavia, occorre sempre considerare che questi valori di risoluzione temporale possono essere soggetti a variazioni essendo la capacità di acquisizione dei dati spettrali a livello satellitare sostanzialmente vincolata dalle condizioni del cielo nel momento di rivisitazione (Furukawa et al., 2021).

La risoluzione temporale è uno dei principali elementi da considerare in un contesto di monitoraggio di parametri rapidamente variabili nel tempo (e.g. stato idrico) (Knipper et al., 2019) e di valutazione dello stato sanitario della vegetazione per la quale, al fine di poter rispondere efficacemente allo sviluppo patogenico, sono richieste tempestive azioni di controllo che partono proprio da una rapida identificazione (McKellip et al., 2005); mediante strumenti con bassa risoluzione temporale la risposta può essere insufficiente per fornire informazioni di valore ai fini della gestione delle operazioni colturali (Knipper et al., 2019; Veysi et al., 2017) e per tale motivo, in tali contesti di utilizzo, diviene di fondamentale supporto l'utilizzo di piattaforme in grado di garantire una alta frequenza di ritorno, tra cui SAPR vengono citati (Burkart et al., 2018). L'impiego di tali piattaforme consente una più

puntuale pianificazione delle operazioni di acquisizione delle immagini potendo infatti mantenere un buon livello di indipendenza dalle locali condizioni di illuminazione, anche in presenza di coperture nuvolose (Fiorucci et al., 2018).

2.4 IMAGING SPETTRALE

L'*imaging* spettrale (*spectral imaging*, *SI*) si riferisce ad un gruppo di tecniche di RS che combinano due modalità di rilevamento i.e. *imaging* e spettrometria (Garini et al., 2006): attraverso l'*imaging* si recuperano le informazioni relative alla forma fisica della pianta nonché alla sua struttura mentre la spettrometria definisce le informazioni spettrali cui le caratteristiche chimiche e fisiche della superficie in osservazione si riferiscono (Mishra et al., 2020); in questo modo a differenza delle telecamere *RGB* (*red, green, blue*) che catturano la luce esclusivamente nello spettro visibile e limitatamente alle lunghezze d'onda del rosso, verde e blu, le tecniche di *SI* consentono di completare l'informazione spettrale nel visibile ed oltretutto estendere l'esplorazione ad altre componenti dello spettro elettromagnetico (Li et al., 2014).

Tra le diverse tecniche di RS spettrale *imaging* multispettrale (MI) ed *imaging* iperspettrale (HSI) vengono citati (Gracia-Romero et al., 2017); le maggiori differenze si evidenziano nelle caratteristiche tecniche dei sensori ottici impiegati per l'analisi della radiazione riflessa i.e. ampiezza e numero delle bande a cui gli stessi dati di riflettanza dati possono essere catturati (Lechner et al., 2020).

2.4.1 Imaging iperspettrale

Per un dato intervallo di lunghezze d'onda, tipicamente compreso tra 400-2500 nm, i sensori iperspettrali consentono di ottenere l'informazione spettrale relativa ad un insieme continuo di bande che hanno la caratteristica di essere strette, nonché con ampiezza inferiore a 10 nm (Garg, 2020; Hansen & Schjoerring, 2003), e tra di loro contigue (Folkman et al., 2001; Green et al., 1998).

Per la stessa superficie si può ottenere pertanto un set di immagini 2-D simultanee, ciascuna ad una specifica lunghezza d'onda (Fabiyi et al., 2021); queste immagini vengono comunemente visualizzate tramite una rappresentazione tridimensionale ottenuta per sovrapposizione delle stesse immagini 2-D, a formare un cubo iperspettrale di dati (*hypercube*), una immagine grafica 3-D individuata da due dimensioni spaziali (x, y) e una dimensione spettrale (λ) (fig. 12) (Huang et al., 2014; Mulla, 2013).

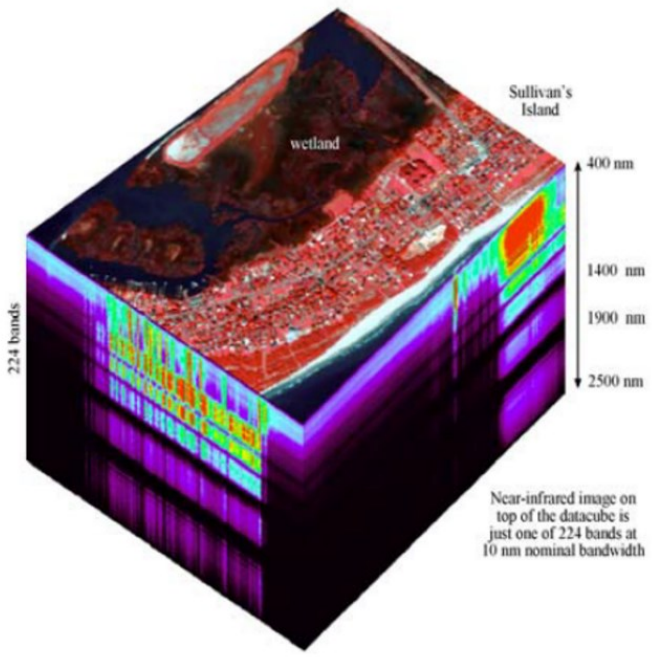

Fig. 12. Cubo di dati iperspettrale Airborne Visible Infrared Imaging Spectrometer (AVIRIS) di Sullivand's Island (SC) ottenuta il giorno 26 ottobre 1998; sulla sommità del cubo un'immagine ottenuta nel NIR, su una delle 224 ottenute su bande strette di ampiezza 10 nm (PPT – Dr. John R. Jensen Department of Geography University of South Carolina Columbia, SC 29208 PowerPoint Presentation ID:5526131, n.d.).

In questo modo ogni pixel del cubo di dati contiene l'informazione relativa a ciascuna delle bande rilevate dal sensore iperspettrale ed essendo le stesse bande rilevate con un approccio continuo, a partire da un cubo di dati iperspettrale è possibile estrarre, per ciascun pixel, uno spettro completo (Fabiyi et al., 2020); i sistemi di rilevamento iperspettrale (HS) si avvantaggiano dell'integrazione di tecniche spettroscopiche (relative allo studio dello spettro elettromagnetico) e di *imaging* (a supporto di forma e struttura della chioma) in una unica tecnologia potendo equiparare *HSI* a termini quali "*imaging spectroscopy*" o "*imaging spectrometry*" (Adão et al., 2017; Jia et al., 2020).

La capacità dei sensori HS di investigare la risposta spettrale ad incrementi ridotti (< 10 nm), in modo continuo, su tutto il range di lunghezze d'onda di interesse, si traduce nell'ottenimento di immagini contenenti l'informazione di centinaia di bande diverse (Schweizer & Moura, 2001).

La grande quantità di informazioni spettrali ottenibile attraverso sistemi di HSI è in generale eccedente rispetto alle informazioni realmente informative in relazione a quelli che sono i fini dell'analisi (Mariotto et al., 2013), questa caratteristica è peraltro intrinseca nell'etimologia stessa del termine "iperspettrale" il cui prefisso *iper-* va a denotare per l'appunto eccesso,

sovrabbondanza (Hunt & Daughtry, 2017); in questi termini, i vantaggi dell'*HSI* sono relativi: quando le bande utili non sono conosciute a priori è vantaggioso avere a disposizione un numero di bande in eccesso piuttosto che in difetto, qualora, al contrario, vi sia conoscenza dei canali a cui l'informazione di riflettanza andrà ricercata, la possibilità di limitare l'analisi ad un numero ridotto di canali non comporta svantaggi (Hunt & Daughtry, 2017); la alta dimensionalità del *dataset* è anzi correlata a difficoltà di gestione dei dati iperspettrali innanzitutto in termini di incremento della complessità nonché delle tempistiche necessarie per l'elaborazione dello stesso set di dati (Al-Saddik et al., 2018; Bradter et al., 2020) evidenziando una certa carenza di tempestività, esigenza cruciale per applicazioni tra le quali, a titolo esemplificativo, si cita la gestione di stress biotici (Wu et al., 2016) per le quali, la possibilità di intervenire efficacemente, è in effetti strettamente connessa alle esigenze stesse di tempestività (Adokiya et al., 2016); inoltre, nella gestione di un ampio volume di dati, tempi di trasferimento, costi e capacità di archiviazione diventano critici (Jia et al., 2020; Ribalta et al., 2020; Schweizer & Moura, 2001).

Ulteriori criticità si rendono poi evidenti quando tecniche di intelligenza artificiale (AI) vengono applicate a supporto dei processi di classificazione di immagine dove la presenza di informazioni ridondanti determina un calo delle performance dei convenzionali modelli di classificazione, in accordo con il fenomeno di Hughes per il quale l'accuratezza della classificazione aumenta con l'aumentare delle bande analizzate fino a raggiungere un numero massimo di canali oltre il quale la stessa accuratezza subisce una drastica riduzione (Fabiyi et al., 2021; Hughes, 1968). Inoltre, sempre in tale contesto viene messa in luce la necessità di prevenire fenomeni di adattamento eccessivo (*overfitting*), spesso segnalati quando i dati iperspettrali vengono utilizzati con modelli empirici (Lee et al., 2004; Ma et al., 2019; Rocha et al., 2017).

Sostanzialmente, nonostante HSI venga citata come una tecnologia potente e versatile (Liu et al., 2020) le possibilità di sviluppo e di diffusione di questi sistemi sono limitate dalla alta quantità di dati che viene generata (Thenkabail et al., 2014); dal momento che le immagini HS includono informazioni spettrali ridondanti o associate a rumore si ritiene tuttavia possibile ragionare nei termini di una riduzione del volume di dati attraverso la selezione di un ridotto numero di bande, informative dei tratti oggetto di analisi (Bradter et al., 2020; Thenkabail et al., 2000); ciò non può tuttavia realizzarsi senza la precedente e completa valutazione di centinaia di lunghezze d'onda e loro combinazioni (indici vegetativi) per definire quali rivelano informazioni significative ai fini di identificare, ed entro una certa

misura quantificare, il tratto oggetto di studio (Bendel et al., 2020; Thenkabail et al., 2004); lo sviluppo di questa tecnologia deve quindi necessariamente essere supportato da rilevanti sforzi di ricerca che consentano di edificare una solida conoscenza in merito a come i vari tratti vegetali contribuiscano alle variazioni di riflettanza misurate così da poter comprendere e descrivere la variabilità spaziale e temporale dei sistemi agrari (Kattenborn et al., 2019; Mariotto et al., 2013); tale sforzo è normalmente coadiuvato da metodi statistici tra i quali il più popolare è probabilmente l'analisi delle componenti principali (*principal component analysis, PCA*) (Farrell & Mersereau, 2005), tecnica di analisi multivariata grazie alla quale è possibile identificare le combinazioni spettrali che meglio modellizzano le caratteristiche della vegetazione supportando il processo di eliminazione di informazioni ridondanti nonché di riduzione dimensionale dei dati iperspettrali (Jain et al., 2007).

In conclusione, ad oggi HSI viene ancora considerato come una nuova direzione di ricerca dato che costi e necessità di ricorrere a complessi metodi di elaborazione ne limitano il potenziale (Liu et al., 2020) la cui espressione si ritiene dipenderà fortemente dal progresso che verrà raggiunto nell'ambito delle tecnologie applicate di elaborazione (e.g. *machine learning*) e gestione dei dati (e.g. *cloud-computing*) (Aneece & Thenkabail, 2021).

2.4.2 Imaging multispettrale

A differenza dei sistemi di *HSI* in grado di fornire dati spettrali in modo continuo su centinaia di bande ad intervalli ristretti (5-10 nm) (Garg, 2020), i sistemi di imaging multispettrale (*multispectral imaging, MI*) analizzano la riflettanza in modo discreto limitando inoltre l'analisi a un numero ridotto di bande selezionate, in genere inferiore a 10 (Bendel et al., 2020; Hsu, 2007) e spesso in numero di 2-4 (Lamb, 2001) (fig. 13); In una immagine multispettrale, manca l'informazione di alcune porzioni dello spettro ovvero singoli pixel non contengono informazioni sufficienti a ricavare dagli stessi uno spettro completo, data la natura sparsa e discreta dei dati di riflettanza raccolti (fig.13) (Qin et al., 2013).

La risoluzione spettrale dei sensori multispettrali, nonché la capacità di discriminare due picchi distinti nello spettro analizzato, è inferiore a quella ottenibile con sensori iperspettrali (Mulla, 2013); l'ampiezza delle bande spettrali rilevate è infatti indicativamente di 30 nm nel VIS mentre superiore a 100 nm nello SWIR (Giovos et al., 2021).

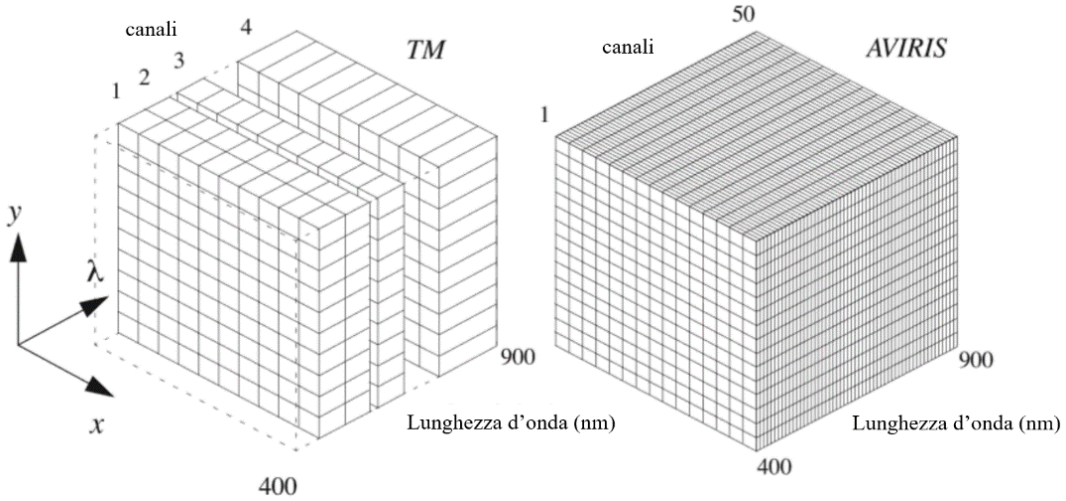

Fig. 13. Schematica visualizzazione tridimensionale dei dati spettrali e spaziali ottenuti con Landsat TM (MS) e AVIRIS (HS) nelle regioni spettrali di VIS e NIR (VNIR) (rielaborato da Schowengerdt, 2006).

MI trova pertanto dei limiti di utilizzo quando l'informazione di riflettanza è disponibile solo ad incrementi spettrali ridotti (e.g. 10-20 nm) e tali da non essere discriminata da sensori multispettrali data la non sufficiente risoluzione spettrale e richiedendo di fatto l'utilizzo di sistemi di *HSI* (Adão et al., 2017; Croft et al., 2015; Lee et al., 2004; Mulla, 2013); al contrario la disponibilità di tecnologie di *HSI* è associata, attraverso firme spettrali altamente dettagliate, ad una quantità di dati sufficiente ad estendere in modo significativo il numero di sostanze discriminabili (Hsu, 2007), migliorare la sensibilità rispetto ai parametri di interesse (Thenkabail et al., 2000), migliorare prestazioni di indici vegetativi (Mutanga & Skidmore, 2004), individuare bande spettrali per una stima accurata di specifici parametri biofisici e biochimici (Kira et al., 2015), inoltre consentendo l'identificazione di variazioni anche lievi della risposta spettrale della superficie analizzata vengono offerte opportunità di sviluppo di applicazioni quali il rilevamento precoce fattori di stress (Nguyen et al., 2021).

L'*MI* rappresenta rispetto all'*HSI*, una alternativa tuttavia conveniente, economicamente così come per minore complessità computazionale, rapidità di analisi e capacità di archiviazione richiesta rimanendo di riferimento nonostante il minore livello di approfondimento spettrale che tale tecnologia è in grado di fornire (Liu et al., 2020); alcuni autori in effetti sottolineano l'importanza di trovare il giusto compromesso tra esigenze di qualità delle immagini e di tempestività (Garini et al., 2006), considerando peraltro che non tutte le possibilità di impiego delle tecnologie di RS richiedono il livello di dettaglio che le tecniche di HSI possono fornire (Mas Garcia et al., 2021): in determinati casi di applicazione, in effetti, le differenze che si

possono rilevare impiegando alternativamente le tecnologie sopracitate non sono significative o comunque non tali da rendere HSI indispensabile al fine di ottenere un livello sufficiente di accuratezza (Badzmierowski et al., 2019; Bradter et al., 2020; Elvidge & Chen, 1995; Halme et al., 2019), inoltre il minore grado di approfondimento spettrale tipico dell'approccio multispettrale può portare a vantaggi operativi anche rilevanti trovando buona collocazione nei sistemi di utilizzo reale, per tali ragioni può essere interessante la simulazione di un sistema multispettrale attraverso la selezione di un numero limitato, indicativamente inferiore o uguale a dieci, di bande iperspettrali (Bendel et al., 2020). Occorre infine sottolineare che, nonostante miniaturizzazione della sensoristica e presentazione della stessa a prezzi sostenibili per un maggior numero di realtà produttive siano tendenze che fanno presupporre delle possibilità di diffusione ubiquitaria dei sistemi di *HSI* (Lechner et al., 2020) attualmente, nonostante la potenza delle tecnologie iperspettrali, queste sono tendenzialmente legate a piattaforme satellitari o mezzi aerei ad alta altitudine rimanendo quindi vincolate ai limiti che derivano dall'impiego di tali piattaforme (Liu et al., 2020); contrariamente l'impiego di tecnologie di *MI* risulta di estrema diffusione in associazione a SAPR (Lechner et al., 2020) confermandosi tra le migliori possibilità di scelta qualora ad essere richieste siano tempestività, osservazioni ripetute, flessibilità di volo ed alta risoluzione spaziale (Wójtowicz et al., 2016).

2.5 APPROCCIO ALL'ANALISI DEI DATI SPAZIALI

Le tecnologie di RS, supportate da sistemi di posizionamento globale (*global positioning system*, GPS) e sistemi informativi geografici (*geographic information system*, GIS), danno accesso ad un ampio bacino di dati informativi (Milla et al., 2005) il che risulta fondamentale ai fini di raggiungimento degli obiettivi di gestione sito-specifica delle colture agrarie. Tuttavia, il successo di questo approccio è legato, tra le altre cose (e.g. gestione dei processi di acquisizione, elaborazione, archiviazione, rappresentazione dei dati), alla possibilità di analizzare e interpretare correttamente le informazioni ottenute da tali sistemi (Huang et al., 2018) come pure alla necessità di generalizzare i criteri adottati, sia spazialmente che temporalmente (Foody et al., 2003).

Al fine di ricavare, a partire dai dati rilevati, informazioni utili alla gestione dei sistemi colturali vengono generalmente proposti due principali approcci metodologici, rispettivamente meccanicistici ed empirici (Weiss et al., 2020; Xie et al., 2019).

Gli approcci meccanicistici presuppongono che la descrizione del sistema faccia riferimento alla conoscenza dei meccanismi chiave coinvolti nella determinazione dei fenomeni misurati; i processi inclusi nel modello meccanicistico, nonostante la relativa specificità, sono sufficientemente generici da mantenere una certa rilevanza anche al variare di condizioni e parametri che caratterizzano il sistema oggetto di studio nonché dal momento in cui lo stesso modello viene utilizzato per descrivere entità tra loro diverse (Baker et al., 2018), i modelli meccanicistici possono così essere usati per fare previsioni rispetto ai tratti oggetto di studio (Resco de Dios et al., 2015).

Gli approcci empirici si basano su mezzi puramente statistici, ad esempio, analisi della regressione (Kira et al., 2016), nonché sulla stima della relazione funzionale tra il set di dati ottenuto dai processi di acquisizione ed elaborazione e la variabile di interesse direttamente misurata (Bala & Islam, 2009) e valutazione dei modelli statistici ricavati, per comparazione dei relativi coefficienti di determinazione (Campos et al., 2021); è possibile stimare relazioni statistiche tra dati anche in assenza di conoscenze in merito ai rapporti causa-effetto che determinano i parametri misurati, con questo approccio lo sguardo ai meccanismi che guidano le dinamiche del sistema osservato è pertanto limitato; questi ultimi non danno garanzia della robustezza del modello ottenuto in quanto per garantirne la piena trasferibilità i parametri modellizzati dovrebbero idealmente rimanere costanti (Korzukhin et al., 2011): spesso gli studi empirici mettono in evidenza relazioni ad alta correlazione relativamente ad uno specifico sito o specie ma ridotto potere predittivo viene messo in luce quando la stessa relazione viene trasferita ad un sito od una specie differente (Bowyer & Danson, 2004).

Da tali considerazioni deriva la necessità di porre particolare attenzione ai contesti in cui questi approcci vengono impiegati ai fini di analizzare sistemi spazialmente e temporalmente complessi, come pure variabili, quali quelli agrari (Combal et al., 2003); occorre pertanto, nell'adozione di un approccio empirico, mantenere in considerazione che le relazioni ricavate, essendo calibrate rispetto alle specifiche osservazioni sperimentali, in assenza di ulteriori approfondimenti, rimangono sostanzialmente vincolate alla rappresentatività del set di dati nonché alle condizioni ambientali e colturali cui il lavoro sperimentale è riferito (Weiss et al., 2020); ciò pone dei limiti rispetto alla possibilità di trasferire la relazione stimata al variare di condizioni atmosferiche (Xiao et al., 2003), caratteristiche topografiche (Matsushita et al., 2007), angolo di acquisizione dei dati (Mao et al., 2020) specie vegetale (Bremer et al., 2011), cultivar (Albetis et al., 2017; Boulent et al., 2020), e fase fenologica (Colombo et al., 2003; Junges et al., 2018).

Sebbene non sia possibile definire a priori l'approccio più adatto, che dovrà essere invece stabilito congiuntamente alle applicazioni di interesse per i soggetti coinvolti (Weiss et al., 2020), in linea generale gli approcci empirici trovano comune utilizzo in ambito di RS della vegetazione (Ramoelo et al., 2015); occorre infatti considerare che lo sviluppo di modelli meccanicistici comporta notevole complessità (Kuparinen, 2006) al contrario, le tecniche empiriche hanno portato dimostrazione della capacità di stima di relazioni ad alto potenziale esplicativo con relativa facilità operativa e computazionale, il che rende le stesse tecniche ampiamente diffuse (Jensen et al., 2019). In relazione a queste ultime, la modalità operativamente più impiegata prevede il calcolo di indici vegetativi (VI) (Finger et al., 2019; Martos et al., 2021; Xie et al., 2019), possibilità confermatasi per la capacità di monitorare ed analizzare in modo rapido variazioni spaziali di numerosi tratti della vegetazione (Hashimoto et al., 2019).

2.6 INDICI VEGETATIVI

A partire da una immagine telerilevata, per ciascuna lunghezza d'onda è possibile estrarre l'informazione di riflettanza ad essa associata la quale è identificativa di specifiche caratteristiche della superficie analizzata (Hatfield et al., 2019).

Nelle condizioni di campo la risposta spettrale rilevata risulta tuttavia normalmente influenzata da fattori di disturbo (e.g. caratteristiche del suolo, caratteristiche dell'atmosfera, effetti di ombreggiamento) (Boulent et al., 2020); per tale motivo, in ambito di RS, la ricerca si è focalizzata sulla possibilità di minimizzare gli effetti di rumore ed esaltare la risposta della vegetazione con il fine di evidenziarne tratti definiti (Bannari et al., 1995; Jackson & Huete, 1991). Tale impulso trova realizzazione attraverso lo sviluppo di indici spettrali, più specificatamente indici vegetativi (VI) qualora in riferimento all'analisi spettrale delle superfici vegetali (Huang et al., 2021).

Concettualmente gli indici vegetativi trovano immediata definizione, rappresentando la semplice combinazione matematica di valori di riflettanza misurati su due o più bande spettrali (Giovos et al., 2021; Hatfield et al., 2019), selezionate sulla base di determinate proprietà spettroscopiche della vegetazione (Kattenborn et al., 2019); in questo modo a partire da una serie di immagini diverse, ciascuna contenente l'informazione relativa ad una specifica banda spettrale, è possibile generare un'unica immagine in grado di risaltare caratteristiche o *pattern* definiti ottenendo così sia una migliore rappresentazione degli oggetti presenti sul

suolo che una più semplice interpretazione di ciò che altrimenti rimarrebbe un complesso insieme di dati (Huang et al., 2021) (fig. 14).

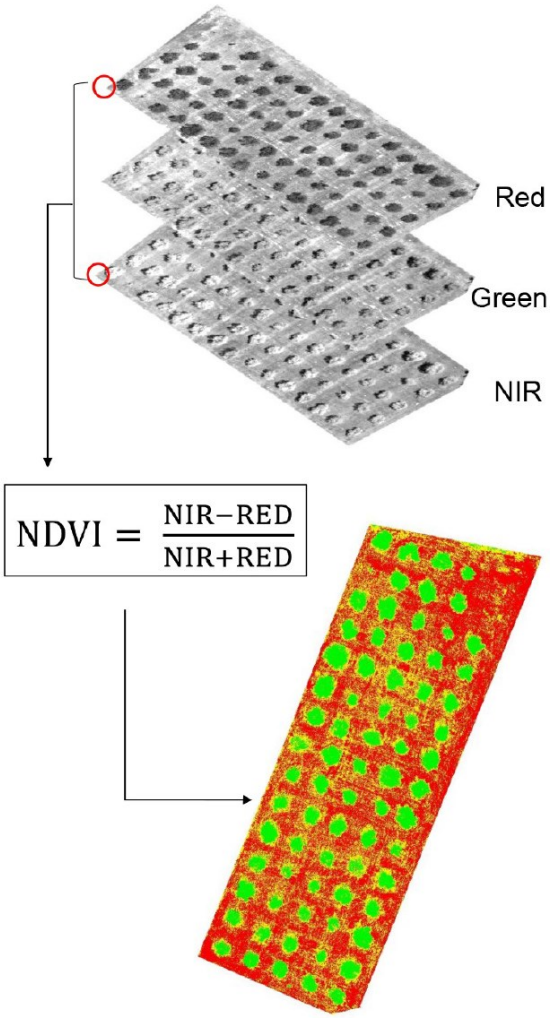

Fig. 14. Schematica rappresentazione del calcolo di un generico indice vegetativo (NDVI) (rielaborato da Caruso et al., 2019).

Lo sviluppo dei VI può essere originariamente attribuito a Jordan (1969) il quale attraverso *Ratio Vegetation Index* (RVI) correlò il rapporto dei valori di riflettanza nel NIR (800 nm) e nel RED (675 nm) (eq. 2) all'indice di area fogliare (LAI) basandosi sul principio per il quale gli organi verdi assorbono una minore quantità di luce nel NIR piuttosto che nel RED, potendo pertanto correlare positivamente RVI all'estensione fogliare della pianta.

$$RVI = \frac{NIR}{RED} \qquad eq.2$$

In generale i VI vengono considerati per la potenzialità di fornire delle informazioni facilmente interpretabili nonché immediatamente spendibili (Joshi & Chandra, 2011) il che ha

reso gli stessi uno strumento di RS sul quale gran parte delle attuali applicazioni si focalizzano (Hatfield et al., 2019).

2.6.1 Classificazione degli indici vegetativi

A seconda dell'ambito di interesse i diversi VI possono essere distinti impiegando differenti criteri di classificazione (Bannari et al., 1995); in ambito di SI, lo sviluppo delle tecnologie di *imaging* multi- ed iperspettrale ha accompagnato la definizione di due tendenze rispetto allo sviluppo di VI le quali sono diretta conseguenza della risoluzione spettrale del sensore impiegato ovvero (i) indici vegetativi a banda larga (*broadband vegetation indices*) i.e. indici multispettrali (ii) indici vegetativi a banda stretta (*narrowband vegetation indices*) i.e. indici iperspettrali (Hatfield et al., 2008).

Più di un centinaio di VI tra quelli ad oggi a disposizione sono stati sviluppati a partire da immagini multispettrali (Xue & Su, 2017), tuttavia la possibilità di investigare la risposta spettrale della superficie su centinaia di lunghezze d'onda diverse, concretizzatasi parallelamente allo sviluppo delle tecnologie iperspettrali, rende le possibili combinazioni di lunghezza d'onda sperimentabili praticamente infinite (Giovos et al., 2021) aprendo a nuove possibilità di ricerca nonché di applicazione (Xue & Su, 2017) e consentendo di superare il livello di saturazione raggiunto in termini di sviluppo di nuovi VI nei primi anni 2000 (Giovos et al., 2021). Oltre allo sviluppo di nuove combinazioni spettrali, la tendenza allo sviluppo di VI a banda stretta è supportata dalla necessità di perfezionare le prestazioni generali degli VI (Hatfield et al., 2008); Mutanga & Skidmore (2004), ad esempio, hanno sperimentato l'utilizzo di VI a banda stretta per superare i problemi di saturazione che si verificano tipicamente nell'impiego di alcuni VI a banda larga (e.g. NDVI) in condizioni di densa copertura vegetale ottenendo significativi miglioramenti dell'accuratezza nelle stime di biomassa della vegetazione o ancora, secondo Gao (1996) una più accurata stima dello stato idrico della vegetazione è possibile usando NDWI a banda stretta in grado di evitare canali spettrali dove l'informazione di riflettanza è fortemente contaminata dalla presenza di altre molecole (e.g. cellulosa), approccio non possibile attraverso indici a banda larga che vanno inevitabilmente a restituire una informazione che accorpa, insieme alle informazione di interesse, il contributo spettrale di molecole responsabili di rumore.

Nonostante lo sviluppo delle tecniche SI, la possibilità di derivazione di VI a partire da immagini ottenute con sensori RGB suscita interesse al fine di ottenere rapidamente e a costo ridotto, risultati affidabili (Gracia-Romero et al., 2017), spesso anche migliori di quelli

ottenibili attraverso tecnologie di SI (Poley & McDermid, 2020), e questo sembra verificarsi particolarmente quando la possibilità di ottenere immagini ad alta risoluzione spaziale assume, sull'accuratezza dei risultati, un peso maggiore rispetto ai parametri di risoluzione spettrale (Maes & Steppe, 2019). Costi ridotti e semplicità di calcolo fanno dei VI RGB una soluzione in grado di rendere facilmente accessibili le operazioni di raccolta dei dati (Costa et al., 2020) e pertanto di largo utilizzo (Tsouros et al., 2019); nonostante ciò le possibilità applicative dei VI RGB sono ridotte venendo, secondo Giovos et al. (2021), principalmente impiegati per la stima di pigmenti fogliari (e.g. carotenoidi e antociani).

Una panoramica strutturata di diversi VI calcolabili a partire da dati satellitari è stata pubblicata on-line dall'*Institute of Crop Science and Resource Conservation* (INRES, www.indexdatabase.de) dell'Università di Bonn.

2.6.2 Validazione degli indici vegetativi

Le opportunità di sviluppo dei VI seguono un approccio sostanzialmente empirico (Eitel et al., 2008); il criterio più diffuso per definire il potere esplicativo di uno o più VI rispetto ad una variabile di interesse si basa infatti sulla possibilità di stabilire, tra gli indici vegetativi testati e la variabile stessa di interesse, una relazione statistica semplice (Weiss et al., 2020) tipicamente validata sfruttando procedure indirette supportate da valutazioni *in situ* (Xue & Su, 2017). Queste valutazioni possono riguardare semplici analisi visive come per il rilevamento di stress biotici (Albetis et al., 2017), piuttosto che valutazioni di biomassa, LAI (Lelong et al., 2008) e contenuto di pigmenti (Peñuelas et al., 1993), relativamente alla stima di tratti quali vigore e sviluppo vegetativo, come pure misure di conduttanza stomatica o di potenziale idrico per l'analisi dello stato idrico della vegetazione (Bellvert et al., 2014), con il fine ultimo di definire statisticamente la correttezza del modello impiegato nonché la tendenza dell'indice spettrale analizzato a cambiare in funzione della variabile posta ad analisi (Pu & Cheng, 2015; van der Meer, 2004). In taluni casi vengono a tale scopo impiegati sistemi di misura prossimali (Huang et al., 2021; Tokekar et al., 2016) per i quali, si sottolinea, è opportuno verificare che abbiano caratteristiche analoghe a quelle dei sistemi impiegati per le operazioni di telerilevamento aereo e mantenendo un paragonabile angolo di osservazione, potendo così eseguire valutazioni su un campione di piante sentinella georeferenziate (Xue & Su, 2017).

2.6.3 Normalized Difference Vegetation Index

Tra i VI più noti e diffusi il *normalized difference vegetation index* (NDVI) viene citato (Bulcock & Jewitt, 2010) sia nell'ambito delle applicazioni satellitari (Berner et al., 2011) che nel campo dei SAPR (Gago et al., 2015); NDVI fu proposto da Rouse et al. (1974), e rappresenta matematicamente il rapporto normalizzato dei valori di riflettanza nel visibile (VIS) e nel vicino infrarosso (NIR) (Walter et al., 2015) in accordo con la generica equazione in seguito riportata (eq. 3):

$$NDVI = \frac{NIR - VIS}{NIR + VIS} \qquad eq.3$$

Il calcolo esatto di NDVI, con riferimento alle bande spettrali effettivamente impiegate, dipende dal sensore utilizzato e dagli obiettivi dello studio, tuttavia, nel campo del visibile (VIS) la riflettanza nel rosso (RED) è comunemente impiegata (Costa et al., 2020; Huete et al., 2002; Tucker, 1979) potendo quindi riscrivere:

$$NDVI = \frac{NIR - RED}{NIR + RED} \qquad eq.4$$

Oltre alla forma in eq. 4 che coinvolge ρ_{NIR} e ρ_{RED} spesso il calcolo prende in considerazione la riflettanza nel verde (GREEN) anziché nel rosso ottenendo la forma nota come *green normalized difference vegetation index* (GNDVI) (eq. 5) (Mulla, 2013); GNDVI viene citato per una maggiore sensibilità alla concentrazione di Chl_{a+b} ed assume valori compresi tra 0 e 1,0 (Candiago et al., 2015).

$$GNDVI = \frac{NIR - GREEN}{NIR + GREEN} \qquad eq.5$$

Si ritiene che i canali spettrali RED e NIR contengano più del 90% dell'informazione spettrale della vegetazione (Baret et al., 1989) e sono pertanto ubiquitari nell'ambito dei sistemi di RS (Giovos et al., 2021); NDVI trova correlazione con la concentrazione fogliare di Chl_{a+b} essendo che questi mostrano un massimo di riflettanza nel NIR, pertanto più alta è la concentrazione di Chl_{a+b} più la radiazione riflessa risulterà impoverita nel NIR ed arricchita nel RED facendo quindi tendere il rapporto delle riflettanze a valori più alti (McKellip et al., 2005); in particolare il calcolo dell'NDVI restituisce dei valori adimensionali che si collocano nel range compreso tra -1 e 1 (Meneses-Tovar, 2011). A titolo indicativo si può affermare che valori negativi sono tipici di corpi idrici mentre sono prossimi a zero per superfici prive di Chl_{a+b} (e.g. sabbia, superfici rocciose) infine sono positivi per le superfici dotate di Chl_{a+b} vegetali (Jones & Vaughan, 2010); in quest'ultimo caso il valore assunto da NDVI è definito

in dipendenza del contenuto di clorofilla della superficie vegetale (Pastor-Guzman et al., 2015): valori più prossimi a 1, secondo Daglio et al. (2022) indicativamente intorno 0,75, indicano la presenza di vegetazione sana mentre valori più bassi indicano la parziale perdita di clorofilla imputabile a fattori di stress di diverso genere (Hossain et al., 2010) (fig. 15).

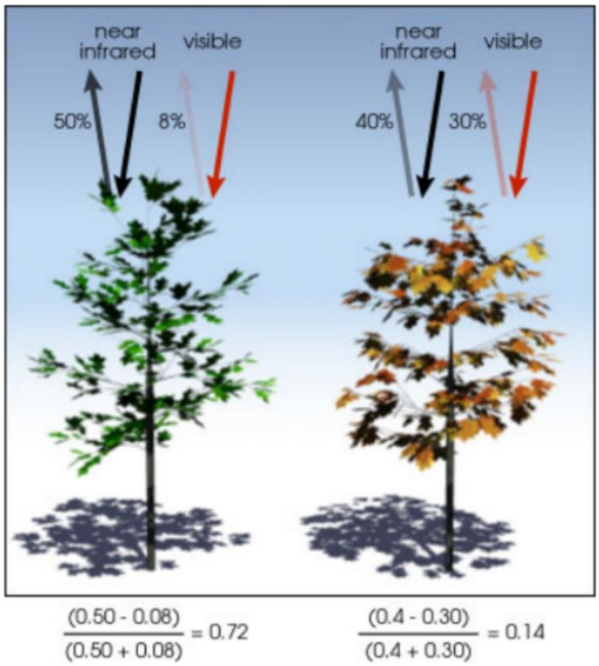

Fig. 15. Variazioni dei valori di NDVI in dipendenza di diverse condizioni fisiologiche dell'individuo vegetale: stato sanitario normale (sinistra), stato sanitario fortemente alterato (destra) (ESA – Eduspace EN – Global Change – Vegetation Indices (https://www.esa.int/SPECIALS/Eduspace_Global_IT/SEMXMWSWT1H_0.html).

La possibilità di discriminare superfici di natura diversa rende l'utilizzo di NDVI utile ad esempio per scopi di classificazione della copertura del suolo (Defries & Townshend, 2007) o di *vegetation masking* (Primicerio et al., 2015), inoltre la tendenza di tale VI a variare in funzione della concentrazione di Chl_{a+b} rende lo stesso NDVI in grado di correlarsi ad un ampio numero di parametri fisiologici e produttivi (Huang et al., 2021) essendo in effetti l'uso di NDVI citato ad esempio nella stima di LAI (Carlson & Ripley, 1997; Thenkabail et al., 2000), biomassa (Goswami et al., 2015), stadio fenologico (Hmimina et al., 2013), rese produttive (Kyratzis et al., 2015; Quarmby et al., 1993), entità di stress biotici (Sandmann et al., 2018), entità di stress abiotici (Cogato et al., 2019).

Occorre considerare che, quando questo VI viene valutato a livello di chioma, i valori di NDVI non identificano esclusivamente le caratteristiche compositive della superficie ma anche il movimento e l'angolazione delle foglie (Gitelson et al., 2014) nonché le variazioni

nell'organizzazione strutturale della chioma in grado di esporre il suolo (Daughtry et al., 2000).

2.6.4 Limiti all'utilizzo degli indici vegetativi

Nonostante i VI furono inizialmente stati proposti con il fine di estrarre il segnale spettrale puro delle strutture vegetali (Jackson & Huete, 1991), nelle condizioni reali diversi fattori si sono dimostrati capaci di alterare in modo complesso il comportamento degli stessi VI: geometria solare (Galvão et al., 2013; Middleton, 1991), angolo di osservazione (Galvão et al., 2009), condizioni atmosferiche (Hadjimitsis et al., 2010), architettura della chioma (Goel & Qin, 1994), caratteristiche della sensoristica (Teillet et al., 1997) sono alcune tra le condizioni in grado di influenzare, con effetti diversi, ciascun VI. Secondo Huang et al. (2021), l'effetto di tali condizioni è all'origine di variabilità dei dati ovvero, complementarmente, di una ridotta ripetibilità; non esistono cioè due immagini spettrali, che siano tra loro perfettamente sovrapponibili e questo per estensione è valido anche per i prodotti da esse derivati (e.g. mappe NDVI); pur confermando il grande potenziale che deriva dall'impiego dei VI, gli stessi autori sottolineano come il successo di tali strumenti sia vincolato a qualità dei dati spettrali e capacità di interpretazione degli stessi.

2.6.5 Indici vegetativi composti

Per ridurre l'effetto di variabili diverse da quella oggetto di studio con il fine ultimo di ottenere un miglioramento di accuratezza dei risultati ottenuti i diversi VI vengono talvolta considerati nelle loro possibili combinazioni (Eitel et al., 2008; Kerkech et al., 2018; Xu et al., 2019). Tale possibilità fu originariamente introdotta per ridurre l'influenza del LAI sulla determinazione del contenuto fogliare di clorofilla (Daughtry et al., 2000); successivamente, ulteriori casistiche hanno dimostrato la validità dell'utilizzo di VI composti, per esempio Mahlein et al. (2010) sono riusciti a differenziare tre differenti patologie della barbabietola utilizzando due o più indici in combinazione mentre l'indice composto TCARI/OSAVI è stato proposto per la capacità di migliorare la sensibilità alla concentrazione di Chl_{a+b}, riducendo significativamente l'effetto di fonti di disturbo (e.g. geometria solare, vigore vegetativo, effetti di riflessione del suolo), le quali invece condizionano maggiormente le prestazioni dello stesso TCARI se questo viene impiegato in forma non combinata con OSAVI, in maniera particolarmente evidente a basse concentrazioni di Chl_{a+b} (Haboudane et al., 2002).

2.7 APPLICAZIONI DEGLI INDICI VEGETATIVI

Inizialmente associato alla classificazione delle coperture del suolo, il significato pratico dei VI è evoluto con la possibilità di ottenere indicazioni qualitative ed entro certi limiti quantitative rispetto a definiti parametri di interesse (Giovos et al., 2021). Ad ogni modo lo sviluppo di nuovi indici spettrali è di norma previsto sulla base di specifiche necessità applicative (Xue & Su, 2017) e sul piano pratico è pertanto utile distinguere i diversi VI sulla base delle applicazioni per le quali gli stessi vengono proposti (IDB - Index DataBase). Secondo una *review* di Giovos et al. (2021) sull'impiego dei VI in viticoltura, le applicazioni di maggiore interesse riguardano tratti raggruppabili nelle seguenti 5 categorie: (i) pigmenti clorofilliani, (ii) altri pigmenti, (iii) parametri biofisici, (iv) biomassa, (v) stato idrico (tab. 2).

Nonostante l'alto potere esplicativo insieme a semplicità di calcolo, la facile reperibilità di dati spettrali e la lunga storia di utilizzo abbiano guidato una ampia diffusione di NDVI, questo non rappresenta l'unico VI a disposizione né una soluzione universalmente valida (Huang et al., 2021). Ad esempio, il *Modified Chlorophyll Absorption in Reflectance Index* (MCARI) prende in considerazione le componenti spettrali del verde fornendo informazioni anche sulla densità della chioma poiché la radiazione luminosa alle lunghezze d'onda del verde viene riflessa anche dagli strati più profondi della chioma stessa riuscendo a penetrare negli strati superiori (Walter et al., 2015). Il *Soil Adjusted VI* (SAVI) è impiegato per ottenere una compensazione degli effetti del suolo in quelle aree in cui la copertura vegetale è ridotta e la superficie del suolo è esposta; i valori assunti da SAVI sono compresi tra -1,0 e 1,0, e nel calcolo di questo VI è previsto il parametro L che può essere definito in funzione delle caratteristiche della copertura vegetale impiegando valori compresi tra -1,0 e 1,0, utilizzando valori bassi in condizioni di alta densità delle coperture vegetali (se L = 0 allora SAVI = NDVI) o valori crescenti per vegetazione sparsa (Huete, 1988). In condizioni standard si suppone L sia prossimo a 0,5 (Xue & Su, 2017); siccome il parametro L dovrebbe variare in modo inversamente proporzionale alla copertura vegetale, viene sostituito da una funzione variabile ricavando *modified SAVI* (MSAVI) e riducendo l'influenza del suolo nudo (Qi et al., 1994). Infine, secondo Zhang et al. (2015), i valori RDVI ed MSAVI sono significativamente ridotti dalla presenza di zone d'ombra e pertanto il loro utilizzo può essere proposto per identificare pixel affetti dalla presenza di ombre.

Tab. 2. Indici vegetativi; si noti che B = ρ_{blue} (430-500 nm); G = ρ_{green} (500-560 nm); R = ρ_{red} (620-670 nm); RE = $\rho_{red-edge}$ (670-720nm); NIR = ρ_{NIR} (720-1200nm); SWIR1 = ρ_{SWIR1} (1195-1225 nm); SWIR2 = ρ_{SWIR2} (1550-1590nm); una più estesa presentazione degli indici vegetativi utilizzati in viticoltura è stata proposta da Giovos et al. (2021).

ID	Indice	Formula	Indicazione	Fonte
1	CI_{green} (Cholophyll Index Green)	$(NIR/G) - 1$	Clorofilla	Jiménez-Brenes et al. (2019)
2	$Cl_{REDEDGE}$ (Chlorophyll Index Red Edge)	$(NIR/RE) - 1$	Clorofilla	Albetis et al. (2018)
3	CVI (Chlorophyll VI)	$NIR * (R/G^2)$	Clorofilla	Datt et al. (2003)
4	DVI (Difference VI)	NIR – R	Biomassa	Richardson & Everitt (1992)
5	EVI2 (Enhanced Vegetation Index2)	$2.5 * \frac{NIR - R}{(NIR + 2{,}4 * R + 1)}$	Biomassa	Potopová et al. (2020)
6	G/R (Green Index)	G/R	Pigmenti	Courel et al. (1991)
7	Gitleson cl1	$((1/G) - 1)/NIR) * NIR$	Clorofilla	Kandylakis et al. (2016)
8	Gitleson cl2	$((1/RE) - 1)/NIR) * NIR$	Clorofilla	Kandylakis et al. (2016)
9	GNDVI (Green NDVI)	(NIR – G)/(NIR + G)	Biomassa	Gitelson et al. (1996)
10	GRVI (Green-red VI)	(R – G)/(R + G)	Biomassa	Motohka et al. (2010)
11	MCARI (Modified Chlorophyll Absorption in Reflectance Index)	$((RE - R) - 0{,}2 * (RE - G)) * (RE/R)$	Clorofilla	Daughtry et al. (2000) Mulla (2013)
12	MCARI1	$1{,}2 * (2{,}5 * (NIR - R) - 1{,}3 * (NIR - G))$	Clorofilla	Haboudane et al. (2004)
13	MGRVI (Modified Green Red Vegetation Index)	$(G^2 - R^2)/(G^2 + R^2)$	Pigmenti	Pádua et al. (2018) Brunori et al., (2020)
14	MRVI (Modified Normalized Difference Vegetation Index)	$(R - 1)/(NIR - 1)$	Biomassa	Jiménez-Brenes et al. (2019)
15	MSAVI (Modified Soil Adjusted VI)	$\frac{2 * NIR + 1 - \sqrt{(2 * NIR + 1)^2 - 8 * (NIR - R)}}{2}$	Clorofilla	Qi et al. (1994) Mulla (2013)
16	MSR (Modified Simple Ratio)	$((NIR/R) - 1)/\sqrt{((NIR/R) + 1)}$	Biomassa Parametri biofisici	Baluja et al. (2012)
17	MTVI1 (Modified Triangular VI 1)	$1{,}2 * (1{,}2 * (NIR - G) - 2{,}5 * (R - G))$	Clorofilla	Rey-Caramés et al. (2015) Zarco-Tejada et al. (2010)
18	NDRE (Normalized Difference Red Edge Index)	$(NIR - RE)/(NIR + RE)$	Clorofilla	Romero et al. (2018)

Tab. 2. Continua

ID	Indice	Formula	Indicazione	Fonte
18	NDRE (Normalized Difference Red Edge Index)	$(NIR - RE)/(NIR + RE)$	Clorofilla	Romero et al. (2018)
19	NDVI (Normalized difference VI)	(NIR – R)/(NIR + R)	Biomassa	Rouse Jr et al. (1974) Mulla (2013)
20	NGRDI (Normalized difference green/red index)	$(G - R)/(G + R)$	Pigmenti	Jiménez-Brenes et al. (2019)
21	NIR – G	$NIR - G$	Parametri biofisici	Jiménez-Brenes et al. (2019)
22	NIR/G index	NIR/G	Parametri biofisici	Jiménez-Brenes et al. (2019)
23	NLI (Nonlinear vegetation index)	$(NIR^2 - R)/(NIR^2 + R)$	Biomassa	Jiménez-Brenes et al. (2019)
24	OSAVI (Optimal Soil Adjusted VI)	$(1 + 0{,}16) * ((NIR - R)/(NIR + R + 0.16))$	Clorofilla	Rondeaux et al. (1996) Sivanandam & Lucieer (2022)
25	PRSI (Plant Senescence Reflectance Index)	$(R - G)/RE$	Carotenoidi/ clorofilla	Merzlyak et al. (1999) Sivanandam & Lucieer (2022)
26	PVI (Perpendicular VI)	(NIR – aR – b)/$\sqrt{(a^2 + 1)}$	Biomassa	Hadizadeh et al. (2020)
27	R/G Simple ratio red/green	R/G	Pigmenti	Jiménez-Brenes et al. (2019)
28	RDVI (Renormalized Difference VI)	(NIR – R)/$\sqrt{(NIR + R)}$	Biomassa	Roujean & Breon (1995)
29	REGI (Red-edge Green Index)	$(RE - G)/(RE + G)$	Pigmenti Clorofilla	Albetis et al. (2018)
30	RERI (Red-edge Red Index)	$(RE - R)/(RE + R)$	Pigmenti Clorofilla	Albetis et al. (2018)
31	RVI (Ratio Vegetation Index)	R/NIR	Biomassa	Jiménez-Brenes et al. (2019)
32	SR (Simple Ratio)	NIR/R	Clorofilla	Birth & McVey (1968)
33	TCARI (Transformed chlorophyll absorption in reflectance)	$3 * (((RE - R) - 0{,}2 * (RE - G)) * (RE/R))$	Clorofilla	Haboudane et al. (2002)
34	TCARI/OSAVI	$TCARI/OSAVI$	Clorofilla	Haboudane et al. (2002)
35	TVI2 (Triangular VI 2)	$0{,}5 * (120 * (NIR - G) - 200 * (R - G))$	Bomassa Pigmenti	Brook et al. (2020) Zarco-Tejada et al. (2005)

Tab. 2. Continua

ID	Indice	Formula	Indicazione	Fonte
36	VIF	$NIR/(NIR+R)$	Biomassa	Giovos et al. (2021)
37	CIVE (Color Index of Vegetation)	$0{,}441*R-0{,}811*G+0{,}385*B+18{,}78745$	Pigmenti	Jiménez-Brenes et al. (2019)
38	ExB (Excess Blue)	$1{,}4*B-G$	Pigmenti	Jiménez-Brenes et al. (2019)
39	ExG (Excess Green)	(2*G – R – B)/(R + G + B)	Pigmenti	Woebbecke et al. (1995)
40	ExGR (Excess Green-Red)	ExG – ExR	Pigmenti	Meyer & Neto (2008)
41	ExR (Excess Red)	(1,4*R – G)/(R + G + B)	Pigmenti	Meyer et al. (1999)
42	NGBDI (Normalized green-blue difference index	$(G-B)/(G+B)$	Pigmenti	Pádua et al. (2018)
43	NPCI (Normalized Pigment Chlorophyll Index)	$(B-R)/(B+R)$	Pigmenti Clorofilla	Jiménez-Brenes et al. (2019) Zarco-Tejada et al. (2005)
44	NPCI2 (Normalized Pigment Chlorophyll Index 2)	$(R-B)/(R+B)$	Clorofilla	Giovos et al. (2021)
45	TGI (Triangular greenness index)	$G-0{,}39*R-0{,}61*B$	Pigmenti	Pádua et al. (2018)
46	ARI (Anthocyanin Content Index)	$G^{-1}-RE^{-1}$	Antociani	Gitelson et al. (2006)
47	GVMI (Global Vegetation Moisture Index)	$\frac{(NIR+1)-(SWIR+0{,}02)}{(NIR+1)+(SWIR+0{,}02)}$	Contenuto idrico	Giovos et al. (2021)
48	MSI (Moisture Stress Index)	$SWIR/NIR$	Contenuto idrico	Giovos et al. (2021)
49	NDWI (Normalized Difference Water Index)	$(NIR-SWIR2)/(NIR+SWIR2)$	Contenuto idrico	Giovos et al. (2021)
50	SIPI (Structure Insensitive Pigment Index)	$(NIR-B)/(NIR+R)$	Carotenoidi Carotenoidi/ clorofilla	Zarco-Tejada et al. (2005)
51	SIWSI (Shortwave Infrared Water Stress Index)	$(NIR-SWIR1)/(NIR+SWIR1)$	Contenuto idrico	Giovos et al. (2021)
52	SWIRR (Shortwave infrared ratio)	SWIR1/SWIR2	Contenuto idrico	Giovos et al. (2021)
53	VARI (Visible Atmospherically Resistant Index)	$(G-R)/(G+R-B)$	Pigmenti	Jiménez-Brenes et al. (2019)

In effetti molti VI sono oggi disponibili per la stima di diversi parametri di interesse (Mulla, 2013); nonostante ciò, secondo un recente lavoro di Giovos et al. (2021), rispetto all'utilizzo di VI in viticoltura solo alcuni di questi trovano un significativo impiego i.e. NDVI, GNDVI, MSR, SR, MSAVI ed RDVI.

Più in dettaglio, sempre in accordo con lo stesso lavoro di Giovos et al. (2021), la maggior parte dei VI si focalizza sul rilevamento di biomassa e densità di vegetazione con finalità di segmentazione dei filari e monitoraggio dell'area fogliare (e.g. NDVI, EVI, SAVI, MSAVI) altri vengono impiegati per la stima di concentrazione fogliare di Chl_{a+b} con il fine di rilevare stato di salute e stadio fenologico della vegetazione (e.g. CLREDEDGE, MCARI, MTVI1) oppure per la stima di altri pigmenti fogliari (e.g. PRI, ExB, ExG, ExR) principalmente con funzione di indicatore di stress biotici; infine una serie di VI che contengono informazioni nel NIR o SWIR sono stati proposti per la valutazione dello stato idrico delle piante (NDWI, SIWSI, GVMI, MSI).

2.7.1 Monitoraggio fattori di stress

La possibilità di identificazione di situazioni di stress tramite tecnologie di RS è messa in luce dal fatto che l'esposizione della pianta ad un generico fattore di stress si esplica normalmente con modificazioni biofisiche e biochimiche dei tessuti colpiti (e.g. alterazione dei fenomeni fotosintetici) (Balachandran et al., 1997; Hectors et al., 2007), determinando in ultima analisi una variazione delle proprietà ottiche della superficie vegetale (Al-Saddik et al., 2018; Calamita et al., 2021; di Gennaro et al., 2016).

Alcuni autori sottolineano tuttavia che con l'uso di tecniche di RS, la diagnosi nella maggior parte dei casi viene a basarsi sulla valutazione di quella che è la risposta della pianta allo stress, piuttosto che su una valutazione diretta del fattore di stress stesso (Jones & Vaughan, 2010); è comune, ad esempio, valutare lo stato di azoto-carenza sulla base del contenuto fogliare di Chl_{a+b} il cui decremento è indicazione tuttavia della risposta della pianta alla carenza nutrizionale, piuttosto che dello stress nutrizionale in sé (Baret & Buis, 2008; Ramoelo et al., 2015). Da ciò derivano difficoltà nella discriminazione di quei fattori di stress i quali, pur diversi, danno luogo a simili risposte della pianta interessata (Albetis et al., 2018; Cruz et al., 2019; Zhao et al., 2022). Per tale motivo, sebbene comunemente la valutazione dello stato della vegetazione avvenga attraverso un approccio empirico basato sulla correlazione tra indici vegetativi e parametri biofisici o biochimici (Ramoelo et al., 2015), secondo Hatfield et al. (2008) comprensione e conoscenza delle relazioni fisiologiche che si

esplicano a livello fogliare rimangono di fondamentale propedeuticità al fine di poter interpretare determinate variazioni spettrali.

Secondo Hunt and Daughtry (2017) si possono identificare tre problemi generali nel RS dei fattori di stress della vegetazione ovvero (1) accuratezza dell'identificazione, (2) capacità di monitoraggio, (3) automatizzazione dei processi di controllo.

2.7.2 Monitoraggio del mal dell'esca della vite

Tra le ampelopatie globalmente più diffuse ed economicamente impattanti il complesso del mal dell'esca della vite (ED) viene citato (fig. 16) (Dewasme et al., 2022; Guerin-Dubrana et al., 2019). Le diverse varietà di vite (*Vitis vinifera* L.) mostrano differenti livelli di suscettibilità ad ED tuttavia, stando alle conoscenze attuali, nessuna cultivar né specie appartenenti al genere *Vitis* mostra completa resistenza ad ED (Guan et al., 2016) il che è aggravato dall'assenza di efficaci possibilità curative di effettiva fruibilità (Bruez et al., 2021) e ad oggi, nonostante vengano proposte diverse soluzioni di prevenzione (Roblin et al., 2019), una delle strategie più efficaci è rappresentata dal continuo monitoraggio dello stato sanitario del vigneto con il fine di limitare la diffusione dei patogeni associati ad ED (Mondello et al., 2018) la quale avviene attraverso la dispersione di spore tramite sia pioggia che vento (Fontaine et al., 2016).

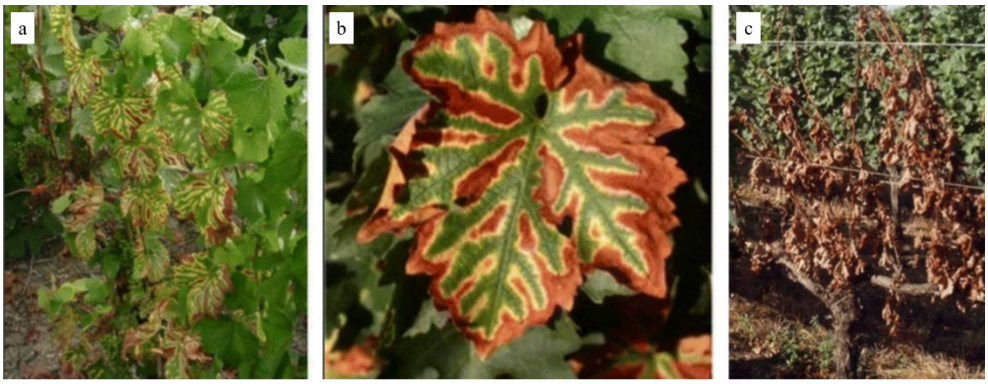

Fig. 16. Alcune sintomatologie caratteristiche del mal dell'esca della vite su vitigno a bacca bianca; aspetto della chioma di pianta gravemente affetta da ED (a), dettaglio delle tigrature fogliari (b), manifestazione apoplettica (c) (Fontaine et al., 2016).

Nonostante ciò, una valutazione quantitativa ripetuta della presenza di focolai non è normalmente svolta, anche considerato la ridotta efficacia delle tradizionali attività di monitoraggio in quanto, basandosi queste su valutazioni visive, si svantaggiano di soggettività e forte dispendio di tempo (Al-Saddik et al., 2019; Psirofonia et al., 2017) portando peraltro

normalmente a sottostimare l'incidenza di ED data la pronunciata variabilità temporale che caratterizza il periodo di latenza durante il quale non è possibile l'identificazione visiva delle stesse (Sosnowski et al., 2011). Al contrario, le tecniche di RS si propongono con la potenzialità di individuare in modo rapido la precisa posizione delle piante sintomatiche (Albetis et al., 2017; Al-Saddik et al., 2019; Daglio et al., 2022) e, potendo investigare regioni dello spettro elettromagnetico non visibili all'occhio umano, aprire alla possibilità di una identificazione anche precoce delle patologie vegetali, rendendo l'intervento in campo più rapido nonché maggiormente efficace (di Gennaro et al., 2016).

Con ED, ci si riferisce ad un complesso di patologie causate da un ampio numero di specie fungine a sviluppo xilematico (Mugnai et al., 1999). I sintomi fogliari tipici dell'interazione (e.g. punti clorotici internervali, tigrature fogliari) (fig. 16b) sono associati a chiusura stomatica, alterazione dell'apparato fotosintetico e attività fitotossica degli agenti di malattia (Fontaine et al., 2016); lenta ripresa vegetativa e scarso vigore possono essere associati al ridotto accumulo di riserve di carboidrati rilevabile durante il periodo invernale a livello degli organi permanenti di piante sintomatiche (Petit et al., 2006). Le condizioni climatiche dell'ambiente di coltivazione sono in grado di influenzare in modo significativo l'espressione dei sintomi, ed in particolare le precipitazioni di inizio estate sembrano accompagnare una più evidente apparenza degli stessi (Calzarano et al., 2018). La manifestazione della forma apoplettica, individuata dal parziale o totale disseccamento della chioma (fig. 16c), sembra essere invece legata a disfunzioni del sistema xilematico che vengono ad evidenziarsi con tale sintomatologia specie in condizioni di buona disponibilità idrica accompagnate da temperature stagionali elevate in grado di indurre un forte disequilibrio tra traspirazione ed assorbimento idrico (Surico et al., 2006).

A livello spettrale le principali alterazioni che interessano gli organi fogliari sintomatici sono evidenziabili nel NIR, in conseguenza della disorganizzazione cellulare accompagnata dall'accumulo di tossine di origine fungina, oltre che *range* del VIS (fig. 17) come risultato di un decremento nella concentrazione di Chl_{a+b}, con particolare riferimento alla clorofilla b (Junges et al., 2018) ad accompagnare un incremento del rapporto clorofilla a/b (Santos et al., 2005). Al contrario, la concentrazione di carotenoidi tende a rimanere stabile (Petit et al., 2006), il rapporto carotenoidi/clorofilla tende così ad aumentare significativamente in piante affette da ED (García et al., 2022) in modo analogo a quanto si verifica con l'avvio dei processi di senescenza fogliare (Anderegg et al., 2020; Merzlyak et al., 1999). Secondo Junges et al. (2018), le variazioni relative dei valori di ρ_{NIR} tipico di piante affette da ED, in

fasi prossime alla chiusura del ciclo vegetativo, non risulta chiaramente distinguibile da quello tipico di organi fogliari in fase di senescenza.

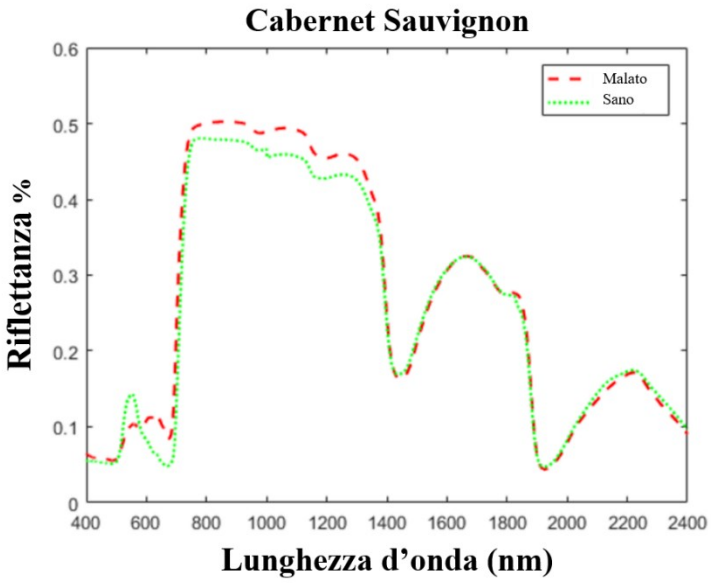

Fig. 17. Comportamento spettrale medio di un gruppo di foglie asintomatiche (curva verde) e con sintomi di ED (curva rossa) del vitigno a bacca nera Cabernet Sauvignon (rielaborato da Al-Saddik et al., 2018).

Secondo alcuni autori già in fasi pre-sintomatiche, gli organi interessati possono evidenziare accumulo epidermico di polifenoli (di Gennaro et al., 2016), ma anche alterazioni delle funzionalità fotosintetiche ed in generale espressione di geni di difesa per poi amplificare queste risposte durante la fase di espressione dei sintomi (Magnin-Robert et al., 2011); L'identificazione precoce sembra dunque essere possibile e, a livello fogliare, l'analisi dello spettro elettromagnetico nelle zone più sensibili alla concentrazione di Chl_{a+b} i.e. *green* (520-550 nm) e *red edge* (intorno a 700 nm) evidenziano nelle prime fasi dell'interazione pianta-patogeno un comportamento spettrale distinguibile da quello normale, tipico della vegetazione sana (Junges et al., 2018). Di Gennaro et al. (2016), impiegando SAPR, hanno estratto NDVI, da immagini multispettrali, per evidenziare le differenze spettrali tra piante sane e piante asintomatiche riuscendo a prevedere la comparsa dei sintomi con 2-3 settimane di anticipo rispetto alla manifestazione visiva dei sintomi, confermando il potenziale di identificazione precoce di alterazioni a carico dell'apparato fotosintetico, pur sottolineando i limiti dell'approccio impiegato, essenzialmente legati all'incapacità di discriminazione rispetto a cause di stress in grado di provocare simili modificazioni. Simili difficoltà emergono dal lavoro di Albetis et al. (2018) nel quale, sempre rispetto all'analisi di immagini multispettrali da SAPR, se effettivamente alcuni VI, i.e. RGI, GVRI, CI e NDRE, hanno

fornito promettenti risultati nei termini di una identificazione delle piante malate, seppur con una tendenza a dimostrare maggiore efficacia per livelli di infezione superiori al 50%, gli esiti sono stati al contrario non soddisfacenti quando all'attenzione si è posta la possibilità di discriminare due avversità, i.e. ED e flavescenza dorata le quali, pur di natura diversa, conducono a simili variazioni dei pigmenti fogliari. Difficoltà di discriminazione sono state evidenziate anche relativamente all'uso di VI clorofilla e struttura dipendenti in situazioni di basso vigore vegetativo (Daglio et al., 2022).

Tali considerazioni condurrebbero, ai fini di una applicazione pratica, alla necessità che le informazioni ottenute dai sistemi di identificazione vengano ad essere completate da un sopralluogo tecnico per confermare gli interventi necessari riducendo tuttavia l'efficienza del monitoraggio (Bendel et al., 2020).

Una prima possibilità, esplorata da Kerkech et al. (2018) per evitare la confusione dovuta alla presenza di vegetazione affetta da stress di natura diversa, è stata quello di combinare l'informazione spettrale di vari VI estratti da immagini RGB ottenute da SAPR con tecniche di deep learning per classificare i pixel, anziché in modo binario (sano/malato), in quattro classi vegetative i.e. (i) suolo, (ii) vegetazione sana, (iii) vegetazione potenzialmente affetta da ED, (iv) vegetazione affetta da ED; segregando i possibili fattori di confusione in una classe a sé stante, Kerkech et al. (2018) hanno raggiunto, combinando l'informazione degli VI ExG, ExR, ExGR, una accuratezza del 95,8 % nella classe "vegetazione affetta da ED" (fig. 18).

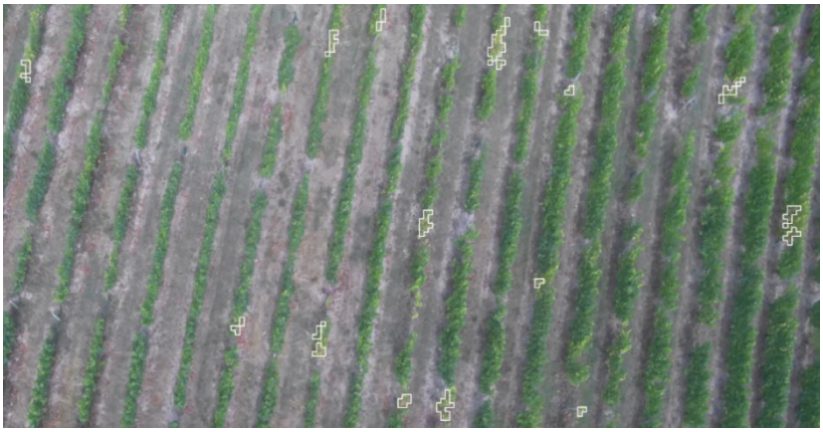

Fig. 18. Mappa di identificazione di ED generata tramite processi di classificazione; le delimitazioni bianche identificano zone vegetative affette da ED (Kerkech et al., 2018).

Infine, l'uso di tecnologie iperspettrali viene spesso proposto come possibilità per caratterizzare il comportamento spettrale della vegetazione individuando specifici tratti spettrali in grado di identificare in modo pressoché univoco il fattore di stress oggetto di analisi (di Gennaro et al., 2016). La fattibilità di tale approccio è già stata dimostrata, e ad esempio Mahlein et al. (2010) hanno evidenziato differenze spettrali tali da rendere possibile la discriminazione di tre malattie fungine attraverso la combinazione di due o più indici vegetativi; i risultati ottenuti a livello fogliare con tecnologie di HSI da diversi autori sembrano confermare come anche l'interazione dei patogeni di ED con l'ospite vegetale vada a generare delle firme spettrali chiaramente distinguibili da quelle di individui sani, sia nel VNIR che nello SWIR (Al-Saddik et al., 2018; Bendel et al., 2020; Junges et al., 2018). Sulla base di simili considerazioni, alcuni autori hanno considerato le tecnologie HS con il fine di identificare specifiche lunghezze d'onda che risultino sufficientemente sensibili all'attività dei patogeni associati a ED, da consentire l'identificazione di aree affette (Bendel et al., 2020; Junges et al., 2020; Pérez-Roncal et al., 2022).

In particolare, dai lavori di Bendel et al. (2020) emerge che a livello prossimale l'identificazione iperspettrale, anche precoce, sembra possibile mantenendo livelli di accuratezza sufficienti particolarmente nello SWIR, sebbene con dei limiti alla possibilità di trasferire spazialmente e temporalmente le relazioni ottenute; risultati relativamente più stabili sembrano ottenibili nel VNIR.

Sempre secondo gli stessi autori, oltre a garantire una migliore efficienza computazionale e di elaborazione, la selezione di bande spettrali significative da utilizzare con un approccio multispettrale, sembra essere una strategia utile per migliorare le prestazioni della classificazione in sostituzione all'impiego dell'intera regione iperspettrale. Nonostante ciò, l'accuratezza di classificazione diminuisce significativamente quando l'analisi viene proposta a livello aereo tanto maggiormente quanto meno evidente è la manifestazione dei sintomi, con la necessità, in questo caso, di impostare delle strategie per migliorare la stessa classificazione, ad esempio impiegando immagini da SAPR ottenute ad angolazioni minori così da catturare lateralmente la chioma nei sistemi in parete o, come proposto da Albetis et al. (2018) agendo sulla quota di volo per incrementare la risoluzione spettrale delle immagini.

2.7.3 *Monitoraggio dello stress idrico*

Un indicatore sistematicamente considerato nella valutazione dello stato idrico della pianta è il potenziale idrico (Ψ) misurato con camere a pressione (Girona et al., 2006) tuttavia,

nonostante questa modalità consenta di ottenere risultati di grande accuratezza (Scholander et al., 1964), l'applicabilità su vaste aree e con alta frequenza temporale risulta limitata dalla laboriosità connessa a tale modalità operativa, pertanto, per rispondere alle esigenze di rapidità e tempestività, l'impiego di sistemi di RS viene investigato (Ihuoma & Madramootoo, 2017).

Nelle piante di vite (*Vitis vinifera* L.), considerate sensibili allo stress idrico, un deficit idrico può già nel breve periodo influire sulla fisiologia della pianta stessa inducendo nelle fasi precoci dello stress una diminuzione della conduttanza stomatica e quindi un aumento della temperatura fogliare (Matese et al., 2018). Contestualmente, l'aumento stesso della resistenza stomatica determina un decremento della concentrazione sottostomatica di CO_2 (Flexas et al., 2002) e, dato il ridotto tasso di assimilazione di CO_2, la EMR assorbita dalla foglia, non potendo essere impiegata nelle reazioni fotochimiche di produzione dell'energia viene, al fine di ottenere una dissipazione dell'energia radiante in eccesso e quindi proteggere l'apparato fotosintetico da danni fotossidativi, deviata ad altri processi tra cui si citano emissione per fluorescenza (Demmig-Adams et al., 1996) e ciclo delle xantofille (Eskling et al., 1997). In quest'ultimo caso in particolare, viene innescata la conversione di violaxantina ad anteraxantina e zeaxantina, tramite processi di de-epossidazione, quindi lo stato dei carotenoidi può essere correlato alle riduzioni dell'efficienza fotosintetica che si verificano contestualmente alle condizioni di eccesso luminoso, inoltre queste reazioni sono facilmente reversibili quindi i cambiamenti sono osservabili su scala giornaliera (Demmig-Adams et al., 1996).

In considerazione del fatto che la presenza di forme de-epossidate (fotoprotettive) è responsabile del decremento dei valori di riflettanza intorno a 531 - 538 nm (fig. 19a), Gamon et al., (1992) hanno sviluppato il *photochemical reflectance index* (*PRI*), un VI a banda stretta, sensibile allo stato di de-epossidazione dei pigmenti dei pigmenti carotenoidi e quindi all'efficienza del processo di fotosintesi; essendo parte della radiazione luminosa in eccesso dissipata con il ciclo delle xantofille in situazioni di stress idrico. Suárez et al., (2008) hanno estratto *PRI* da immagini ottenute con SAPR dimostrando la sensibilità dello stesso VI alle variazioni giornaliere di parametri fisiologici correlati allo stato idrico della pianta, tra cui conduttanza stomatica (g_s), potenziale idrico (Ψ) e differenza di temperatura tra chioma e aria (Tc–Ta).

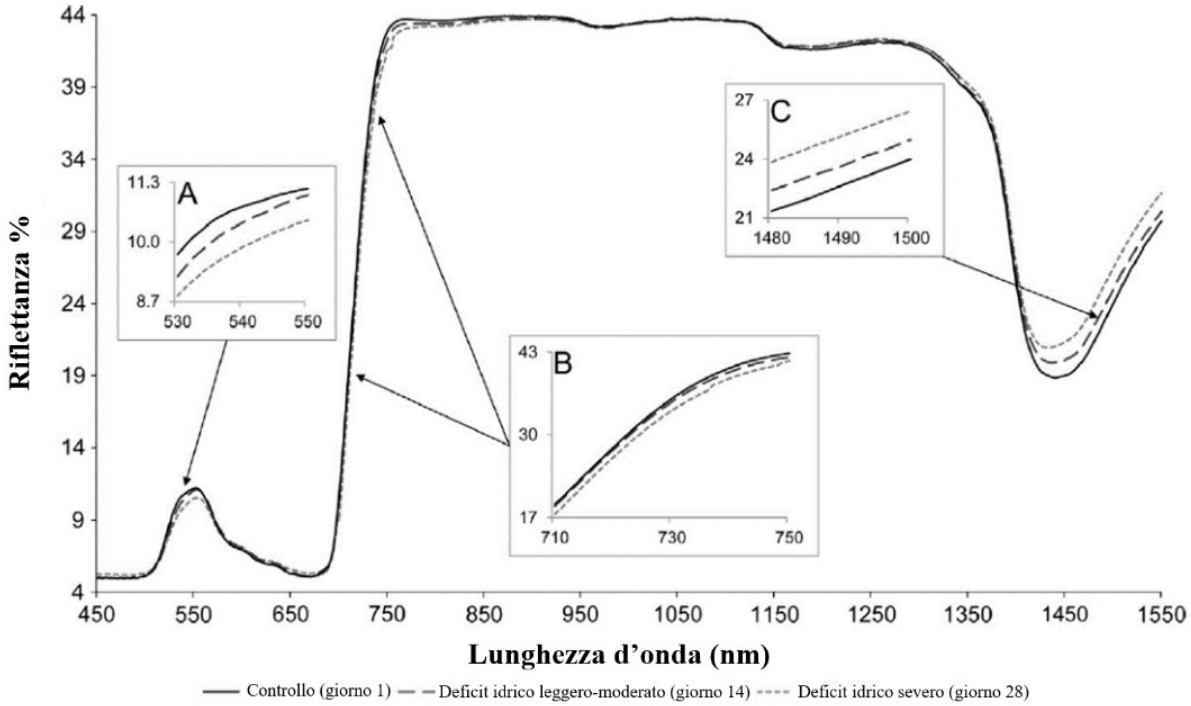

Fig. 19. Variazioni spettrali associate a diversi livelli di stress idrico (rielaborato da Rapaport et al., 2015).

Tra gli altri cambiamenti fisiologici indotti da situazioni di carenza idrica, la retroregolazione dei processi di fotosintesi porta a riduzioni nella concentrazione di pigmenti fotosintetici (Chaves et al., 2002); in conseguenza a questi effetti, nonostante l'acqua non mostri caratteristiche di assorbimento nel VIS, anche in questa regione spettrale gli effetti dello stress idrico sono evidenziabili (fig. 19a, 19b) e molti VI basati sulla riflettanza nel VIS e RE sono citati per la capacità di evidenziare situazioni di carenza idrica a livello di chioma (Pôças et al., 2015); nel NIR, i valori di riflettanza influenzati in particolar modo da proprietà strutturali degli organi vegetali, la massima risposta di VI contenenti questa informazione spettrale viene rilevata per quelle varietà o specie che tendono più facilmente a manifestare perdita di elasticità della parete cellulare in risposta alla condizione di deficienza idrica ed in genere quando lo stress è già ben sviluppato (Penuelas et al., 1993).

In generale, spesso si riportano delle buone correlazioni tra un particolare VI e lo stato idrico della vegetazione perdendo tuttavia la potenzialità predittiva dello stesso VI quando questo viene applicato a comunità vegetali diverse o a diversi siti di studio (Bowyer & Danson, 2004). Ad esempio, nei lavori di Baluja et al. (2012) la correlazione di TCARI/OSAVI con il parametro potenziale stem (Ψ_{stem}) ha evidenziato un R^2 di 0,58 per la cultivar Tempranillo, mentre in altre condizioni l'R^2 è sceso fino a 0,01 per Thompson Seedless (Zarco-Tejada et al., 2013) (tab. 3).

Tab. 3. Comparazione dei risultati ottenuti in alcuni lavori volti alla valutazione della correlazione di diversi VI con Ψ_{stem} (MPa).

Indice	R^2	Sensore	Scala	Fonte	Cultivar
GI	0,54	MS	Aereo	Baluja et al. (2012)	*Vitis vinifera* L. cv tempranillo
	0,44	HS	Prossimale	Cogato et al. (2022)	*Vitis vinifera* L. cv grenache
GNDVI	0,58	MS	Aereo	Baluja et al. (2012)	*Vitis vinifera* L. cv tempranillo
	0,33	HS	Prossimale	Cogato et al. (2022)	*Vitis vinifera* L. cv shiraz
MCARI	0,01	MS	Aereo	Baluja et al. (2012)	*Vitis vinifera* L. cv tempranillo
MCARI1	0,21	MS	Aereo	Baluja et al. (2012)	*Vitis vinifera* L. cv tempranillo
MCARI2	<0,01	MS	Aereo	Baluja et al. (2012)	*Vitis vinifera* L. cv tempranillo
MSAVI	0,11	MS	Aereo	Baluja et al. (2012)	*Vitis vinifera* L. cv tempranillo
MSI	0,31	HS	Prossimale	Rapaport et al. (2015)	*Vitis vinifera* L. cv cabernet sauvignon
MSR	0,66	MS	Aereo	Baluja et al. (2012)	*Vitis vinifera* L. cv tempranillo
MTVI3	0,01	MS	Aereo	Baluja et al. (2012)	*Vitis vinifera* L. cv tempranillo
NDVI	0,68	MS	Aereo	Baluja et al. (2012)	*Vitis vinifera* L. cv tempranillo
	0,57	HS	Prossimale	Serrano et al. (2010)	*Vitis vinifera* L. cv chardonnay
	0,03	HS	Prossimale	Rapaport et al. (2015)	*Vitis vinifera* L. cv cabernet sauvignon
TCARI/OSAVI	0,58	MS	Aereo	Baluja et al. (2012)	*Vitis vinifera* L. cv tempranillo
	0,01	MS	Aereo	Zarco-Tejada et al. (2013)	*Vitis vinifera* L. cv thompson seedless
SRI	0,64	MS	Aereo	Baluja et al. (2012)	*Vitis vinifera* L. cv tempranillo
PRI	0,25	MS	Aereo	Baluja et al. (2012)	*Vitis vinifera* L. cv tempranillo
	0,53	MS	Aereo	Zarco-Tejada et al. (2013)	*Vitis vinifera* L. cv thompson seedless
	0,19	HS	Prossimale	Rapaport et al. (2015)	*Vitis vinifera* L. cv cabernet sauvignon
	0,45	HS	Prossimale	Cogato et al. (2022)	*Vitis vinifera* L. cv grenache
	0,69	HS	Prossimale		*Vitis vinifera* L. cv shiraz
RDVI	0,10	MS	Aereo	Baluja et al. (2012)	*Vitis vinifera* L. cv tempranillo
	0,49	MS	Aereo	Zarco-Tejada et al. (2013)	*Vitis vinifera* L. cv thompson seedless

Similmente, López-García et al. (2021) impiegando SAPR hanno investigato la potenzialità di diversi VI RBG e multispettrali per il monitoraggio dello stato idrico di vigneti evidenziando tuttavia dei limiti alla ripetibilità dei risultati nelle diverse annate con la necessità di definire, per ciascuna stagione, tramite accoppiamento di misurazioni a terra, il modello più adatto. Infine, Baluja et al. (2012) hanno evidenziato una buona correlazione di NDVI con i valori di potenziale stem (Ψ_{stem}) e conduttanza stomatica (g_s) in piante di vite, mentre una scarsa correlazione è stata evidenziata per gli stessi VI da Zarco-Tejada et al. (2012) per piante di limone.

Secondo alcuni autori la difficoltà nel replicare i risultati ottenuti potrebbe in alcuni casi dipendere da dinamiche fisiologiche distintive delle diverse comunità vegetali (Ihuoma & Madramootoo, 2017), ma anche dalla possibilità che la risposta di uno specifico VI o di un gruppo di VI, correlati solo indirettamente allo stato idrico della pianta, possa variare in funzione di diversi livelli dello stesso stress (Poblete et al., 2017). In particolare secondo

Suárez et al. (2008) le prestazioni di VI clorofilla dipendenti e VI strutturali (e.g. NDVI, TCARI/OSAVI), essendo sostanzialmente vincolate ad effetti di disorganizzazione strutturale e di riduzione di Chl_{a+b}, potrebbero risultare non idonei alla segnalazione di variazioni dello stato idrico nel breve periodo, quando queste variazioni compositive e strutturali sono poco evidenti, meglio adattandosi all'indicazione di stress idrici prolungati, condizioni per cui l'effetto di questi stessi fenomeni si manifesta più nettamente. Occorre poi tenere in considerazione che alcuni VI (e.g. NDVI) sono soggetti ad effetti di saturazione in condizioni di alta densità della vegetazione, il che potrebbe ulteriormente ridurne la sensibilità alle variazioni dello stato idrico della vegetazione specie nelle fasi iniziali dello stress, nonché per livelli ancora relativamente alti di Chl_{a+b} (Romero et al., 2018). In conclusione, come evidenziato da Romero et al. (2018), diversi VI contenenti informazioni spettrali nel RED e nel NIR (i.e. GI, RDVI, OSAVI, MSAVI e DVI) mostrano prestazioni migliori quando lo stress idrico è avanzato potendo pertanto supporre un ruolo di tali regioni spettrali nel monitoraggio dello stato idrico della vegetazione tuttavia limitato a situazioni di stress idrico cumulati.

Si ritiene invece che le variazioni riscontrabili nel breve periodo debbano essere ricercate piuttosto nei cambiamenti che si verificano nelle fasi iniziali dello stress, tra cui l'aumento della temperatura fogliare, e l'analisi di immagini termiche (Baluja et al., 2012) o, rimanendo nel dominio ottico dello spettro elettromagnetico, la valutazione dello stato di de-epossidazione dei pigmenti carotenoidi, di cui *PRI* viene citato come un indicatore dinamico e reattivo, in grado di consentire una valutazione delle variazioni giornaliere dello stato idrico della vegetazione (Rossini et al., 2013; Wong et al., 2022). In quest'ultimo caso alcuni autori sottolineano che le prestazioni possono essere limitate da variazioni di tipo stagionale a carico dei carotenoidi, che potrebbero sovrapporsi, specie in certe fasi fenologiche, agli effetti di variazione dovuti allo stress idrico con la necessità in taluni casi di isolare le risposte giornalieri dai fenomeni stagionali, al fine di migliorare l'accuratezza dell'analisi (Hmimina et al., 2015). Infine, secondo Cogato et al. (2022) sembra appropriato ragionare nei termini di una integrazione delle informazioni ricavate da diversi VI con l'obiettivo di catturare l'intera risposta fisiologica della pianta allo stress idrico ritenendo che la combinazione di VI contenenti bande nel verde, NIR e rosso sia la più appropriata per tale scopo.

In generale, tuttavia, correlandosi solo indirettamente allo stato idrico della vegetazione alcuni autori ritengono che per condizioni variabili, l'utilizzo di informazioni spettrali nel VIS per la stima di Ψ non sia in grado di fornire dei risultati ripetibili conducendo spesso a esiti

contrastanti (Poblete et al., 2017), al contrario i VI che combinano le informazioni di NIR e SWIR sembrano fornire delle relazioni più stabili (Rallo et al., 2014; Rapaport et al., 2015). Contrariamente alle lunghezze d'onda del VIS, nelle regioni di NIR e SWIR l'acqua mostra delle evidenti caratteristiche di assorbimento (Giovos et al., 2021; Jacquemoud et al., 2000) in tre regioni di lunghezze d'onda (i.e. 950–970, 1150–1260 e 1520–1540 nm) (fig. 19c) (Sims & Gamon, 2003), pertanto molti indici che includono informazioni spettrali in questa regione dello spettro elettromagnetico sono stati sviluppati per il monitoraggio dello stato idrico della vegetazione (Dawson et al., 2010; Giovos et al., 2021; Sims & Gamon, 2003), con particolare riferimento alle regioni 1150-1260 e 1520-1540 nm, dove l'assorbimento del vapor d'acqua atmosferico è minimo (Sims & Gamon, 2003). Nonostante ciò, più comunemente viene sperimentato l'utilizzo di VI che includono informazioni spettrali nel VNIR essendo ad oggi il costo dei sensori SWIR almeno 5 volte maggiore rispetto a quello dei sensori VNIR (Mishra et al., 2020).

Alcuni autori sottolineano infine come talvolta il ridotto potere esplicativo dei convenzionali indici multispettrali calcolati nel VNIR possa dipendere dai limiti degli approcci statistici tradizionali normalmente volti alla valutazione di sole relazioni lineari (Poblete et al., 2017). Tecniche di AI possono essere proposte per ottenere un miglioramento del potenziale predittivo grazie alla capacità di modellizzazione di relazioni lineari e non lineari (Hsu et al., 1995; Riad et al., 2004); sulla base di tali considerazioni l'impiego di tecniche di AI è spesso valutato nell'applicazione delle tecniche di RS al monitoraggio dello stato idrico della vegetazione mostrando risultati promettenti. Ad esempio, King & Shellie (2016) modellizzando le informazioni termiche tramite tecniche di *machine learning* hanno ottenuto R^2 compresi tra 0,89 e 0,93 in diverse cultivar. Romero et al. (2018) hanno utilizzato diversi VI multispettrali come dati di apprendimento ottenendo alte correlazioni tra Ψ_{stem} stimati con sistemi di *machine learning* e Ψ_{stem} effettivamente misurati (R = 0,83), mentre gli stessi VI valutati singolarmente attraverso relazioni lineari hanno mostrato nella maggior parte dei casi R^2 non maggiori di 0,25. Similmente, Poblete et al. (2017) tramite modelli di reti neurali artificiali che utilizzano le informazioni spettrali tra 550 e 800 nm, hanno migliorato la previsione di Ψ_{stem} (R^2 = 0,87) confermando il potenziale di questo approccio nella valorizzazione dell'informazione spettrale disponibile nel VNIR.

3 SCOPO DEL LAVORO

Il presente lavoro è stato previsto con l'obiettivo di valutare la fattibilità di impiego di VI multispettrali ed RGB nella descrizione della variabilità intra-parcellare associata alla presenza di fattori di stress, i.e. stress idrico e mal dell'esca della vite.

Per quanto concerne gli aspetti relativi al monitoraggio dello stato idrico della vegetazione la possibilità di correlare VI selezionati a parametri misurabili indicativi dello stato idrico della vegetazione, i.e. potenziale idrico *stem* (Ψ_{stem}), potenziale idrico fogliare (Ψ_{leaf}) e potenziale idrico *pre-dawn* (Ψ_{pd}) è stata valutata; è stata inoltre indagata la possibilità di discriminazione di diversi livelli di intensità dello stress idrico nell'ambito di tre tesi i.e. controllo irrigato (WW), stress moderato (MS), stress severo (SS).

Infine, l'analisi delle *performance* di diversi VI, è stata prevista con lo scopo di esaminare la possibile identificazione di valori soglia in grado di consentire la discriminazione di aree vegetative interessate dall'azione di patogeni associati a mal dell'esca della vite, rispetto ad aree vegetative caratterizzate da un comportamento fisiologico normale.

4 MATERIALI E METODI

4.1 Acquisizione dei dati

4.1.1 Siti sperimentali

Il presente lavoro ha previsto la raccolta di dati di campo, immagini MS ed RGB di due vigneti in produzione, localizzati rispettivamente nei comuni di Precenicco (sito A) e Udine (sito B) (Friuli-Venezia Giulia, Italia nord-orientale) (fig. 20).

L'area di studio riferita al sito A (fig. 20A) è stata individuata, nell'ambito di un vigneto commerciale con un sesto d'impianto di 1,0 m x 3,0 m; le piante di vite (*Vitis vinifera* L. cv. Glera), sono allevate a *Sylvoz*. Il sito sperimentale ha interessato una parcella di circa 0,5 ha, a comprendere 1520 piante distribuite su 10 filari. Il sito è stato oggetto sia di valutazioni relative allo stato idrico che di mappatura delle piante affette da ED.

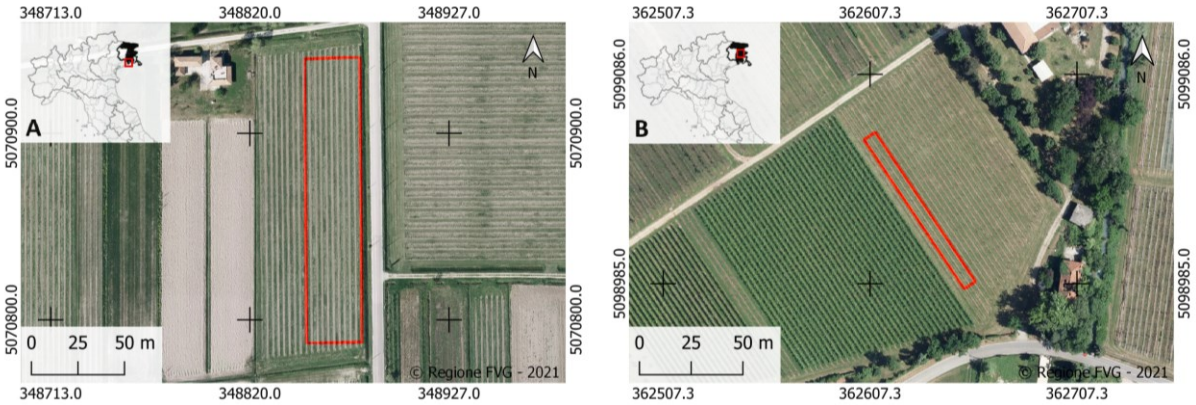

Fig. 20. Localizzazione delle parcelle selezionate presso i comuni di Precenicco (A) e Udine (B); le perimetrazioni in rosso indicano le aree interessate dalle valutazioni sperimentali; le mappe sono state restituite con il sistema di coordinate RDN2008 / UTM zone 33 (N-E).

Il sito B (fig. 20B) è stato individuato nell'ambito di un vigneto sperimentale dell'azienda agraria "A. Servadei" dell'Università degli Studi di Udine; tale vigneto ha un sesto d'impianto di 1,0 m x 2,5 m; l'area di studio ha interessato 3 filari contigui, per ciascun filare è stata prevista l'applicazione di uno specifico regime idrico con il fine di mantenere i valori medi di potenziale idrico pre-alba (Ψ_{pd}) entro *range* definiti; ciò ha reso possibile il confronto di 3 tesi (fig. 21):

(i) controllo irrigato (WW), Ψ_{pd} = -0,2 MPa (da germogliamento a raccolta)

(ii) stress moderato (MS), Ψ_{pd} = -0,35 MPa (da fioritura a raccolta)

(iii) stress severo (SS), Ψ_{pd} = -0,55 MPa (da fioritura a raccolta)

I valori di Ψ_{pd} caratterizzanti le tre tesi si intendono come media dei valori misurati durante il periodo compreso tra le fasi fenologiche di germogliamento e maturazione; per ciascuna tesi sono state individuate 4 repliche costituite da 10 piante ciascuna.

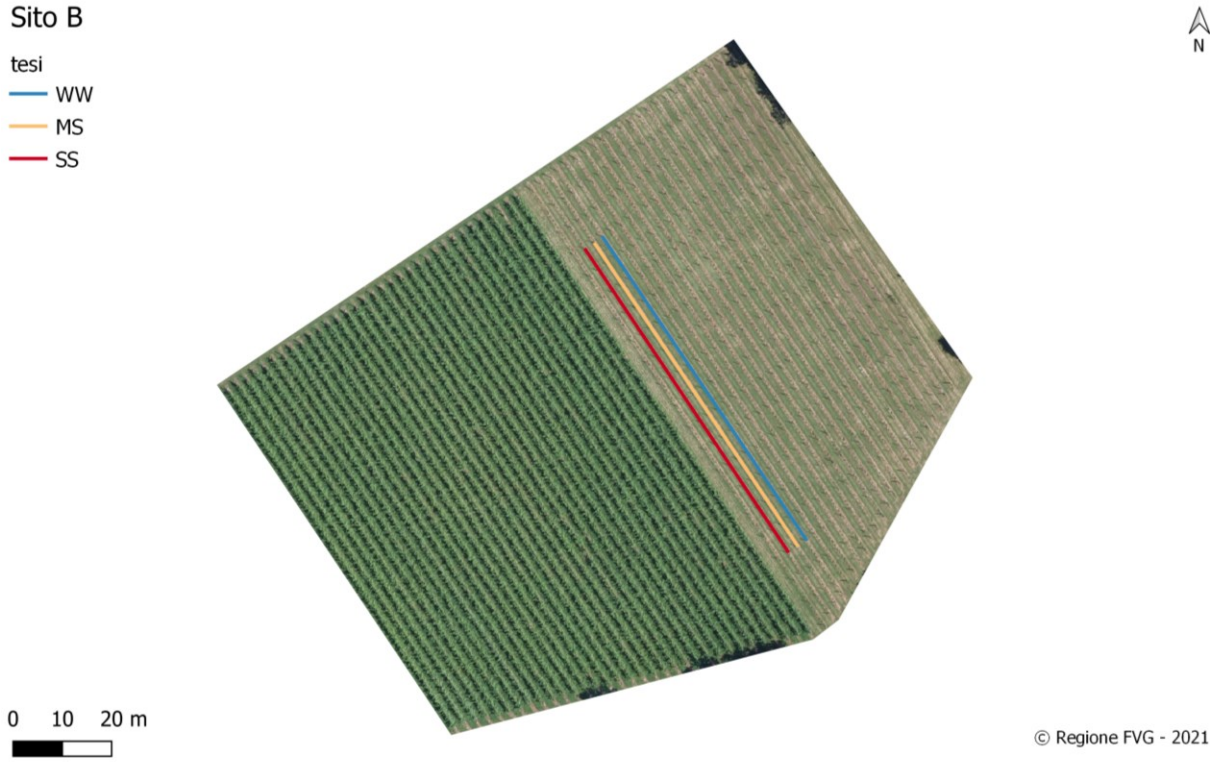

Fig. 21. Tesi confrontate nell'ambito delle prove sperimentali previste per il sito B.

Le piante di vite (*Vitis vinifera* L. cv. Pinot Grigio), sono allevate a *Guyot*. Il sito è stato oggetto di sole valutazioni relative allo stato idrico; in considerazione della presenza non significativa di piante sintomatiche, la mappatura di piante affette da ED non è stata prevista per questo sito di studio.

4.1.2 Acquisizione dei dati di campo

Le misurazioni relative a potenziale idrico del fusto (Ψ_{stem}), potenziale idrico fogliare (Ψ_{leaf}) e potenziale idrico pre-alba (Ψ_{pd}), sono state effettuate con l'ausilio di una camera di Scholander (Soil Moisture Corp., Santa Barbara, USA), seguendo la modalità operativa descritta da Scholander et al. (1964); le misure di potenziale idrico sono state effettuate nelle giornate del 29/07/2021 e del 24/08/2021; le misurazioni sono state operate tra le ore 12:00 e le ore 14:00, a distanza di 1-3 ore dai voli previsti nelle giornate medesime. Le piante

interessate dalle misure di potenziale idrico sono state selezionate seguendo uno schema sperimentale completamente randomizzato (sito A) o a blocchi randomizzati (sito B).

La mappatura di piante affette da ED, prevista per il sito A, è stata effettuata durante il mese di settembre 2021 ed ha riguardato tutte le piante presenti nell'area di studio; le piante sono state classificate con uno schema binario (sintomatico/non sintomatico), tramite una valutazione visiva. Sono stati classificati come sintomatici gli individui che, al momento dell'osservazione, hanno dato evidente manifestazione della sintomatologia descritta come "tigratura fogliare" (almeno alcune foglie interessate da sintomi distinguibili) essendo tale manifestazione ritenuta caratteristica dell'interazione tra le piante di *Vitis vinifera* L. e i patogeni associati a ED (Fontaine et al. 2016). Tutti gli individui sintomatici sono stati parimenti classificati, non è stata cioè prevista la discriminazione di più classi in base a livelli diversi di intensità della manifestazione. Non sono state classificate come sintomatiche le piante che hanno manifestato condizioni simili a quella descritta come "colpo apoplettico" data la non sufficientemente evidente eziologia.

4.1.3 Acquisizione dei dati aerei e pre-elaborazione

La campagna aerea ha riguardato l'acquisizione di immagini MS ed RGB; per ogni vigneto sono state ottenute due serie di immagini rispettivamente riferite alle giornate del 29/07/2021 e del 24/08/2021; l'acquisizione è avvenuta tra le ore 12:00 e le ore 15:00.

La campagna aerea è stata condotta con l'ausilio del SAPR SenseFly eBee X equipaggiato con un sistema di *imaging* basato sul sensore multispettrale Parrot Sequoia (fig. 22a) ed il sensore RGB SenseFly S.O.D.A. 3D (fig. 22b).

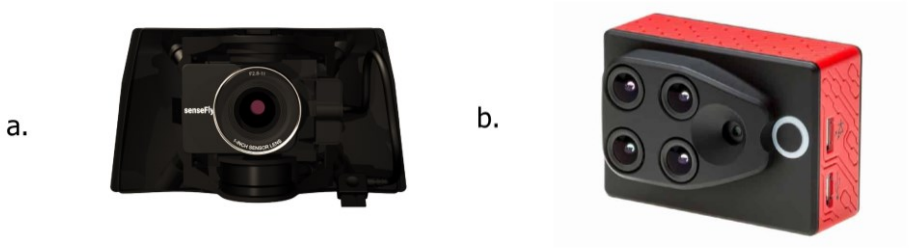

Fig. 22. Sensoristica impiegata per l'acquisizione dei dati: sensore multispettrale Parrot Sequoia (a), sensore RGB SenseFly S.O.D.A. 3D (b).

Le immagini sono state acquisite ad un livello di volo (*above ground level,* AGL) di 50 m. Le immagini MS sono state acquisite su 4 canali spettrali i.e. *green* (550nm ± 40nm), *red* (660nm ± 40nm), *red-edge* (735nm ± 10nm), *nir* (790nm ± 40nm).

Il *software* Pix4D è stato impiegato per la pre-elaborazione delle immagini aeree; le immagini aeree sono state tra loro fuse (*mosaicking*) ad ottenere per ciascun volo un unico ortomosaico. Le stesse immagini sono state infine sottoposte a processi di correzione geometrica e radiometrica.

4.2 Elaborazione e analisi dei dati

4.2.1 Selezione e calcolo degli indici vegetativi

L'analisi della letteratura non ha indicato, nei diversi VI soggetti a valutazione, una direzione di scelta univoca essendo i risultati riportati spesso contrastanti. Pertanto, è stato selezionato un insieme di VI sovrabbondante rispetto agli indici spettrali comunemente citati per valutazione e monitoraggio di fattori di stress.

In tab. 2 viene riportato l'elenco dei VI selezionati per il presente studio (da 1 a 45), specificando per ciascuno di essi la formula utilizzata per il calcolo, gli indicatori biofisici/biochimici correlati e le fonti di riferimento associate.

A partire dalle immagini multispettrali 36 VI sono stati calcolati per ciascun sito oggetto di studio (sito A e sito B); a questi vengono ad aggiungersi ulteriori 9 VI calcolati esclusivamente per il sito A; non è quindi stata prevista l'elaborazione delle immagini RGB relative al sito B, per il quale solo informazioni relative allo stato idrico sono state raccolte. Ciò è stato motivato dal fatto che secondo una recente *review* di Giovos et al. (2021) sull'impiego di VI in viticoltura, gli indici RGB verrebbero citati principalmente nella valutazione di stress biotici mentre, per la valutazione dello stato idrico della vegetazione, l'informazione disponibile nel VIS dovrebbe essere combinata con quella di altre zone ottiche dello spettro (i.e. NIR, SWIR) per trarre informazioni di valore a tale scopo.

Tutti gli VI sono stati calcolati per operazioni tra *raster* impiegando il software qGIS v3.22.0-Białowieża (Open Source Geospatial Foundation Project, http://qgis.osgeo.org).

4.2.2 *Estrazione delle aree vegetative*

Al fine di associare i dati raccolti a terra, con quelli spettrali rilevati tramite la campagna aerea, per ciascuna area oggetto di studio è stata prevista la realizzazione di una specifica mappa di riferimento; le mappe sono state create utilizzando il *software* qGIS sopra descritto.

La posizione di ognuna delle piante oggetto delle valutazioni a terra è stata individuata, sulla mappa di riferimento, da un *buffer* (ROI) avente diametro pari a 0,3 m; i *buffer* sono stati creati utilizzando il *plugin* MMQGIS v2020.1.16 e sono stati centrati rispetto alla posizione del fusto di ciascuna pianta (fig. 23).

Ciascun *buffer* è servito come punto di estrazione degli VI precedentemente calcolati; i valori estratti sono stati calcolati come media dei valori che l'VI ha assunto nei pixel associati all'area del *buffer*.

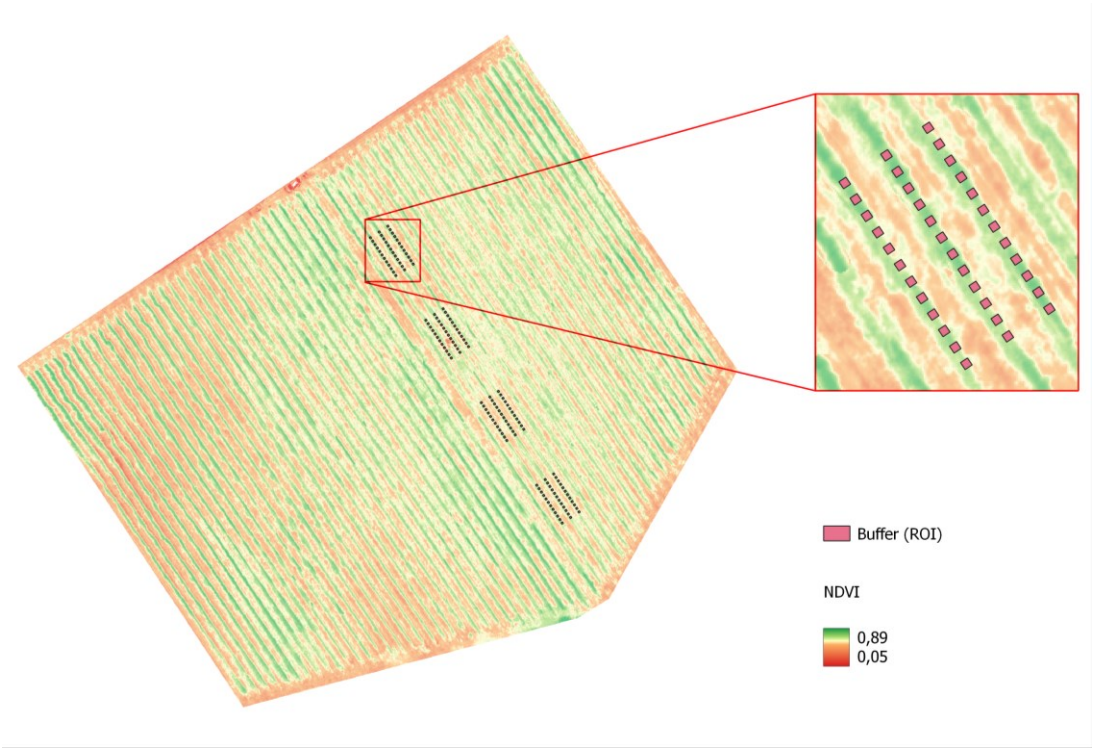

Fig. 23. Identificazione delle regioni di interesse (ROI), nonché dei *buffer* di estrazione degli VI calcolati per il sito B. Le ROI sono rappresentate su mappa NDVI restituita in falsi colori.

4.2.3 *Analisi statistiche*

Tramite il software Microsoft® Excel® per Microsoft 365 MSO (Versione 2211), le serie dei valori medi degli VI calcolati sono state associate, sulla base della corrispondenza degli ID pianta, alle informazioni rilevate a terra; al termine delle operazioni di unione dei dati è stato

ottenuto un *database* funzionale alle operazioni di elaborazione statistica previste per gli stessi dati.

Le analisi statistiche sono state condotte con il software R (v4.2.1; R Core Team, 2022) impiegando i pacchetti ggpubr (v0.4.0; Kassambara, 2020), report (v0.5.5; Makowski et al., 2021), ggforce (v0.4.1; Pedersen, 2022), ggplot2 (v3.3.6; Wickham,2016), readxl (v1.4.1; Wickham e Bryan, 2022) e dplyr (v1.0.9; Wickham et al., 2022). L'elaborazione ha previsto la stima di modelli di regressione lineare semplice e modelli di regressione polinomiale dei valori medi calcolati per gli VI selezionati rispetto ai dati ottenuti a terra. Al fine di valutare la bontà del modello statistico ottenuto, per ciascuna relazione è stato calcolato il relativo coefficiente di determinazione (R^2); il calcolo del *p-value* (*p*) è stato previsto al fine di caratterizzare il livello di significatività delle relazioni ottenute.

La stessa metodologia è stata impiegata per valutazioni a livello di singola data e di singolo vigneto; l'analisi per vigneto ha riguardato l'elaborazione congiunta dei *dataset* ottenuti in entrambe le giornate di raccolta dei dati stessi, riferiti allo stesso vigneto.

Tutte le elaborazioni statistiche svolte sono state presentate nell'allegato 1.

5 RISULTATI

5.1 Misura dei parametri di potenziale idrico

La distribuzione spaziale dei valori di Ψ_{stem} delle piante campionate viene presentata in fig. 24 per il sito di Udine e fig. 25 per il sito di Precenicco. Per il sito di Precenicco, a fronte di una più ampia casistica (tab. 5), in condizioni di campo normali, è stata osservata una certa variabilità nello spazio dei valori di Ψ_{stem} (fig. 25); per il sito di Udine, in condizioni controllate, le caratteristiche di stato idrico, rilevate dai valori Ψ_{stem}, sono state piuttosto omogenee per tutta l'area considerata, in entrambe le date (fig. 24). Si ritiene tuttavia che in condizioni normali di coltivazione lo stato idrico di un vigneto sia soggetto a forte variabilità spaziale (Acevedo-Opazo et al. 2008). Per il vigneto di Udine, la variabilità dei valori di Ψ_{stem} misurati nelle singole date è risultata contenuta; particolarmente per il *dataset* relativo al mese di luglio (29/07/2021) il *range* dei valori di Ψ_{stem} è stato piuttosto ridotto (tab. 4).

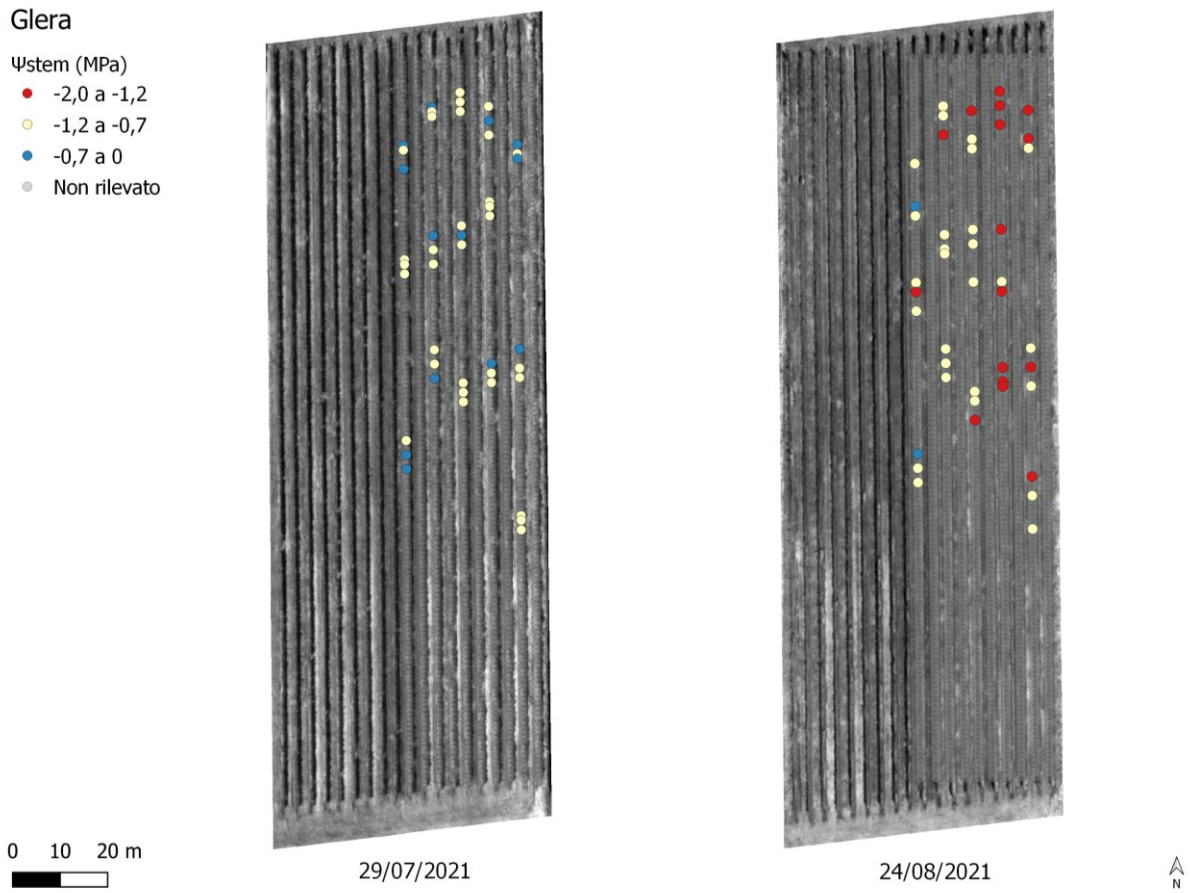

Fig. 25. Distribuzione spaziale dei valori di Ψstem misurati per il vigneto sito di Precenicco nelle due date di valutazione. I dati sono stati rappresentati su immagini NIR in banda singola grigia.

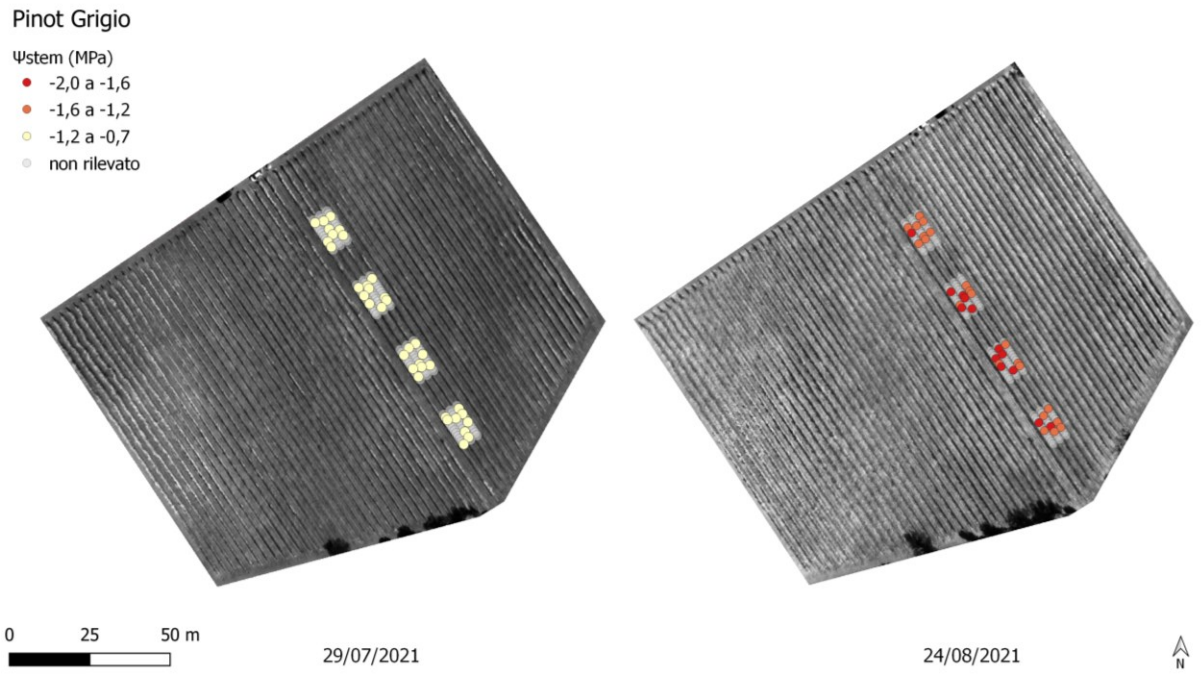

Fig. 24. Distribuzione spaziale dei valori di Ψ_{stem} misurati per il sito sperimentale di Udine nelle due date di valutazione. I dati sono stati rappresentati su immagini NIR in banda singola grigia.

In generale, nell'ambito delle tre tesi valutate per il sito di Udine (i.e. WW/MS/SS) i parametri Ψ_{stem} e Ψ_{leaf} hanno assunto spesso valori confrontabili nonostante i diversi regimi idrici previsti; ad esempio, nel mese di agosto (24/08/2021) sono sempre stati misurati valori di $\Psi_{stem} \leq$ -1,3 MPa. Simili livelli di Ψ_{stem} sono normalmente associati a condizioni di stress idrico severo (Romero et al. 2018); dall'analisi di Ψ_{stem} e Ψ_{leaf} in generale non emergono le differenze tra le tesi, previste in termini di trattamento idrico.

Si suppone che tale condizione possa essere dovuta all'effetto di fattori quali *vapour pressure deficit* (VPD) e temperatura dell'aria; secondo Williams et al. (2007), i fattori citati sono un riflesso della domanda evaporativa, la quale può condurre a rilevanti diminuzioni dei valori di Ψ_{stem} e Ψ_{leaf} nonostante lo stato idrico del suolo non sia limitante. Al contrario, si assume che Ψ_{pd} sia rilevato in condizioni di equilibrio rispetto al potenziale idrico del suolo rappresentando un buon indicatore del contenuto di umidità del suolo stesso (Winkel and Rambal 1993, Van Zyl 1987). A conferma di ciò, il parametro Ψ_{pd} ha meglio rappresentato le differenze in termini di disponibilità idrica del suolo previste per le diverse tesi (tab. 4).

Sebbene si possano rilevare diverse opinioni nella definizione dei valori soglia di Ψ_{pd} utili alla discriminazione di livelli di stress differenti (Sivilotti et al. 2005), secondo Ojeda et al. (2002) uno stress moderato viene rilevato per valori di Ψ_{pd} compresi tra -0,4 MPa e -0,6 MPa.

Inoltre, in condizioni di stress fisiologicamente tollerabili dalla pianta, diversi meccanismi intervengono (e.g. aggiustamenti di tipo osmotico) rendendo possibile il mantenimento di Ψ_{pd} a valori tendenzialmente più alti e stabili; il crollo dei valori di potenziale idrico si ha in concomitanza con stress idrici severi (Sivilotti et al. 2005).

Tab. 4. Analisi dei dati di potenziale idrico relativi al vigneto di Pinot grigio (*Vitis vinifera* L.) di Udine.

Data	Variabile	Tesi	Media	σ	CV	n
29/07/2021	Ψ_{leaf} (MPa)	WW	-1,06	0,09	0,28	12
		MS	-1,18	0,09	0,26	12
		SS	-1,19	0,07	0,22	12
		Tutte	-1,14	0,10	0,38	36
	Ψ_{pd} (MPa)	WW	-0,41	0,07	0,27	12
		MS	-0,62	0,13	0,48	12
		SS	-0,67	0,13	0,40	12
		Tutte	-0,57	0,17	0,75	36
	Ψ_{stem} (MPa)	WW	-0,86	0,04	0,13	12
		MS	-1,02	0,05	0,15	12
		SS	-0,99	0,03	0,12	12
		tutte	-0,96	0,09	0,32	36
24/08/2021	Ψ_{stem} (MPa)	WW	-1,50	0,07	0,20	12
		MS	-1,54	0,11	0,38	12
		SS	-1,64	0,10	0,38	11
		tutte	-1,56	0,14	0,6	35
entrambe	Ψ_{stem} (MPa)	WW	-1,15	0,27	0,78	24
		MS	-1,34	0,27	0,71	24
		SS	-1,34	0,29	0,96	23
		tutte	-1,26	0,32	1,1	71

Tab. 5. Analisi dei dati di potenziale idrico stem relativi al vigneto di Glera (*Viis vinifera* L.) di Precenicco.

Data	Variabile	Media	σ	CV	n
29/07/2021	Ψ_{stem} (MPa)	-0,85	0,15	0,56	45
24/08/2021	Ψ_{stem} (MPa)	-1,00	0,23	0,86	45
entrambe	Ψ_{stem} (MPa)	-0,96	0,25	0,98	100

5.2 Valutazione dello stato sanitario

La valutazione dello stato sanitario effettuata in campo per il sito A ha permesso di determinare il livello di diffusione di ED. Il 38% delle piante mappate ha presentato sintomi riconducibili a ED. I risultati della mappatura sono presentati in fig. 26.

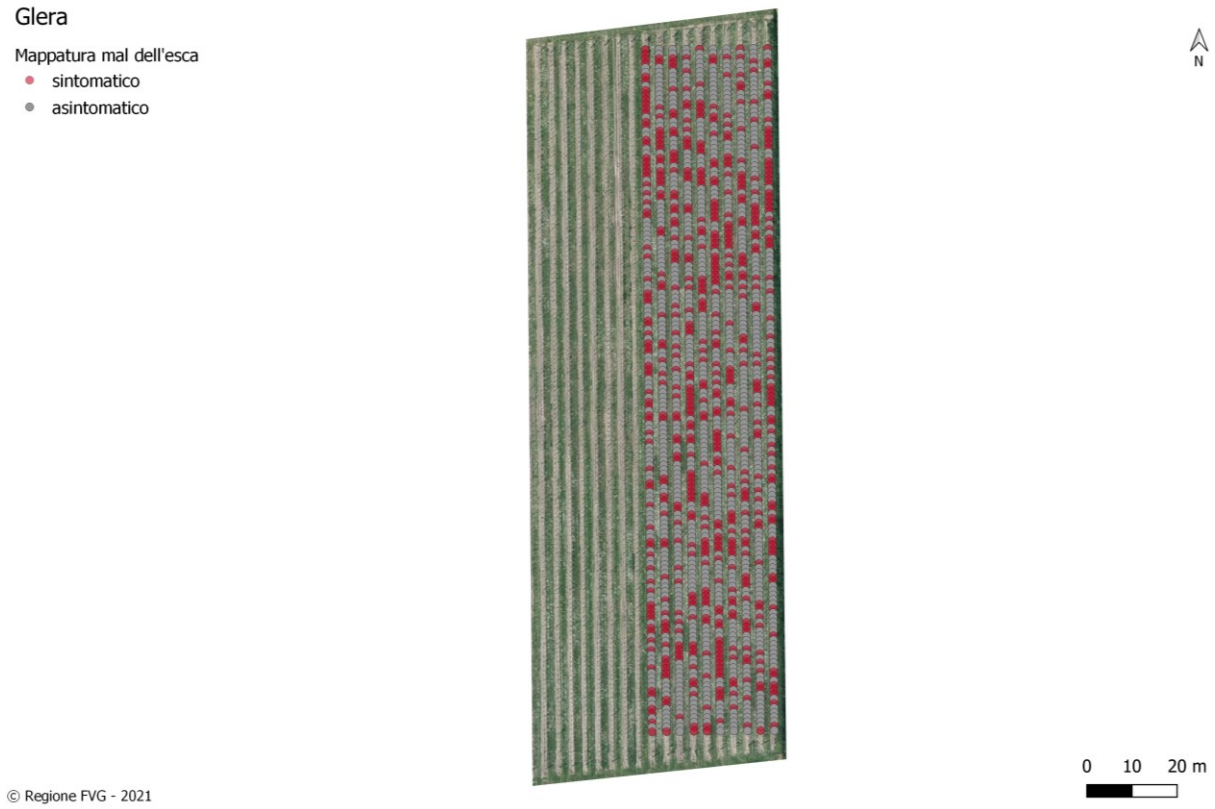

Fig. 26. Rappresentazione della distribuzione spaziale delle piante sintomatiche realizzata sulla base delle osservazioni visive previste contestualmente alla mappatura dello stato sanitario del vigneto di Precenicco.

5.3 Valutazione di VI per il monitoraggio dello stato idrico

5.3.1 Confronto delle relazioni tra VI e Ψ_{pd}, Ψ_{leaf}, Ψ_{stem}

Nella giornata del 29/07/2021, relativamente al sito di Udine, le misurazioni in campo hanno riguardato l'analisi tre parametri di potenziale idrico (i.e. Ψ_{pd}, Ψ_{leaf}, Ψ_{stem}) al fine di prevedere un confronto tra le relazioni ottenute e valutare eventuali differenze nel grado di dipendenza statistica delle variabili misurate rispetto ai VI calcolati a partire dalle immagini MS.

Per il caso considerato, i cui risultati sono stati presentati in allegato 1, in base alla valutazione dei coefficienti di determinazione, nessuna relazione ad alto potere predittivo è stata evidenziata; nonostante ciò, i modelli lineari ottenuti per il parametro Ψ_{pd} hanno

generalmente condotto a risultati migliori; nella valutazione dei coefficienti di determinazione, le correlazioni con il parametro Ψ_{stem} hanno fatto rilevare i valori più bassi ($R^2 \leq 0{,}05$). Sono stati raggiunti valori massimi pari a $R^2 = 0{,}11$ ed $R^2 = 0{,}24$ rispettivamente per i parametri Ψ_{leaf} e Ψ_{pd}. Il campo di variazione dei dati più ridotto è stato calcolato per il parametro Ψ_{stem}, quello maggiore per Ψ_{pd} (tab. 4). Si assume che i risultati ottenuti e le differenze osservate nel confronto tra variabili (Ψ_{stem}, Ψ_{leaf}, Ψ_{pd}) possano essere stati influenzati almeno in parte dalla diversa distribuzione dei dati.

5.3.2 Relazioni tra VI e Ψ_{stem}

Le relazioni tra i VI calcolati e i valori di Ψ_{stem} sono riportate in tab. 7 (Udine) e tab. 8 (Precenicco).

L'analisi per singola data delle relazioni lineari calcolate per ciascun VI rispetto a Ψ_{stem}, non ha evidenziato risultati soddisfacenti. Sebbene alcune relazioni significative siano state osservate ($p \leq 0.01$) nella maggior parte dei casi sono stati rilevati valori di $R^2 \leq 0{,}10$ e in ogni caso non superiori a $R^2 = 0{,}17$ per il sito di Udine ed $R^2 = 0{,}16$ per il sito di Precenicco. Particolarmente per il sito sperimentale di Udine, si suppone che gli scarsi risultati possano essere, almeno parzialmente, ricondotti al ridotto campo di variazione dei dati (CV), al pari di quanto già considerato in altri contesti sperimentali (e.g. Chang et al. (2001)).

Per quest'ultimo sito si apprezza un miglioramento, spesso significativo, nelle *performance* di buona parte dei VI calcolati, analizzando in modo congiunto i *dataset* relativi a entrambe le date (n = 71); il citato miglioramento è stato osservato contestualmente ad un incremento significativo del campo di variazione dei dati (CV = 1,1 MPa). Un ulteriore incremento dei valori di R^2 si è ottenuto impiegando modelli non lineari; in accordo con quanto osservato da Romero et al. (2018), le relazioni polinomiali hanno generalmente prodotto un migliore *fit* rispetto ai dati di Ψ_{stem} (tab. 7). In riferimento al sito di Precenicco, tramite l'analisi congiunta dei *dataset* (n = 100) non è stato verificato un aumento altrettanto diffuso e netto dei valori di R^2 caratterizzanti le relazioni ottenute.

In generale, l'analisi delle rette di regressione calcolate per il sito di Precenicco ha condotto a risultati contrastanti rispetto a quelli verificati per il sito di Udine, con particolare a riferimento ad alcuni VI (tab. 6); tali valutazioni indicano difficoltà nel riprodurre i risultati ottenuti, in condizioni sperimentali differenti.

Tab. 6. Confronto dei valori di R^2 di alcuni VI valutati in condizioni sperimentali differenti.

Indici vegetativi	Precenicco	Udine
	R^{2a} (n = 100)	R^2 (n = 71)
DVI	0,04*	0,38***
Gitelson Cl1	0,06*	0,58***
Gitelson Cl2	0,03	0,43***
MCARI1	0,05*	0,36***
MRVI	0,04	0,39***
MTVI1	0,05*	0,36***
NIR-G	0,04	0,39***
PVI	0,03	0,39***
TVI2	0,04*	0,37***

[a]Livello di significatività: *$p \leq 0.05$; **$p \leq 0.01$; ***$p \leq 0.001$

Dall'analisi della letteratura si può verificare come in generale spesso, lo stesso VI, se valutato in condizioni sperimentali diverse, possa condurre a risultati discordanti (tab. 3). Molteplici fattori potrebbero essere all'origine delle difficoltà di riproducibilità dei risultati ottenuti e.g. (i) variabile qualità delle immagini e dei prodotti da esse derivati (e.g. mappe di VI) a causa di differenze tecniche nella sensoristica impiegata e/o nelle modalità di pre-processamento delle immagini (Huang et al. 2021), (ii) diverso modello statistico adottato (Romero et al. 2018), (iii) variabilità nella risposta fisiologica varietale e di specie (Bowyer & Danson 2004, Penuelas et al. 1993), (iv) caratteristiche del sito sperimentale (e.g. effetto del vigore sulla saturazione di alcuni VI) (Romero et al. 2018), (v) interferenza di fenomeni di natura diversa in grado di provocare alterazioni fisiologiche simili a quelle del fattore di stress oggetto di studio (Hmimina et al. 2015). Nello specifico della casistica analizzata nel presente studio, il differente grado di complessità dei due sistemi analizzati (i.e. sito di Udine e sito di Precenicco) potrebbe aver almeno in parte condizionato i risultati ottenuti e la loro riproducibilità.

Nel vigneto di Precenicco l'esperimento è stato condotto nelle normali condizioni di campo e l'effetto di sovrapposizione, nel punto di estrazione dei dati (ROI), di tralci provenienti da piante vicine con diverse caratteristiche di stato idrico, potrebbe aver portato a una contaminazione della risposta spettrale pura della pianta in osservazione rendendo difficile l'accoppiamento con i valori di Ψ_{stem} misurati per la specifica pianta; simili effetti sono già stati osservati da alcuni autori in altri contesti sperimentali (Daglio et al. 2022, Rançon et al. 2018).

Al contrario, per il vigneto di Udine, la prova è stata condotta seguendo uno schema di suddivisione del sito di studio in blocchi sottoposti a regimi idrici specifici e controllati; tale schema sperimentale potrebbe aver reso poco significativi i citati effetti di sovrapposizione rispetto ai punti di estrazione dei VI essendo, tutte le piante di uno stesso filare, caratterizzate da un simile comportamento fisiologico, e presumibilmente anche spettrale, come testimoniato dalla omogenea distribuzione dei valori di Ψ_{stem} nell'area di studio (fig. 24). Differenze nei valori minimi di Ψ_{stem} potrebbero aver similmente condizionato i risultati; nello specifico, i valori più negativi di Ψ_{stem} registrati in condizioni controllate per il sito di Udine potrebbero aver determinato performance migliori, specie per quei VI che tendono fornire risultati più stabili in situazioni di stress idrico severo.

Infine, in considerazione degli scarsi risultati ottenuti in modo generalizzato per il vigneto di Precenicco, si suppone che una non costante qualità delle immagini MS possa aver influito sulla scarsa riproducibilità ad esempio provocando un disaccoppiamento, anche parziale, delle zone di estrazione degli VI calcolati, rispetto ai punti effettivi di misura dei valori di potenziale in campo. L'utilizzo di sensori MS montati su SAPR può comportare notevoli errori radiometrici e geometrici richiedendo l'esecuzione di processi di calibrazione (Poncet et al. 2019). Nonostante questi processi siano funzionali a una riduzione di tali errori occorre chiarire la robustezza e la ripetibilità del metodo impiegato; secondo Whiteside & Bartolo (2016) la variabilità radiometrica viene considerata tra i principali limiti all'utilizzo di SAPR essendo in grado di influire sulla riproducibilità dei risultati ottenuti per voli o sensori diversi. Per simili motivi, secondo Huang et al. (2021), non esistono due immagini MS che siano tra loro perfettamente sovrapponibili, inoltre, ogni VI può essere condizionato in maniera più o meno evidente da effetti atmosferici e di sensoristica (e.g. correzioni geometriche e radiometriche). Sempre secondo gli stessi autori molto spesso le correzioni operate sulle immagini MS, particolarmente se ottenute da SAPR, risultano deficitarie.

Tab. 7. Analisi statistiche relative al sito sperimentale di Udine; vengono riportati i coefficienti di determinazione calcolati per le relazioni lineari e polinomiali ottenute per 36 VI multispettrali rispetto al parametro Ψ_{stem}.

Indice vegetativo	Modello lineare			Modello polinomiale
	R^2 [a] (n = 36)	R^2 (n = 35)	R^2 (n = 71)	R^2 (n = 71)
	29/07/2021	24/08/2021	Entrambe le date	Entrambe le date
Clgreen	< 0,01	0,05	0,05	0,09*
Clrededge	< 0,01	0,16*	0,05	0,09**
CVI	0,05	0,14*	0,18***	0,21***
DVI	< 0,01	0,01	0,38***	0,45***
EVI2	< 0,01	0,01	0,34***	0,40***
Gitelson Cl1	0,04	0,02	0,58***	0,60***
Gitelson Cl2	< 0,01	< 0,01	0,43***	0,54***
GNDVI	< 0,01	0,05	0,05*	0,10**
GR	< 0,01	< 0,01	< 0,01	< 0,01
GRVI	< 0,01	< 0,01	< 0,01	< 0,01
MCARI	< 0,01	< 0,01	0,16***	0,10**
MCARI1	< 0,01	< 0,01	0,36***	0,41***
MGRVI	< 0,01	< 0,01	< 0,01	< 0,01
MRVI	< 0,01	0,01	0,39***	0,45***
MSAVI	< 0,01	0,01	0,34***	0,40***
MSR	< 0,01	< 0,01	0,01	0,01
MTVI1	< 0,01	< 0,01	0,36***	0,41***
NDRE	< 0,01	0,17*	0,06*	0,11**
NDVI	< 0,01	< 0,01	0,01	0,04
NGRDI	< 0,01	< 0,01	< 0,01	< 0,01
NIR-G	< 0,01	0,02	0,39***	0,50***
NIR/G	< 0,01	0,05	0,05	0,09*
NLI	< 0,01	< 0,01	0,18***	0,25***
OSAVI	< 0,01	< 0,01	0,23***	0,30***
PRSI	< 0,01	0,02	< 0,01	< 0,01
PVI	< 0,01	0,01	0,39***	0,49***
R/G	< 0,01	< 0,01	< 0,01	< 0,01
RDVI	< 0,01	< 0,01	0,29***	0,34***
REGI	< 0,01	0,03	0,05	0,07*
RERI	< 0,01	< 0,01	0,05	0,02
RVI	< 0,01	< 0,01	0,01	0,04
SR	< 0,01	< 0,01	< 0,01	< 0,01
TCARI	< 0,01	< 0,01	0,16***	0,10**
TCARI/OSAVI	< 0,01	< 0,01	0,13**	0,08*
TVI2	< 0,01	< 0,01	0,37***	0,42***
VIF	< 0,01	< 0,01	0,01	0,03

[a]Livello di significatività: $^{*}p \leq 0.05$; $^{**}p \leq 0.01$; $^{***}p \leq 0.001$

Tab. 8. Analisi statistiche relative al sito sperimentale di Precenicco; vengono riportati i coefficienti di determinazione calcolati per le relazioni lineari ottenute per 36 VI multispettrali e 9 VI RGB rispetto al parametro Ψ_{stem}.

Indice vegetativo	R^2 [a] (n = 45) 29/07/2021	R^2 (n = 45) 24/08/2021	R^2 (n = 100) Entrambe le date
Clgreen	0,13*	< 0,01	0,07*
CIVE	0,02	0,02	0,28***
Clrededge	0,02	0,04	< 0,01
CVI	0,02	0,05	< 0,01
DVI	0,12*	0,01	0,04*
EVI2	0,11*	< 0,01	0,05*
ExB	< 0,01	< 0,01	0,22***
ExG	0,04	< 0,01	0,14***
ExGR	0,03	< 0,01	0,12***
ExR	0,04	0,05	0,08**
Gitelson Cl1	0,05	0,02	0,06*
Gitelson Cl2	0,12*	0,03	0,03
GNDVI	0,13*	< 0,01	0,08**
GR	0,07	0,03	0,07*
GRVI	0,07	0,03	0,07*
MCARI	0,12*	0,01	0,06*
MCARI1	0,11*	0,02	0,05*
MGRVI	0,07	0,03	0,07**
MRVI	0,13*	0,01	0,04*
MSAVI	0,11*	0,01	0,05*
MSR	0,10*	0,01	0,07*
MTVI1	0,11*	0,02	0,05*
NDRE	0,02	0,04	< 0,01
NDVI	0,10*	< 0,01	0,08**
NGBDI	0,01	0,01	0,16***
NGRDI	0,07	0,03	0,07*
NIR-G	0,12*	< 0,01	0,04
NIR/G	0,13*	< 0,01	0,07*
NLI	0,12*	< 0,01	0,07*
NPCI	< 0,01	0,04	0,16***
NPCI2	< 0,01	0,04	0,16***
OSAVI	0,12*	< 0,01	0,07*
PRSI	0,03	0,04	0,07*
PVI	0,12*	0,01	0,03
R/G	0,07	0,03	0,08**
RDVI	0,12*	0,01	0,06*
REGI	0,16**	< 0,01	0,08**
RERI	0,11*	0,02	0,08**
RVI	0,10*	< 0,01	0,08**
SR	0,10*	< 0,01	0,07*

Tab. 8. Continua

Indice vegetativo	R^2 [a] (n = 45) 29/07/2021	R^2 (n = 45) 24/08/2021	R^2 (n = 100) Entrambe le date
TCARI	0,12*	0,01	0,06*
TCARI/OSAVI	0,12*	0,01	0,07*
TGI	< 0,01	0,02	0,31***
TVI2	0,11*	0,02	0,04*
VIF	0,10*	< 0,01	0,08**

[a]Livello di significatività: *$p \leq 0.05$; **$p \leq 0.01$; ***$p \leq 0.001$

5.3.3 Selezione degli VI meglio correlati a Ψ_{stem}

La valutazione delle diverse combinazioni spettrali analizzate (tab. 9), non ha condotto ad un giudizio di preferenza nei confronti di uno specifico *set* di bande; nonostante ciò, si sottolinea che gli VI che hanno prodotto le migliori correlazioni con i valori di Ψ_{stem} ($R^2 > 0,40$), coinvolgono generalmente l'informazione spettrale del NIR (tab. 9). Rispetto ad altre bande spettrali, si può quindi ipotizzare un ruolo di maggiore rilievo delle lunghezze d'onda del NIR nel monitoraggio dello stato idrico della vegetazione; ciò in accordo con una recente *review* di Giovos et al. (2021) i quali considerano i VI non contenenti l'informazione di riflettanza nel NIR poco utili alle valutazioni relative allo stato idrico.

Tab. 9. Distribuzione di frequenza delle combinazioni spettrali analizzate rispetto a diverse classi di correlazione (nulla o molto bassa per R^2 minore o uguale a 0,30; correlazione bassa per R^2 variabile tra 0,30 e 0,40; correlazione moderata per R^2 variabile tra 0,40 e 0,60). Ciascun VI viene indicato con il rispettivo ID ed associato alla relativa combinazione di bande (G = *green*, R = *red*, RE = *red-edge*, NIR = *near infrared*). I risultati riportati si riferiscono all'analisi delle relazioni polinomiali ottenute per il vigneto di Udine per entrambe le date di osservazione.

Combinazione di bande	Correlazione nulla o molto bassa	Correlazione bassa	Correlazione moderata
NIR, G	1, 9, 21		21
NIR, RE	2, 18		
NIR, R	16, 19, 23, 31, 32, 36	24, 28	4, 5, 14, 15, 26
G, R	6, 10, 13, 20, 27		
RE, R, G	11, 33, 25		
NIR, R, G	3		12, 17, 35
RE, G	29		
RE, R	30		
RE, R, G, NIR	34		

Nonostante ciò, spesso i valori di R^2 ottenuti per VI che incorporano il medesimo *set* di bande spettrali (e.g. NIR, RED) sono stati significativamente diversi; oltre al *set* di lunghezze d'onda impiegate, è evidentemente rilevante anche la modalità matematica con la quale le stesse informazioni vengono diversamente combinate. I grafici delle regressioni caratterizzate da valori di $R^2 \geq 0{,}45$ sono presentati in fig. 27.

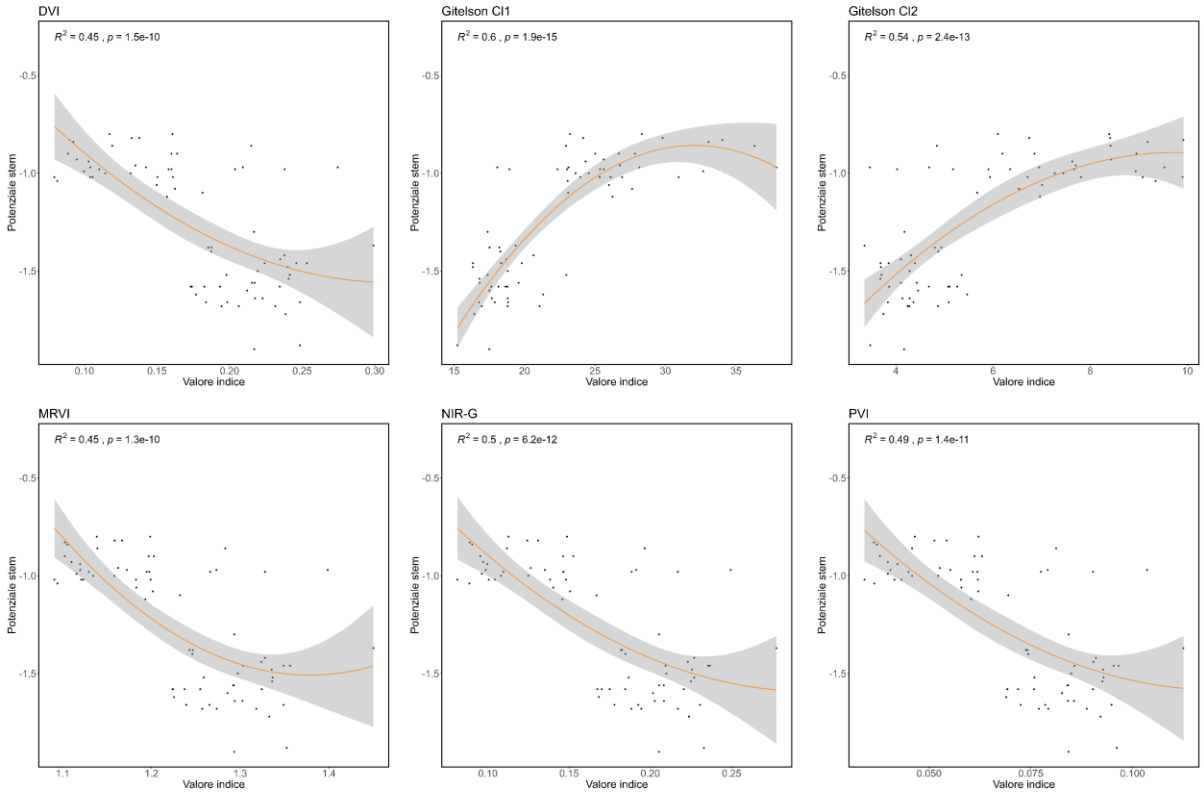

Fig. 27. Regressioni ottenute per gli VI che hanno mostrato dipendenza statistica moderata rispetto ai valori di Ψ_{stem} ($R^2 \geq 0{,}45$)

Si suppone che le variazioni di ρ_{NIR} possano indicare situazioni di stress idrico essendo la stessa riflettanza nel NIR, condizionata da modificazioni strutturali a livello di mesofillo che si verificano in concomitanza di situazioni di stress idrico (Daglio et al. 2022, Sinclair et al. 1973); tali effetti sono tuttavia considerati piuttosto tardivi, inoltre potrebbero variare nella propria entità a seconda della specifica risposta varietale e di specie (Penuelas et al. 1993). Oltre a indicare effetti strutturali indiretti, le lunghezze d'onda del NIR vengono direttamente interessate dalle caratteristiche di assorbimento del legame O-H delle molecole di H_2O (Clevers et al. 2010); al contrario le molecole di H_2O non mostrano caratteristiche di assorbimento nel VIS, le cui lunghezze d'onda possono pertanto indicare i soli effetti indiretti legati a condizioni di deficienza idrica (Pôças et al. 2015).

Tra i VI analizzati, diversi indici hanno mostrato moderate *performance* di correlazione rispetto a Ψ_{stem} (fig. 27), tra questi si citano NIR-G ($R^2 = 0,50$) e PVI ($R^2 = 0,49$); il calcolo di tali VI prevede la combinazione della riflettanza nel NIR con l'informazione spettrale rispettivamente del *green* (NIR-G) e del *red* (PVI) (tab. 3).

Le lunghezze d'onda del verde e del rosso sono dominate dagli effetti di riflessione ed assorbimento dovuti alla presenza di Chl_{a+b} (Lichtenthaler and Buschmann 2001). La diminuzione di Chl_{a+b} è normalmente associata ad un incremento del deficit idrico (Bertamini et al. 2006).

Similmente ai VI NIR-G e PVI, promettenti risultati in termini di correlazione con i valori di Ψ_{stem} sono stati ottenuti per le variabili Gitelson Cl1 ($R^2 = 0,60$) e Gitelson Cl2 ($R^2 = 0,54$).

Gitelson Cl1 e Gitelson Cl2 sono stati calcolati impiegando le formule riportate da Kandylakis et al. (2016), come citato da Giovos et al. (2021); nonostante ciò, nel presente lavoro, le variabili Gitelson Cl1 e Gitelson Cl2 sono state formalmente considerate come semplici trasformazioni matematiche dei valori di ρ_{green} (Gitelson Cl1) e $\rho_{red\text{-}edge}$ (Gitelson Cl2). È stato infatti ritenuto non significativo il contributo di ρ_{NIR} nelle formule proposte, come descritte da Giovos et al. (2021). Essendo gli indici vegetativi ottenuti dalla combinazione matematica dei dati ottenuti da almeno due bande spettrali (Jackson and Huete 1991, Romero et al. 2018), le variabili Gitelson Cl1 e Gitelson Cl2, nel presente lavoro, non sono state considerate tali, sebbene parimenti valutate.

L'analisi delle regressioni ottenute per la *cultivar* Pinot Grigio (Udine) ha permesso di evidenziare, per via grafica dei possibili valori soglia, sperimentabili al fine di valutare le potenzialità di alcuni VI nella discriminazione di piante caratterizzate da uno stress idrico avanzato ($\Psi_{stem} \leq -1,2$ MPa) rispetto a vegetazione caratterizzata da condizioni di stress idrico medio o nullo ($\Psi_{stem} \geq -1,2$ MPa) (tab. 10).

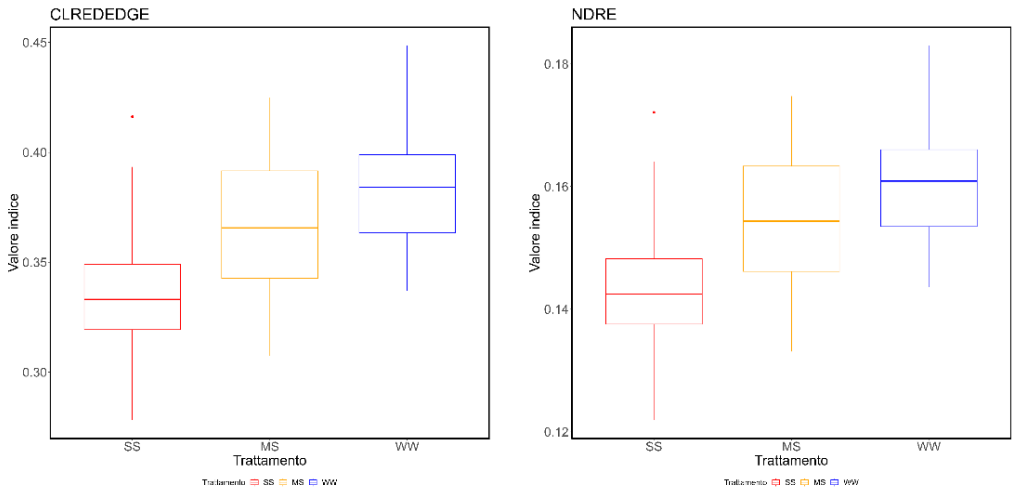

Fig. 28. Boxplot degli VI CLREDEDGE ed NDRE riferiti alla data 24/08/2021 per il sito di Udine.

Tab. 10. Possibili valori soglia utili alla discriminazione di diversi livelli di stato idrico (WW/WS per $\Psi_{stem} \geq$ -1,2 Mpa; SS per $\Psi_{stem} \leq$ -1,2 Mpa)

Indice vegetativo	Livello di stress	Possibile valore soglia
DVI	WW/MS	≤ 0,17
	SS	≥ 0,17
EVI2	WW/MS	≤ 0,32
	SS	≥ 0,32
Gitelson Cl1	WW/MS	≥ 22
	SS	≤ 22
Gitelson Cl2	WW/MS	≥ 5,5
	SS	≤ 5,5
MCARI1	WW/MS	≤ 0,26
	SS	≥ 0,26
MRVI	WW/MS	≤ 1,22
	SS	≥ 1,22
MSAVI	WW/MS	≤ 0,3
	SS	≥ 0,3
MTVI1	WW/MS	≤ 0,26
	SS	≥ 0,26
NIR-G	WW/MS	≤ 0,16
	SS	≥ 0,16
PVI	WW/MS	≤ 0,65
	SS	≥ 0,65

5.3.4 Impiego di VI per la discriminazione di diversi livelli di stato idrico

Sempre nei termini della caratterizzazione di diverse condizioni fisiologiche legate ad una differente disponibilità idrica, attraverso il confronto delle relazioni ottenute per singola data è stato valutato il comportamento dei VI rispetto a diversi livelli di stress. A fronte del generale incremento dei valori di R^2 ottenuto per il sito di Udine, alcuni VI clorofilla dipendenti (i.e. CLREDEDGE, NDRE) hanno mostrato *performance* peggiori rispetto ai risultati ottenuti per la singola data 24/08/2021; inoltre, sempre in tale data, CLREDEDGE ed NDRE sono stati i VI in grado di offrire la migliore discriminazione della tesi SS rispetto ai trattamenti MS e WW (fig. 28). Nel mese di agosto sono stati misurati i valori assoluti di Ψ_{stem} più negativi (tab. 4).

Nonostante venga nuovamente specificato che i risultati ottenuti nelle valutazioni per singola data non sono stati soddisfacenti ($R^2 \leq 0{,}16$), tali osservazioni potrebbero evidenziare la tendenza di alcuni VI a migliorare le proprie *performance* al di sotto di determinati valori di Ψ_{stem} potendo, potenzialmente, assumere un ruolo nell'indicare particolari situazioni di stress idrico severo. Analoghe considerazioni sono state avanzate da Romero et al. (2018) i quali similmente, per alcuni VI, hanno rilevato relazioni maggiormente significative nelle situazioni di maggiore stress idrico. Un tale comportamento di VI sensibili a variazioni di Chl_{a+b} e alterazioni di tipo strutturale è verosimile essendo in generale ritenuto che gli effetti sulle strutture cellulari e sulla riduzione della concentrazione di Chl_{a+b}, siano piuttosto tardivi nella risposta fisiologica della pianta a condizioni di deficienza idrica (Baluja et al. 2012, Gamon et al. 1992, Penuelas et al. 1993).

5.4 Valutazione di VI per il monitoraggio del mal dell'esca della vite

I risultati ottenuti sono presentati nell'allegato 1.

L'analisi di 45 VI calcolati da immagini MS ed RGB non ha condotto a risultati soddisfacenti nel monitoraggio di ED; nessuno dei VI soggetti a valutazione ha consentito una accurata discriminazione di individui asintomatici rispetto a individui sintomatici. Nonostante spesso vengano citati vari fattori in grado di influenzare negativamente l'accuratezza di discriminazione, l'analisi della letteratura evidenzia capacità di discriminazione generalmente migliori di quelle verificati nel presente studio. Sebbene la risposta spettrale di piante affette da ED sia chiaramente distinguibile da quella di piante sane, come dimostrato in diversi lavori condotti a livello fogliare (Al-Saddik et al. 2018, Bendel et al. 2020a, Junges et al. 2018),

nelle condizioni normali di coltivazione la maggiore complessità del sistema rende più difficoltosa la discriminazione (Rançon et al. 2018). Tuttavia, come rilevabile da altri studi, *performance* generalmente migliori di quelle conseguite nel presente studio sono ottenibili nella discriminazione di piante affette da ED da vegetazione sana tramite SAPR, con approccio MS (Albetis et al. 2018, Bendel et al. 2020a). Si ipotizza che i risultati ottenuti possano essere stati condizionati da effetti diversi tra i quali si citano (i) qualità dei dati spettrali, (iii) effetti di contaminazione della risposta spettrale nei punti di estrazione degli indici, (iv) presenza di piante interessate da stress di tipo biotico o abiotico in grado di provocare alterazioni simili a quelle provocate da ED.

6 CONCLUSIONI

I risultati ottenuti nel presente studio suggeriscono che i VI calcolati da immagini MS ad alta definizione ottenute da SAPR possono rappresentare uno strumento utile ad una rapida caratterizzazione dello stato idrico delle piante di vite, con potenziale vantaggio rispetto a tecniche meno tempestive. Tra le variabili analizzate, i VI che coinvolgono l'informazione di riflettanza nel NIR sono risultati generalmente più adatti a tale scopo; si ritiene che diversi tra i VI valutati (e.g. NIR-G, PVI, MRVI, DVI) possano potenzialmente avere un ruolo nella discriminazione di aree vegetative caratterizzate da condizioni fisiologiche assimilabili a stress idrico severo; va valutata la possibilità di discriminazione di più classi di stato idrico.

Le variabili Gitelson Cl1 e Gitelson Cl2 hanno prodotto i migliori risultati in termini di correlazione con i valori di Ψ_{stem} (R^2 = 0,60 ed R^2 = 0,54 rispettivamente).

Ulteriori studi sono necessari per validare i risultati ottenuti testando le performance dei VI analizzati in condizioni sperimentali differenti così da chiarire gli aspetti di riproducibilità.

Relativamente agli aspetti di monitoraggio dello stato sanitario del vigneto, nessuno dei 45 VI analizzati ha consentito di evidenziare differenze tali da consentire la discriminazione di piante sane rispetto a individui affetti da ED; nonostante i risultati ottenuti siano stati non soddisfacenti, si ritiene che l'impiego di immagini MS ed RGB ottenute da SAPR possa comunque essere proposto contestualmente alla valutazione ed al miglioramento della qualità dei dati spettrali.

7 BIBLIOGRAFIA

Acevedo-Opazo C, Tisseyre B, Ojeda H, Ortega-Farias S, Guillaume S. 2008. Is it possible to assess the spatial variability of vine water status? *OENO One* 42:203–219.

Acorsi MG, Gimenez LM, Martello M. 2020. Assessing the Performance of a Low-Cost Thermal Camera in Proximal and Aerial Conditions. *Remote Sensing* 12:3591.

Adão T, Hruška J, Pádua L, Bessa J, Peres E, Morais R, Sousa JJ. 2017. Hyperspectral Imaging: A Review on UAV-Based Sensors, Data Processing and Applications for Agriculture and Forestry. *Remote Sensing* 9:1110.

Adokiya MN, Awoonor-Williams JK, Beiersmann C, Müller O. 2016. Evaluation of the reporting completeness and timeliness of the integrated disease surveillance and response system in northern Ghana. *Ghana Med J* 50:3–8.

Albetis J, Duthoit S, Guttler F, Jacquin A, Goulard M, Poilvé H, Féret JB, Dedieu G. 2017. Detection of Flavescence dorée Grapevine Disease Using Unmanned Aerial Vehicle (UAV) Multispectral Imagery. *Remote Sensing* 9:308.

Albetis J, Jacquin A, Goulard M, Poilvé H, Rousseau J, Clenet H, Dedieu G, Duthoit S. 2018. On the Potentiality of UAV Multispectral Imagery to Detect Flavescence dorée and Grapevine Trunk Diseases. *Remote Sensing* 11:23.

Al-Saddik H, Laybros A, Billiot B, Cointault F. 2018. Using Image Texture and Spectral Reflectance Analysis to Detect Yellowness and Esca in Grapevines at Leaf-Level. *Remote Sensing* 10:618.

Al-Saddik H, Laybros A, Simon JC, Cointault F. 2019. Protocol for the Definition of a Multi-Spectral Sensor for Specific Foliar Disease Detection: Case of "Flavescence Dorée." In: Musetti R, Pagliari L. (eds) *Phytoplasmas. Methods in Molecular Biology.* Humana Press, New York, NY Methods in Molecular Biology 1875:213–238.

Anderegg J, Yu K, Aasen H, Walter A, Liebisch F, Hund A. 2020. Spectral Vegetation Indices to Track Senescence Dynamics in Diverse Wheat Germplasm. *Front Plant Sci* 10:1749.

Aneece I, Thenkabail PS. 2021. Classifying crop types using two generations of hyperspectral sensors (Hyperion and DESIS) with machine learning on the cloud. *Remote Sensing* 13:4704.

Avola D, Cinque L, Foresti GL, Martinel N, Pannone D, Piciarelli C. 2020. A UAV Video Dataset for Mosaicking and Change Detection from Low-Altitude Flights. *IEEE Trans Syst Man Cybern Syst* 50:2139–2149.

Badzmierowski MJ, McCall DS, Evanylo G. 2019. Using Hyperspectral and Multispectral Indices to Detect Water Stress for an Urban Turfgrass System. *Agronomy* 9:439.

Baker RE, Peña JM, Jayamohan J, Jérusalem A. 2018. Mechanistic models versus machine learning, a fight worth fighting for the biological community? *Biol Lett* 14:20170660.

Bala SK, Islam AS. 2009. Correlation between potato yield and MODIS-derived vegetation indices. International Journal of *Remote Sensing* 30:2491–2507.

Balachandran S, Hurry VM, Kelley SE, Osmond CB, Robinson SA, Rohozinski J, Seaton GGR, Sims DA. 1997. Concepts of plant biotic stress. Some insights into the stress physiology of virus-infected plants, from the perspective of photosynthesis. *Physiol Plant* 100:203–213.

Baluja J, Diago MP, Balda P, Zorer R, Meggio F, Morales F, Tardaguila J. 2012. Assessment of vineyard water status variability by thermal and multispectral imagery using an unmanned aerial vehicle (UAV). *Irrig Sci* 30:511–522.

Bannari A, Morin D, Bonn F, Huete AR. 1995. A review of vegetation indices. *Remote sensing reviews* 13:95–120.

Baranoski GVG, Rokne JG. 2007. A practical approach for estimating the red edge position of plant leaf reflectance. *International Journal of Remote Sensing* 26:503–521.

Baret F, Buis S. 2008. Estimating canopy characteristics from remote sensing observations: Review of methods and associated problems. In: Liang S. (ed) *Advances in Land Remote Sensing: System, Modeling, Inversion and Application.* Springer, New York, pp. 173–201.

Baret F, Guyot G, Major D. 1989. TSAVI: a vegetation index which minimizes soil brightness effects on LAI and APAR estimation. In: *12th Canadian Symp on Remote Sensing and IGARSS'90. Vancouver, Canada, 10-14 luglio 1989* 1:1355-1358

Barton CVM. 2011. Advances in remote sensing of plant stress. *Plant and Soil* 354:41–44.

Bellvert J, Zarco-Tejada PJ, Girona J, Fereres E. 2014. Mapping crop water stress index in a 'Pinot-noir' vineyard: Comparing ground measurements with thermal remote sensing imagery from an unmanned aerial vehicle. *Precis Agric* 15:361–376.

Bendel N, Kicherer A, Backhaus A, Klück HC, Seiffert U, Fischer M, Voegele RT, Töpfer R. 2020a. Evaluating the suitability of hyper- and multispectral imaging to detect foliar symptoms of the grapevine trunk disease Esca in vineyards. *Plant Methods* 16:1–18.

Bendel N, Kicherer A, Backhaus A, Köckerling J, Maixner M, Bleser E, Klück HC, Seiffert U, Voegele RT, Töpfer R. 2020b. Detection of grapevine leafroll-associated virus 1 and 3 in white and red grapevine cultivars using hyperspectral imaging. *Remote Sensing* 12:1693.

Berger B, Parent B, Tester M. 2010. High-throughput shoot imaging to study drought responses. *J Exp Bot* 61:3519–3528.

Berner LT, Beck PSA, Bunn AG, Lloyd AH, Goetz SJ. 2011. High-latitude tree growth and satellite vegetation indices: Correlations and trends in Russia and Canada (1982–2008). *J Geophys Res Biogeosci* 116:1015.

Bertamini M, Zulini L, Muthuchelian K, Nedunchezhian N. 2006. Effect of water deficit on photosynthetic and other physiological responses in grapevine (Vitis vinifera L. cv. Riesling) plants. *Photosynthetica* 44:151–154.

Birth GS, McVey GR. 1968. Measuring the Color of Growing Turf with a Reflectance Spectrophotometer. *Agron J* 60:640–643.

Blackburn GA. 2007. Hyperspectral remote sensing of plant pigments. *J Exp Bot* 58:855–867.

Boulent J, St-Charles PL, Foucher S, Théau J. 2020. Automatic Detection of Flavescence Dorée Symptoms Across White Grapevine Varieties Using Deep Learning. *Front Artif Intell* 3:564878.

Born M, Wolf E. 2013. *Principles of optics: electromagnetic theory of propagation, interference and diffraction of light.* Cambridge University Press, Cambridge.

Bowers SA, Hanks RJ. 1971. Reflection of radiant energy from soils. *Soil Sci* 2:130–138

Bowyer P, Danson FM. 2004. Sensitivity of spectral reflectance to variation in live fuel moisture content at leaf and canopy level. *Remote Sens Environ* 92:297–308.

Bradter U, O'Connell J, Kunin WE, Boffey CWH, Ellis RJ, Benton TG. 2020. Classifying grass-dominated habitats from remotely sensed data: The influence of spectral resolution, acquisition time and the vegetation classification system on accuracy and thematic resolution. *Science of The Total Environment* 711:134584.

Bremer DJ, Lee H, Su K, Keeley SJ. 2011. Relationships between Normalized Difference Vegetation Index and Visual Quality in Cool-Season Turfgrass: I. Variation among Species and Cultivars. *Crop Sci* 51:2212–2218.

Brook A, de Micco V, Battipaglia G, Erbaggio A, Ludeno G, Catapano I, Bonfante A. 2020. A smart multiple spatial and temporal resolution system to support precision agriculture from satellite images: Proof of concept on Aglianico vineyard. *Remote Sens Environ* 240:111679.

Brownson JRS. 2014. *Laws of Light. Solar Energy Conversion Systems*. Academic Press, Cambridge 1:41–66.

Bruez E, Larignon P, Bertsch C, Robert-Siegwald G, Lebrun M-H, Rey P, Fontaine F. 2021. Impacts of Sodium Arsenite on Wood Microbiota of Esca-Diseased Grapevines. *Journal of Fungi* 7:498.

Bruning B, Berger B, Lewis M, Liu H, Garnett T. 2020. Approaches, applications, and future directions for hyperspectral vegetation studies: An emphasis on yield-limiting factors in wheat. The Plant Phenome Journal 3:e20007.

Brunori E, Maesano M, Moresi FV, Antolini A, Bellincontro A, Forniti R, Biasi R, Mencarelli F. 2020. Using UAV-based remote sensing to assess grapevine canopy damage due to fire smoke. *J Sci Food Agric* 100:4531–4539.

Bulcock HH, Jewitt GPW. 2010. Spatial mapping of leaf area index using hyperspectral remote sensing for hydrological applications with a particular focus on canopy interception. *Hydrol Earth Syst Sci* 14:383–392.

Burkart A, Hecht VL, Kraska T, Rascher U. 2018. Phenological analysis of unmanned aerial vehicle based time series of barley imagery with high temporal resolution. *Precis Agric* 19:134–146.

Ray TW. 1994. *A FAQ on Vegetation in Remote Sensing. Division of Geological and Planetary Sciences, California Institute of Technology.* Consultato il 6 febbraio 2023 da

http://www.remote-sensing.info/wp-content/uploads/2012/07/A_FAQ_on_Vegetation_in_Remote_Sensing.pdf.

Calamita F, Imran HA, Vescovo L, Mekhalfi ML, la Porta N. 2021. Early identification of root rot disease by using hyperspectral reflectance: the case of pathosystem grapevine/armillaria. *Remote Sensing* 13:2436.

Calderón R, Navas-Cortés JA, Zarco-Tejada PJ. 2015. Early Detection and Quantification of Verticillium Wilt in Olive Using Hyperspectral and Thermal Imagery over Large Areas. *Remote Sensing* 7:5584–5610.

Calzarano F, Osti F, Baranek M, Di Marco S. 2018. Rainfall and temperature influence expression of foliar symptoms of grapevine leaf stripe disease (esca complex) in vineyards. *Phytopathologia Mediterranea* 57:488–505.

Campbell J, Wynne R. 2011. *Introduction to remote sensing*, 5th ed. Guilford press, New York 1:3–28.

Campos J, García-Ruíz F, Gil E. 2021. Assessment of Vineyard Canopy Characteristics from Vigour Maps Obtained Using UAV and Satellite Imagery. *Sensors* 21:2363.

Candiago S, Remondino F, de Giglio M, Dubbini M, Gattelli M. 2015. Evaluating Multispectral Images and Vegetation Indices for Precision Farming Applications from UAV Images. *Remote Sensing* 7:4026–4047.

Carter GA. 1993. Responses of Leaf Spectral Reflectance to Plant Stress. *Am J Bot* 80:239–243.

Carter GA, Knapp AK. 2001. Leaf optical properties in higher plants: linking spectral characteristics to stress and chlorophyll concentration. *Am J Bot* 88:677–684.

de Castro AI, Ehsani R, Ploetz R, Crane JH, Abdulridha J. 2015. Optimum spectral and geometric parameters for early detection of laurel wilt disease in avocado. *Remote Sens Environ* 171:33–44.

Chang CW, Laird DA, Mausbach MJ, Hurburgh CR. 2001. Near-Infrared Reflectance Spectroscopy–Principal Components Regression Analyses of Soil Properties. *Soil Science Society of America Journal* 65:480–490.

Chaves MM, Pereira JS, Maroco J, Rodrigues ML, Ricardo CPP, Osório ML, Carvalho I, Faria T, Pinheiro C. 2002. How Plants Cope with Water Stress in the Field? Photosynthesis and Growth. *Ann Bot* 89:907–916.

Chen T, Zhang J, Chen Y, Wan S, Zhang L. 2019. Detection of peanut leaf spots disease using canopy hyperspectral reflectance. *Comput Electron Agric* 156:677–683.

Clevers JGPW, Kooistra L, Schaepman ME. 2008. Using spectral information from the NIR water absorption features for the retrieval of canopy water content. *International Journal of Applied Earth Observation and Geoinformation* 10:388–397.

Clevers JGPW, Kooistra L, Schaepman ME. 2010. Estimating canopy water content using hyperspectral remote sensing data. *International Journal of Applied Earth Observation and Geoinformation* 12:119–125.

Cogato A, Pagay V, Marinello F, Meggio F, Grace P, Migliorati MDA. 2019. Assessing the Feasibility of Using Sentinel-2 Imagery to Quantify the Impact of Heatwaves on Irrigated Vineyards. *Remote Sensing* 11:2869

Cogato A, Jewan SYY, Wu L, Marinello F, Meggio F, Sivilotti P, Sozzi M, Pagay V. 2022. Water Stress Impacts on Grapevines (Vitis vinifera L.) in Hot Environments: Physiological and Spectral Responses. *Agronomy* 12:1819.

Colombo R, Bellingeri D, Fasolini D, Marino CM. 2003. Retrieval of leaf area index in different vegetation types using high resolution satellite data. *Remote Sens Environ* 86:120–131.

Combal B, Baret F, Weiss M, Trubuil A, Macé D, Pragnère A, Myneni R, Knyazikhin Y, Wang L. 2003. Retrieval of canopy biophysical variables from bidirectional reflectance: Using prior information to solve the ill-posed inverse problem. *Remote Sens Environ* 84:1–15.

Costa L, Nunes L, Ampatzidis Y. 2020. A new visible band index (vNDVI) for estimating NDVI values on RGB images utilizing genetic algorithms. *Comput Electron Agric* 172:105334.

Courel MF, Chamard P, Guenegou MJ, Lerhun J, Levasseur M, Togola M. 1991. *Utilisation des bandes spectrales du vert et du rouge pour une meilleure évaluation des formations végétales actives. In Proceedings of the Congrès AUPELF-UREF*. Sherbrooke, QC, Canada, 21–23 ottobre 1991 1:203–210.

Croft H, Chen JM, Zhang Y, Simic A, Noland TL, Nesbitt N, Arabian J. 2015. Evaluating leaf chlorophyll content prediction from multispectral remote sensing data within a physically-based modelling framework. *ISPRS Journal of Photogrammetry and Remote Sensing* 102:85–95.

Cruz A, Ampatzidis Y, Pierro R, Materazzi A, Panattoni A, de Bellis L, Luvisi A. 2019. Detection of grapevine yellows symptoms in Vitis vinifera L. with artificial intelligence. *Comput Electron Agric* 157:63–76.

Curran PJ, Dungan JL, Macler BA, Plummer SE, Peterson DL. 1992. Reflectance spectroscopy of fresh whole leaves for the estimation of chemical concentration. *Remote Sens Environ* 39:153–166.

Daglio G, Cesaro P, Todeschini V, Lingua G, Lazzari M, Berta G, Massa N. 2022. Potential field detection of Flavescence dorée and Esca diseases using a ground sensing optical system. *Biosyst Eng* 215:203–214.

Datt B, McVicar TR, van Niel TG, Jupp DLB, Pearlman JS. 2003. Preprocessing EO-1 Hyperion hyperspectral data to support the application of agricultural indexes. *IEEE Transactions on Geoscience and Remote Sensing* 41:1246–1259.

Daughtry CST, Walthall CL, Kim MS, de Colstoun EB, McMurtrey JE. 2000. Estimating Corn Leaf Chlorophyll Concentration from Leaf and Canopy Reflectance. *Remote Sens Environ* 74:229–239.

Dave JV. 1980. Effect of Atmospheric Conditions on Remote sensing of a Surface Non homogeneity. *Photogrammetric Engineering and Remote Sensing* 46:1173-1180.

Dawson TP, Curran PJ, Plummer SE. 2010. The biochemical decomposition of slash pine needles from reflectance spectra using neural networks. *International Journal of Remote Sensing* 19:1433–1438.

Defries RS, Townshend JR. 2007. NDVI-derived land cover classifications at a global scale. *International journal of remote sensing* 15:3567–3586.

Delegido J, Verrelst J, Meza CM, Rivera JP, Alonso L, Moreno J. 2013. A red-edge spectral index for remote sensing estimation of green LAI over agroecosystems. *European Journal of Agronomy* 46:42–52.

Demmig-Adams B, Adams WW, Barker DH, Logan BA, Bowling DR, Verhoeven AS. 1996. Using chlorophyll fluorescence to assess the fraction of absorbed light allocated to thermal dissipation of excess excitation. *Physiol Plant* 98:253–264.

Dewasme C, Mary S, Darrieutort G, Roby JP, Gambetta GA. 2022. Long-term esca monitoring reveals disease impacts on fruit yield and wine quality. *Plant Disease*, 106:3076-3082.

D'Oliveira FA, de Melo FCL, Devezas TC. 2016. High-Altitude Platforms — Present Situation and Technology Trends. *Journal of Aerospace Technology and Management* 8:249–262.

Duffy JP, Cunliffe AM, DeBell L, Sandbrook C, Wich SA, Shutler JD, Myers-Smith IH, Varela MR, Anderson K. 2018. Location, location, location: considerations when using lightweight drones in challenging environments. *Remote Sens Ecol Conserv* 4:7–19.

Eitel JUH, Long DS, Gessler PE, Hunt ER. 2008. Combined Spectral Index to Improve Ground-Based Estimates of Nitrogen Status in Dryland Wheat. *Agron J* 100:1694–1702.

Eitel JUH, Keefe RF, Long DS, Davis AS, Vierling LA. 2010. Active Ground Optical Remote Sensing for Improved Monitoring of Seedling Stress in Nurseries. *Sensors* 10:2843–2850.

Eitel JUH, Vierling LA, Litvak ME, Long DS, Schulthess U, Ager AA, Krofcheck DJ, Stoscheck L. 2011. Broadband, red-edge information from satellites improves early stress detection in a New Mexico conifer woodland. *Remote Sens Environ* 115:3640–3646.

Elachi C, Van Zyl. 2021. *Introduction to the physics and techniques of remote sensing*, 3rd ed. John Wiley & Sons, New York, NY, USA 1:19-43.

ESA - *Eduspace IT - Home - Firme spettrali*. Consultato il 7 agosto 2022 da https://www.esa.int/SPECIALS/Eduspace_IT/SEMT8VZRA0G_0.html.

Eskling M, Arvidsson P-O, Åkerlund H-E. 1997. The xanthophyll cycle, its regulation and components. *Physiol Plant* 100:806–816.

Fabiyi SD, Vu H, Tachtatzis C, Murray P, Harle D, Dao TK, Andonovic I, Ren J, Marshall S. 2020. Varietal Classification of Rice Seeds Using RGB and Hyperspectral Images. *IEEE Access* 8:22493–22505.

Fabiyi SD, Murray P, Zabalza J, Ren J. 2021. Folded LDA: Extending the Linear Discriminant Analysis Algorithm for Feature Extraction and Data Reduction in Hyperspectral Remote Sensing. *IEEE J Sel Top Appl Earth Obs Remote Sens* 14:12312–12331.

Farrell MD, Mersereau RM. 2005. On the impact of PCA dimension reduction for hyperspectral detection of difficult targets. *IEEE Geoscience and Remote Sensing Letters* 2:192–195.

Filella I, Peñuelas J. 2007. The red edge position and shape as indicators of plant chlorophyll content, biomass and hydric status. *International journal of remote sensing* 15:1459–1470.

Finger R, Swinton SM, El Benni N, Walter A. 2019. Precision farming at the nexus of agricultural production and the environment. *Annual Review of Resource Economics* 11:313-335.

Fiorucci F, Giordan D, Santangelo M, Dutto F, Rossi M, Guzzetti F. 2018. Criteria for the optimal selection of remote sensing optical images to map event landslides. *Natural Hazards and Earth System Sciences* 18:405–417.

Flexas J, Bota J, Escalona JM, Sampol B, Medrano H. 2002. Effects of drought on photosynthesis in grapevines under field conditions: an evaluation of stomatal and mesophyll limitations. *Functional Plant Biology* 29:461–471.

Folkman MA, Pearlman J, Liao LB, Jarecke PJ. 2001. EO-1/Hyperion hyperspectral imager design, development, characterization, and calibration. *Hyperspectral Remote Sensing of the Land and Atmosphere* 4151:40–51.

Fontaine F, Pinto C, Vallet J, Clément C, Gomes AC, Spagnolo A. 2016. The effects of grapevine trunk diseases (GTDs) on vine physiology. Eur J Plant Pathol 144:707–721.

Foody GM, Boyd DS, Cutler MEJ. 2003. Predictive relations of tropical forest biomass from Landsat TM data and their transferability between regions. *Remote Sens Environ* 85:463–474.

Furukawa F, Laneng LA, Ando H, Yoshimura N, Kaneko M, Morimoto J. 2021. Comparison of RGB and Multispectral Unmanned Aerial Vehicle for Monitoring Vegetation Coverage Changes on a Landslide Area. *Drones* 5:97.

Gago J, Douthe C, Coopman RE, Gallego PP, Ribas-Carbo M, Flexas J, Escalona J, Medrano H. 2015. UAVs challenge to assess water stress for sustainable agriculture. *Agric Water Manag* 153:9–19.

Galvão LS, Roberts DA, Formaggio AR, Numata I, Breunig FM. 2009. View angle effects on the discrimination of soybean varieties and on the relationships between vegetation indices and yield using off-nadir Hyperion data. *Remote Sens Environ* 113:846–856.

Galvão LS, Breunig FM, dos Santos JR, de Moura YM. 2013. View-illumination effects on hyperspectral vegetation indices in the Amazonian tropical forest. *International Journal of Applied Earth Observation and Geoinformation* 21:291–300.

Gamon JA, Peñuelas J, Field CB. 1992. A narrow-waveband spectral index that tracks diurnal changes in photosynthetic efficiency. *Remote Sens Environ* 41:35–44.

Gamon JA, Somers B, Malenovský Z, Middleton EM, Rascher U, Schaepman ME. 2019. Assessing Vegetation Function with Imaging Spectroscopy. *Surv Geophys* 40:489–513.

Gao BC. 1996. NDWI—A normalized difference water index for remote sensing of vegetation liquid water from space. *Remote Sens Environ* 58:257–266.

García JA, Garrido I, Ortega A, del Moral J, Llerena JL, Espinosa F. 2022. Physiological and Molecular Responses of Vitis vinifera cv. Tempranillo Affected by Esca Disease. *Antioxidants* 11:1720.

Garg PK. 2020. Effect of contamination and adjacency factors on snow using spectroradiometer and hyperspectral images. In: P. C. Pandey, P. K. Srivastava, H. Balzter, B. Bhattacharya, & G. P. Petropoulos (Eds.), *Hyperspectral Remote Sensing: Theory and Applications*. Elsevier 1:167– 196.

Garini Y, Young IT, McNamara G. 2006. Spectral imaging: Principles and applications. *Cytometry Part A* 69:735–747.

Gausman HW. Leaf Reflectance of Near-lnfrared. 1974. *Photogram Eng* 40:183–191.

di Gennaro SF, Battiston E, di Marco S, Facini O, Matese A, Nocentini M, Palliotti A, Mugnai L. 2016. Unmanned Aerial Vehicle (UAV)-based remote sensing to monitor grapevine leaf stripe disease within a vineyard affected by esca complex. *Phytopathol Mediterr* 55:262–275.

Giovos R, Tassopoulos D, Kalivas D, Lougkos N, Priovolou A. 2021. Remote Sensing Vegetation Indices in Viticulture: A Critical Review. *Agriculture* 11:457.

Gil-Perez B, Zarco-Tejada PJ, Correa-Guimaraes A, Relea-Gangas E, Navas-Gracia LM, Hernadez-Navarro S, Sans-Requena JF, Berjon A, Martin-Gil J. 2010. Remote sensing detection of nutrient uptake in vineyards using narrow-band hyperspectral imagery. Valladolid. *Vitis* 49:167–173.

Girona J, Mata M, del Campo J, Arbonés A, Bartra E, Marsal J. 2006. The use of midday leaf water potential for scheduling deficit irrigation in vineyards. *Irrig Sci* 24:115–127.

Gitelson AA, Kaufman YJ, Merzlyak MN. 1996. Use of a green channel in remote sensing of global vegetation from EOS-MODIS. *Remote Sens Environ* 58:289–298.

Gitelson AA, Keydan GP, Merzlyak MN. 2006. Three-band model for noninvasive estimation of chlorophyll, carotenoids, and anthocyanin contents in higher plant leaves. *Geophys Res Lett* 33:11.

Gitelson AA, Peng Y, Arkebauer TJ, Schepers J. 2014. Relationships between gross primary production, green LAI, and canopy chlorophyll content in maize: Implications for remote sensing of primary production. *Remote Sens Environ* 144:65–72.

Goel NS, Qin W. 1994. Influences of canopy architecture on relationships between various vegetation indices and LAI and Fpar: A computer simulation. *Remote Sensing Reviews* 10:309–347.

Gómez-Candón D, de Castro AI, López-Granados F. 2014. Assessing the accuracy of mosaics from unmanned aerial vehicle (UAV) imagery for precision agriculture purposes in wheat. *Precis Agric* 15:44–56.

Goswami S, Gamon J, Vargas S, Tweedie C. 2015. Relationships of NDVI, Biomass, and Leaf Area Index (LAI) for six key plant species in Barrow, Alaska. *PeerJ* 3:e911v1.

Gracia-Romero A, Kefauver SC, Vergara-Díaz O, Zaman-Allah MA, Prasanna BM, Cairns JE, Araus JL. 2017. Comparative performance of ground vs. Aerially assessed rgb and multispectral indices for early-growth evaluation of maize performance under phosphorus fertilization. *Front Plant Sci* 8:2004.

Green RO, Eastwood ML, Sarture CM, Chrien TG, Aronsson M, Chippendale BJ, Faust JA, Pavri BE, Chovit CJ, Solis M, et al. 1998. Imaging Spectroscopy and the Airborne Visible/Infrared Imaging Spectrometer (AVIRIS). *Remote Sens Environ* 65:227–248.

Guan X, Essakhi S, Laloue H, Nick P, Bertsch C, Chong J. 2016. Mining new resources for grape resistance against Botryosphaeriaceae: a focus on Vitis vinifera subsp. sylvestris. *Plant Pathol* 65:273–284.

Guerin-Dubrana L, Fontaine F, Mugnai L. 2019. Grapevine trunk disease in European and Mediterranean vineyards: Occurrence, distribution and associated disease-affecting cultural factors. *Phytopathol Mediterr* 58:49–71.

Haboudane D, Miller JR, Tremblay N, Zarco-Tejada PJ, Dextraze L. 2002. Integrated narrow-band vegetation indices for prediction of crop chlorophyll content for application to precision agriculture. *Remote Sens Environ* 81:416–426.

Haboudane D, Miller JR, Pattey E, Zarco-Tejada PJ, Strachan IB. 2004. Hyperspectral vegetation indices and novel algorithms for predicting green LAI of crop canopies: Modeling and validation in the context of precision agriculture. *Remote Sens Environ* 90:337–352.

Hadizadeh M, Rahnama M, Adine Poor H, Hesari B, Kazemi M. 2020. The comparison between remotely-sensed vegetation indices of Meteosat second generation satellite and temperature-based agrometeorological indices for monitoring of main crops in the northeast of Iran. *Arabian Journal of Geosciences* 13:1-13.

Hadjimitsis DG, Papadavid G, Agapiou A, Themistocleous K, Hadjimitsis MG, Retalis A, Michaelides S, Chrysoulakis N, Toulios L, I. Clayton CR. 2010. Atmospheric correction for satellite remotely sensed data intended for agricultural applications: impact on vegetation indices. *Natural Hazards and Earth System Sciences* 10:89–95.

Halme E, Pellikka P, Mõttus M. 2019. Utility of hyperspectral compared to multispectral remote sensing data in estimating forest biomass and structure variables in Finnish boreal forest. *International Journal of Applied Earth Observation and Geoinformation* 83:101942.

Hansen PM, Schjoerring JK. 2003. Reflectance measurement of canopy biomass and nitrogen status in wheat crops using normalized difference vegetation indices and partial least squares regression. *Remote Sens Environ* 86:542–553.

Hashimoto N, Saito Y, Maki M, Homma K. 2019. Simulation of Reflectance and Vegetation Indices for Unmanned Aerial Vehicle (UAV) Monitoring of Paddy Fields. *Remote Sensing* 11:2119.

Hatfield JL, Gitelson AA, Schepers JS, Walthall CL. 2008. Application of Spectral Remote Sensing for Agronomic Decisions. *Agron J* 257:117 –131.

Hatfield JL, Prueger JH, Sauer TJ, Dold C, O'brien P, Wacha K. 2019. Applications of Vegetative Indices from Remote Sensing to Agriculture: Past and Future. *Inventions* 4:71.

Hectors K, Prinsen E, de Coen W, Jansen MAK, Guisez Y. 2007. Arabidopsis thaliana plants acclimated to low dose rates of ultraviolet B radiation show specific changes in morphology and gene expression in the absence of stress symptoms. *New Phytologist* 175:255–270.

Hendry GA, Houghton JD, Brown SB. 1987. Tansley Review No. 11. The degradation of chlorophyll-A biological enigma. *New phytologist* 107:255–302.

Hmimina G, Dufrêne E, Pontailler JY, Delpierre N, Aubinet M, Caquet B, de Grandcourt A, Burban B, Flechard C, Granier A, et al. 2013. Evaluation of the potential of MODIS satellite data to predict vegetation phenology in different biomes: An investigation using ground-based NDVI measurements. *Remote Sens Environ* 132:145–158.

Hmimina G, Merlier E, Dufrêne E, Soudani K. 2015. Deconvolution of pigment and physiologically related photochemical reflectance index variability at the canopy scale over an entire growing season. *Plant Cell Environ* 38:1578–1590.

Hoff RM, Christopher SA. 2012. Remote Sensing of Particulate Pollution from Space: Have We Reached the Promised Land? *Journal of the Air & Waste Management Association* 59:645–675.

Horler DNH, Dockray M, Barber J. 2007. The red edge of plant leaf reflectance. *International journal of remote sensing* 4:273–288.

Horvath H. 1993. Atmospheric light absorption—A review. *Atmospheric Environment Part A General Topics* 27:293–317.

Hossain A, Jia Y, Chao X. 2010. Development of Remote Sensing Based Index for Estimating/Mapping Suspended Sediment Concentration in River and Lake Environments. In: *Proceedings of 8th international symposium on Ecohydraulics (ISE 2010), Seoul, Corea, 12–16 settembre* 435:578–585.

Hsu KL, Gupta HV, Sorooshian S. 1995. Artificial Neural Network Modeling of the Rainfall-Runoff Process. *Water Resour Res* 31:2517–2530.

Hsu PH. 2007. Feature extraction of hyperspectral images using wavelet and matching pursuit. *ISPRS Journal of Photogrammetry and Remote Sensing* 62:78–92.

Huang H, Liu L, Ngadi MO. 2014. Recent Developments in Hyperspectral Imaging for Assessment of Food Quality and Safety. *Sensors* 14:7248–7276.

Huang S, Tang L, Hupy JP, Wang Y, Shao G. 2021. A commentary review on the use of normalized difference vegetation index (NDVI) in the era of popular remote sensing. *J For Res* 32:1–6.

Huang Y, Chen ZX, Tao YU, Huang XZ, Gu XF. 2018. Agricultural remote sensing big data: Management and applications. *J Integr Agric* 17:1915–1931.

Huete A, Didan K, Miura T, Rodriguez EP, Gao X, Ferreira LG. 2002. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. *Remote Sens Environ* 83:195–213.

Huete A. 1988. A soil-adjusted vegetation index (SAVI). *Remote Sens Environ* 25:295–309.

Hughes GF. 1968. On the Mean Accuracy of Statistical Pattern Recognizers. *IEEE Trans Inf Theory* 14:55–63.

Hunt ER, Daughtry CST. 2017. What good are unmanned aircraft systems for agricultural remote sensing and precision agriculture? *International journal of remote sensing* 39:5345–5376.

IDB - *Index DataBase*. Consultato il 3 ottobre 2022 da https://www.indexdatabase.de/.

Ihuoma SO, Madramootoo CA. 2017. Recent advances in crop water stress detection. *Comput Electron Agric* 141:267–275.

Jackson RD, Huete AR. 1991. Interpreting vegetation indices. *Prev Vet Med* 11:185–200.

Jacquemoud S, Bacour C, Poilvé H, Frangi JP. 2000. Comparison of Four Radiative Transfer Models to Simulate Plant Canopies Reflectance: Direct and Inverse Mode. *Remote Sens Environ* 74:471–481.

Jain N, Ray SS, Singh JP, Panigrahy S. 2007. Use of hyperspectral data to assess the effects of different nitrogen applications on a potato crop. *Precis Agric* 8:225–239.

Jensen D, Simard M, Cavanaugh K, Sheng Y, Fichot CG, Pavelsky T, Twilley R. 2019. Improving the Transferability of Suspended Solid Estimation in Wetland and Deltaic Waters with an Empirical Hyperspectral Approach. *Remote Sensing* 11:1629.

Jia B, Wang W, Ni X, Lawrence KC, Zhuang H, Yoon SC, Gao Z. 2020. Essential processing methods of hyperspectral images of agricultural and food products. *Chemometrics and Intelligent Laboratory Systems* 198:103936.

Jiménez-Brenes FM, López-Granados F, Torres-Sánchez J, Peña JM, Ramírez P, Castillejo-González IL, de Castro AI. 2019. Automatic UAV-based detection of Cynodon dactylon for site-specific vineyard management. P*LoS One* 14:e218132.

Jin X, Li Z, Atzberger C. 2020. Editorial for the Special Issue "Estimation of Crop Phenotyping Traits using Unmanned Ground Vehicle and Unmanned Aerial Vehicle Imagery." *Remote Sensing* 12:940.

Jones H, Vaughan R. 2010. *Remote sensing of vegetation: principles, techniques, and applications*. Oxford University Press, New York, NY, USA.

Jordan CF. 1969. Derivation of Leaf-Area Index from Quality of Light on the Forest Floor. *Ecology* 50:663–666.

Joshi, Chandra P. 2011. Performance evaluation of vegetation indices using remotely sensed data. *International Journal of Geomatics and Geosciences* 2:231–240.

Junges AH, Ducati JR, Scalvi Lampugnani C, Almança MAK. 2018. Detection of grapevine leaf stripe disease symptoms by hyperspectral sensor. *Phytopathol Mediterr* 57:399–406.

Junges AH, Almança MAK, Fajardo TVM, Ducati JR. 2020. Leaf hyperspectral reflectance as a potential tool to detect diseases associated with vineyard decline. *Trop Plant Pathol* 45:522–533.

Junqueira AM, Mao F, Mendes TSG, Simões SJC, Balestieri JAP, Hannah DM. 2021. Estimation of river flow using CubeSats remote sensing. *Science of The Total Environment* 788:147762.

Kandylakis Z, Karantzalos K. Precision Viticulture from Multitemporal, Multispectral Very High Resolution Satellite Data. *In Proceedings of the XXIII ISPRS Congress. Praga, Repubblica Ceca*, *12–19 Luglio 2016* 1:919-925

Kattenborn T, Fassnacht FE, Schmidtlein S. 2019. Differentiating plant functional types using reflectance: which traits make the difference? *Remote Sens Ecol Conserv* 5:5–19.

Kaur S, Bansal RK, Mittal M, Goyal LM, Kaur I, Verma A, Son LH. 2019. Mixed Pixel Decomposition Based on Extended Fuzzy Clustering for Single Spectral Value Remote Sensing Images. *Journal of the Indian Society of Remote Sensing* 47:427–437.

Kemp W. 1991. Energy and the Electromagnetic Spectrum. In: *Organic Spectroscopy*. Macmillan Press, Palgrave London, UK 1–17.

Kerkech M, Hafiane A, Canals R. 2018. Deep leaning approach with colorimetric spaces and vegetation indices for vine diseases detection in UAV images. *Comput Electron Agric* 155:237–243.

King BA, Shellie KC. 2016. Evaluation of neural network modeling to predict non-water-stressed leaf temperature in wine grape for calculation of crop water stress index. *Agric Water Manag* 167:38–52.

Kira O, Linker R, Gitelson A. 2015. Non-destructive estimation of foliar chlorophyll and carotenoid contents: Focus on informative spectral bands. *International Journal of Applied Earth Observation and Geoinformation* 38:251–260.

Kira O, Nguy-Robertson AL, Arkebauer TJ, Linker R, Gitelson AA. 2016. Informative spectral bands for remote green LAI estimation in C3 and C4 crops. *Agric For Meteorol* 218–219:243–249.

Knipling EB. 1970. Physical and physiological basis for the reflectance of visible and near-infrared radiation from vegetation. *Remote Sens Environ* 1:155–159.

Knipper KR, Kustas WP, Anderson MC, Alsina MM, Hain CR, Alfieri JG, Prueger JH, Gao F, McKee LG, Sanchez LA. 2019. Using High-Spatiotemporal Thermal Satellite ET Retrievals for Operational Water Use and Stress Monitoring in a California Vineyard. *Remote Sensing* 11:2124.

Knyazikhin Y, Schull MA, Stenberg P, Mõttus M, Rautiainen M, Yang Y, Marshak A, Carmona PL, Kaufmann RK, Lewis P, Disney MI, Vanderbilt V, Davis AB, Baret F, Jacquemoud S, Lyapustin A, Myneni RB. 2013. Hyperspectral remote sensing of foliar nitrogen content. *Proc. Natl Acad. Sci. USA* 110:E185–E192.

Korzukhin MD, Ter-Mikaelian MT, Wagner RG. 2011. Process versus empirical models: which approach for forest ecosystem management? *Canadian Journal of Forest Research* 26:879–887.

Kuparinen A. 2006. Mechanistic models for wind dispersal. *Trends Plant Sci* 11:296–301.

Lamb DW. 2001. Airborne remote sensing of vines for canopy variability and productivity. *Australian Grapegrower and Winemaker* 449a:89– 92.

Leblon B, Gallant L, Granberg H. 1996. Effects of shadowing types on ground-measured visible and near-infrared shadow reflectances. *Remote Sens Environ* 58:322–328.

Lechner AM, Foody GM, Boyd DS. 2020. Applications in Remote Sensing to Forest Ecology and Management. *One Earth* 2:405–412.

Lee KS, Cohen WB, Kennedy RE, Maiersperger TK, Gower ST. 2004. Hyperspectral versus multispectral data for estimating leaf area index in four different biomes. *Remote Sens Environ* 91:508–520.

Lelong CCD, Burger P, Jubelin G, Roux B, Labbé S, Baret F. 2008. Assessment of Unmanned Aerial Vehicles Imagery for Quantitative Monitoring of Wheat Crop in Small Plots. *Sensors* 8:3557–3585.

Li L, Zhang Q, Huang D. 2014. A Review of Imaging Techniques for Plant Phenotyping. *Sensors* 14:20078–20111.

Lichtenthaler HK, Buschmann C. 2001. Chlorophylls and Carotenoids: Measurement and Characterization by UV-VIS Spectroscopy. *Current Protocols in Food Analytical Chemistry* 1:F4.3.1-F4.3.8.

Liu H, Bruning B, Garnett T, Berger B. 2020. Hyperspectral imaging and 3D technologies for plant phenotyping: From satellite to close-range sensing. *Comput Electron Agric* 175:105621.

Lopatin J, Fassnacht FE, Kattenborn T, Schmidtlein S. 2017. Mapping plant species in mixed grassland communities using close range imaging spectroscopy. *Remote Sens Environ* 201:12–23.

López-García P, Intrigliolo DS, Moreno MA, Martínez-Moreno A, Ortega JF, Pérez-álvarez EP, Ballesteros R. 2021. Assessment of Vineyard Water Status by Multispectral and RGB Imagery Obtained from an Unmanned Aerial Vehicle. *Am J Enol Vitic* 72:285–297.

Maes WH, Steppe K. 2019. Perspectives for Remote Sensing with Unmanned Aerial Vehicles in Precision Agriculture. *Trends Plant Sci* 24:152–164.

Magnin-Robert M, Letousey P, Spagnolo A, Rabenoelina F, Jacquens L, Mercier L, Cĺment C, Fontaine F. 2011. Leaf stripe form of esca induces alteration of photosynthesis and defence reactions in presymptomatic leaves. *Functional Plant Biology* 38:856–866.

Mahlein AK. 2016. Plant disease detection by imaging sensors – Parallels and specific demands for precision agriculture and plant phenotyping. *Plant Dis* 100:241–254.

Mahlein AK, Steiner U, Dehne HW, Oerke EC. 2010. Spectral signatures of sugar beet leaves for the detection and differentiation of diseases. *Precis Agric* 11:413–431.

Maimaitiyiming M, Ghulam A, Bozzolo A, Wilkins JL, Kwasniewski MT. 2017. Early Detection of Plant Physiological Responses to Different Levels of Water Stress Using Reflectance Spectroscopy. *Remote Sensing* 9:745.

Mao ZH, Deng L, Duan FZ, Li XJ, Qiao DY. 2020. Angle effects of vegetation indices and the influence on prediction of SPAD values in soybean and maize. *International Journal of Applied Earth Observation and Geoinformation* 93:102198.

Mariotto I, Thenkabail PS, Huete A, Slonecker ET, Platonov A. 2013. Hyperspectral versus multispectral crop-productivity modeling and type discrimination for the HyspIRI mission. *Remote Sens Environ* 139:291–305.

Martos V, Ahmad A, Cartujo P, Ordoñez J. 2021. Ensuring Agricultural Sustainability through Remote Sensing in the Era of Agriculture 5.0. *Applied Sciences* 11:5911.

Mas Garcia S, Ryckewaert M, Abdelghafour F, Metz M, Moura D, Feilhes C, Prezman F, Bendoula R. 2021. Combination of multivariate curve resolution with factorial discriminant analysis for the detection of grapevine diseases using hyperspectral imaging. A case study: flavescence dorée. *Analyst* 146:7730–7739.

Matese A, Toscano P, di Gennaro SF, Genesio L, Vaccari FP, Primicerio J, Belli C, Zaldei A, Bianconi R, Gioli B. 2015. Intercomparison of UAV, Aircraft and Satellite Remote Sensing Platforms for Precision Viticulture. *Remote Sensing* 7:2971–2990.

Matese A, Baraldi R, Berton A, Cesaraccio C, di Gennaro SF, Duce P, Facini O, Mameli MG, Piga A, Zaldei A. 2018. Estimation of Water Stress in Grapevines Using Proximal and Remote Sensing Methods. *Remote Sensing* 10:114.

Matsushita B, Yang W, Chen J, Onda Y, Qiu G. 2007. Sensitivity of the Enhanced Vegetation Index (EVI) and Normalized Difference Vegetation Index (NDVI) to Topographic Effects: A Case Study in High-density Cypress Forest. *Sensors* 7:2636–2651.

Maxwell AE, Warner TA, Sensing FF. 2018. Implementation of machine-learning classification in remote sensing: An applied review. *International Journal of Remote Sensing* 39:2784–2817.

McCabe MF, Aragon B, Houborg R, Mascaro J. 2017. CubeSats in Hydrology: Ultrahigh-Resolution Insights Into Vegetation Dynamics and Terrestrial Evaporation. *Water Resour Res* 53:10017–10024.

McKellip R, Ryan RE, Blonski S, Prados D, Ryan RE, Blonski S, Prados D. 2005. Crop Surveillance Demonstration Using a Near-Daily MODIS Derived Vegetation Index Time Series. In: *Proc. of the 2005 International workshop on the analysis of multi-temporal remote sensing images. Biloxi, MS, USA, 16–18 May 2005; IEEE: Piscataway, NJ, USA.*

van der Meer F. 2004. Analysis of spectral absorption features in hyperspectral imagery. *International Journal of Applied Earth Observation and Geoinformation* 5:55–68.

Meneses-Tovar, C. L. 2011. NDVI as indicator of degradation. *Unasylva*, 62:39-46.

Merzlyak MN, Gitelson AA, Chivkunova OB, Rakitin VY. 1999. Non-destructive optical detection of pigment changes during leaf senescence and fruit ripening. *Physiol Plant* 106:135–141.

Meyer GE, Neto JC. 2008. Verification of color vegetation indices for automated crop imaging applications. *Comput Electron Agric* 63:282–293.

Meyer GE, Hindman TW, Laksmi K. 1999. Machine vision detection parameters for plant species identification. In: *Proceedings of the SPIE, Washington, DC, USA, 14 January 1999* 3543:327–335.

Middleton EM. 1991. Solar zenith angle effects on vegetation indices in tallgrass prairie. *Remote Sens Environ* 38:45–62.

Milas AS, Arend K, Mayer C, Simonson MA, Mackey S. 2017. Different colours of shadows: classification of UAV images. *International Journal of Remote Sensing* 38:3084–3100.

Milla KA, Lorenzo A, Brown C. 2005. GIS, GPS, and remote sensing technologies in extension services: Where to start, what to know. *Journal of extension* 43:1-8.

Mishra P, Polder G, Vilfan N. 2020. Close Range Spectral Imaging for Disease Detection in Plants Using Autonomous Platforms: a Review on Recent Studies. *Current Robotics Reports* 1:43–48.

Mohanty BP, Cosh MH, Lakshmi V, Montzka C. 2017. Soil Moisture Remote Sensing: State-of-the-Science. *Vadose Zone Journal* 16:1–9.

Mondello V, Songy A, Battiston E, Pinto C, Coppin C, Trotel-Aziz P, Clément C, Mugnai L, Fontaine F. 2018. Grapevine trunk diseases: A review of fifteen years of trials for their control with chemicals and biocontrol agents. *Plant Dis* 102:1189–1217.

Moran MS, Inoue Y, Barnes EM. 1997. Opportunities and limitations for image-based remote sensing in precision crop management. *Remote Sens Environ* 61:319–346.

Motohka T, Nasahara KN, Oguma H, Tsuchida S. 2010. Applicability of Green-Red Vegetation Index for Remote Sensing of Vegetation Phenology. *Remote Sensing* 2:2369–2387.

Moya I, Camenen L, Evain S, Goulas Y, Cerovic ZG, Latouche G, Flexas J, Ounis A. 2004. A new instrument for passive remote sensing: 1. Measurements of sunlight-induced chlorophyll fluorescence. *Remote Sens Environ* 91:186–197.

Mugnai L, Graniti A, Surico G. 1999. Esca (Black Measles) and Brown Wood-Streaking: Two Old and Elusive Diseases of Grapevines. *Plant disease* 83:404–418.

Mulla DJ. 2013. Twenty five years of remote sensing in precision agriculture: Key advances and remaining knowledge gaps. *Biosyst Eng* 114:358–371.

Mutanga O, Skidmore AK. 2004. Narrow band vegetation indices overcome the saturation problem in biomass estimation. *International journal of remote sensing* 25:3999–4014.

Nguyen C, Sagan V, Maimaitiyiming M, Maimaitijiang M, Bhadra S, Kwasniewski MT. 2021. Early Detection of Plant Viral Disease Using Hyperspectral Imaging and Deep Learning. *Sensors* 21:742.

Ojeda H, Andary C, Kraeva E, Carbonneau A, Deloire A. 2002. Influence of pre-and postveraison water deficit on synthesis and concentration of skin phenolic compounds during berry growth of Vitis vinifera cv. Shiraz. *Am Soc Enol Viticulture* 53:261-267.

Ouédraogo MM, Degré A, Debouche C, Lisein J. 2014. The evaluation of unmanned aerial system-based photogrammetry and terrestrial laser scanning to generate DEMs of agricultural watersheds. *Geomorphology* 214:339–355.

Ozdemir A, Polat K. 2020. Deep learning applications for hyperspectral imaging: a systematic review. *Journal of the Institute of Electronics and Computer* 2:39-56.

Pádua L, Marques P, Hruška J, Adão T, Bessa J, Sousa A, Peres E, Morais R, Sousa JJ. 2018. Vineyard properties extraction combining UAS-based RGB imagery with elevation data. *International Journal of Remote Sensing* 39:5377–5401.

Pastor-Guzman J, Atkinson PM, Dash J, Rioja-Nieto R. 2015. Spatiotemporal Variation in Mangrove Chlorophyll Concentration Using Landsat 8. *Remote Sensing* 7:14530–14558.

Peña JM, Torres-Sánchez J, Serrano-Pérez A, de Castro AI, López-Granados F. 2015. Quantifying Efficacy and Limits of Unmanned Aerial Vehicle (UAV) Technology for Weed Seedling Detection as Affected by Sensor Resolution. *Sensors* 15:5609–5626.

Peña-Barragán JM, Ngugi MK, Plant RE, Six J. 2011. Object-based crop identification using multiple vegetation indices, textural features and crop phenology. *Remote Sens Environ* 115:1301–1316.

Peñuelas J, Gamon JA, Griffin KL, Field CB. 1993. Assessing community type, plant biomass, pigment composition, and photosynthetic efficiency of aquatic vegetation from spectral reflectance. *Remote Sens Environ* 46:110–118.

Penuelas J, Filella I, Biel C, Serrano L, Save R. 1993. The reflectance at the 950–970 nm region as an indicator of plant water status. *International journal of remote sensing* 14:1887–1905.

Pérez-Roncal C, Arazuri S, Lopez-Molina C, Jarén C, Santesteban LG, López-Maestresalas A. 2022. Exploring the potential of hyperspectral imaging to detect Esca disease complex in asymptomatic grapevine leaves. *Comput Electron Agric* 196:106863.

Petit AN, Vaillant N, Boulay M, Clément C, Fontaine F. 2006. Alteration of Photosynthesis in Grapevines Affected by Esca. *Phytopathology* 96:1060–1066.

Petri CA, Galvão LS. 2019. Sensitivity of Seven MODIS Vegetation Indices to BRDF Effects during the Amazonian Dry Season. *Remote Sensing* 11:1650.

Poblete T, Ortega-Farías S, Moreno MA, Bardeen M. 2017. Artificial Neural Network to Predict Vine Water Status Spatial Variability Using Multispectral Information Obtained from an Unmanned Aerial Vehicle (UAV). *Sensors* 17:2488.

Pôças I, Rodrigues A, Gonçalves S, Costa PM, Gonçalves I, Pereira LS, Cunha M. 2015. Predicting Grapevine Water Status Based on Hyperspectral Reflectance Vegetation Indices. *Remote Sensing* 7:16460–16479.

Poley LG, McDermid GJ. 2020. A Systematic Review of the Factors Influencing the Estimation of Vegetation Aboveground Biomass Using Unmanned Aerial Systems. *Remote Sensing* 12:1052.

Poncet AM, Knappenberger T, Brodbeck C, Fogle M, Shaw JN, Ortiz BV. 2019. Multispectral UAS Data Accuracy for Different Radiometric Calibration Methods. *Remote Sensing* 11:1917.

Potopová V, Trnka M, Hamouz P, Soukup J, Castraveț T. 2020. Statistical modelling of drought-related yield losses using soil moisture-vegetation remote sensing and multiscalar indices in the south-eastern Europe. *Agric Water Manag* 236:106168.

Primicerio J, Gay P, Aimonino DR, Comba L, Matese A, di Gennaro SF. 2015. NDVI-based vigour maps production using automatic detection of vine rows in ultra-high resolution aerial images. In: *10th European Conference on Precision Agriculture* 1:465–470.

Psirofonia P, Samaritakis V, Eliopoulos P, Potamitis I. 2017. Use of Unmanned Aerial Vehicles for Agricultural Applications with Emphasis on Crop Protection: Three Novel Case-studies. Insects of Greece View project Bio Insecticides View project. *Journal of Agricultural Science and Technology* 5:30-39.

Pu R, Cheng J. 2015. Mapping forest leaf area index using reflectance and textural information derived from WorldView-2 imagery in a mixed natural forest area in Florida, US. *International Journal of Applied Earth Observation and Geoinformation* 42:11–23.

Qi J, Chehbouni A, Huete AR, Kerr YH, Sorooshian S. 1994. A modified soil adjusted vegetation index. *Remote Sens Environ* 48:119–126.

Qin J, Chao K, Kim MS, Lu R, Burks TF. 2013. Hyperspectral and multispectral imaging for evaluating food safety and quality. *J Food Eng* 118:157–171.

Quarmby NA, Milnes M, Hindle TL, Silleos N. 1993. The use of multi-temporal NDVI measurements from AVHRR data for crop yield estimation and prediction. *International Journal of Remote Sensing* 14:199–210.

Rallo G, Minacapilli M, Ciraolo G, Provenzano G. 2014. Detecting crop water status in mature olive groves using vegetation spectral measurements. *Biosyst Eng* 128:52–68.

Ramoelo A, Dzikiti S, van Deventer H, Maherry A, Cho MA, Gush M. 2015. Potential to monitor plant stress using remote sensing tools. *J Arid Environ* 113:134–144.

Rançon F, Bombrun L, Keresztes B, Germain C. 2018. Comparison of SIFT encoded and deep learning features for the classification and detection of Esca disease in Bordeaux vineyards. *Remote Sens* 11:1.

Rapaport T, Hochberg U, Shoshany M, Karnieli A, Rachmilevitch S. 2015. Combining leaf physiology, hyperspectral imaging and partial least squares-regression (PLS-R) for grapevine water status assessment. *ISPRS Journal of Photogrammetry and Remote Sensing* 109:88–97.

Resco de Dios V, Fellows AW, Nolan RH, Boer MM, Bradstock RA, Domingo F, Goulden ML. 2015. A semi-mechanistic model for predicting the moisture content of fine litter. *Agric For Meteorol* 203:64–73.

Rey-Caramés C, Diago MP, Pilar Martín M, Lobo A, Tardaguila J. 2015. Using RPAS Multi-Spectral Imagery to Characterise Vigour, Leaf Development, Yield Components and Berry Composition Variability within a Vineyard. *Remote Sensing* 7:14458–14481.

Riad S, Mania J, Bouchaou L, Najjar Y. 2004. Rainfall-runoff model usingan artificial neural network approach. *Math Comput Model* 40:839–846.

Ribalta LP, Tulczyjew L, Marcinkiewicz M, Nalepa J. 2020. Hyperspectral Band Selection Using Attention-Based Convolutional Neural Networks. *IEEE Access* 8:42384–42403.

Richardson AJ, Everitt JH. 1992. Using spectral vegetation indices to estimate rangeland productivity. *Geocarto Int* 7:63–69.

Roberts DA, Nelson BW, Adams JB, Palmer F. 1998. Spectral changes with leaf aging in Amazon caatinga. *Trees* 12:315–325.

Roblin G, Luini E, Fleurat-Lessard P, Larignon P, Berjeaud JM. 2019. Towards a preventive and/or curative treatment of esca in grapevine trunk disease: General basis in the elaboration of treatments to control plant pathogen attacks. *Crop Protection* 116:156–169.

Rock BN, Hoshizaki T, Miller JR. 1988. Comparison of in situ and airborne spectral measurements of the blue shift associated with forest decline. *Remote Sens Environ* 24:109–127.

Romero M, Luo Y, Su B, Fuentes S. 2018. Vineyard water status estimation using multispectral imagery from an UAV platform and machine learning algorithms for irrigation scheduling management. *Comput Electron Agric* 147:109–117.

Rondeaux G, Steven M, Baret F. 1996. Optimization of soil-adjusted vegetation indices. *Remote sensing of environment* 55:95-107.

Rossini M, Fava F, Cogliati S, Meroni M, Marchesi A, Panigada C, Giardino C, Busetto L, Migliavacca M, Amaducci S, et al. 2013. Assessing canopy PRI from airborne imagery to map water stress in maize. *ISPRS Journal of Photogrammetry and Remote Sensing* 86:168–177.

Roujean JL, Breon FM. 1995. Estimating PAR absorbed by vegetation from bidirectional reflectance measurements. *Remote sensing of Environment* 51:375-384.

Rouse J, Haas H, Schell A, Deering W, Harlan C. 1974. *Monitoring the Vernal Advancement of Retrogradation (Green Wave Effect) of Natural Vegetation*; Type III, Final Report; NASA: Washington, DC, USA; Consultato il 6 febbraio 2023 da https://ntrs.nasa.gov/archive/nasa/casi.ntrs.nasa.gov/19730009608.pdf.

de Sá NC, Castro P, Carvalho S, Marchante E, López-Núñez FA, Marchante H. 2018. Mapping the flowering of an invasive plant using unmanned aerial vehicles: Is there potential for biocontrol monitoring? *Front Plant Sci* 9:293.

Sandmann M, Grosch R, Graefe J. 2018. Use of features from fluorescence, thermography, and NDVI imaging to detect biotic stress in lettuce. *Plant Dis* 102:1101–1107.

Sankaran S, Mishra A, Ehsani R, Davis C. 2010. A review of advanced techniques for detecting plant diseases. *Comput Electron Agric* 72:1–13.

Santos C, Fragoeiro S, Phillips A. 2005. Physiological response of grapevine cultivars and a rootstock to infection with Phaeoacremonium and Phaeomoniella isolates: an in vitro approach using plants and calluses. *Sci Hortic* 103:187–198.

Scholander PF, Hammel HT, Hemmingsen EA, Bradstreet ED. 1964. Hydrostatic Pressure and Osmotic Potential in Leaves of Mangroves and Some Other Plants. *Proc. Nat. Acad. Sci. USA* 52:119–125.

Schweizer SM, Moura JMF. 2001. Efficient detection in hyperspectral imagery. *IEEE Transactions on Image Processing* 10:584–597.

Serrano L, González-Flor C, Gorchs G. 2010. Assessing vineyard water status using the reflectance based Water Index. *Agric Ecosyst Environ* 139:490–499.

Sims DA, Gamon JA. 2002. Relationships between leaf pigment content and spectral reflectance across a wide range of species, leaf structures and developmental stages. *Remote Sens Environ* 81:337–354.

Sims DA, Gamon JA. 2003. Estimation of vegetation water content and photosynthetic tissue area from spectral reflectance: a comparison of indices based on liquid water and chlorophyll absorption features. *Remote Sens Environ* 84:526–537.

Sinclair TR, Schreiber MM, Hoffer RM. 1973. Diffuse Reflectance Hypothesis for the Pathway of Solar Radiation Through Leaves1. *Agron J* 65:276–283.

Sivanandam P, Lucieer A. 2022. Tree Detection and Species Classification in a Mixed Species Forest Using Unoccupied Aircraft System (UAS) RGB and Multispectral Imagery. *Remote Sensing* 14:4963.

Sivilotti P, Bonetto C, Paladin M, Peterlunger E. 2005. Effect of Soil Moisture Availability on Merlot: From Leaf Water Potential to Grape Composition. *Am J Enol Vitic* 56:9–18.

Slaton MR, Hunt ER, Smith WK. 2001. Estimating near-infrared leaf reflectance from leaf structural characteristics. *Am J Bot* 88:278–284.

Sosnowski M, Luque J, Loschiavo A, Martos S, Garcia-Figueres F, Wicks TJ, Scott ES. 2011. Studies on the effect of water and temperature stress on grapevines inoculated with Eutypa lata. *Phytopathologia Mediterranea* 50:S127-S138.

Suárez L, Zarco-Tejada PJ, Sepulcre-Cantó G, Pérez-Priego O, Miller JR, Jiménez-Muñoz JC, Sobrino J. 2008. Assessing canopy PRI for water stress detection with diurnal airborne imagery. *Remote Sens Environ* 112:560–575.

Sun L, Gao F, Anderson MC, Kustas WP, Alsina MM, Sanchez L, Sams B, McKee L, Dulaney W, White WA, et al. 2017. Daily Mapping of 30 m LAI and NDVI for Grape Yield Prediction in California Vineyards. *Remote Sensing* 9:317.

Surico G, Mugnai L, Marchi G. 2006. Older and more recent observations on esca: a critical overview. *Phytopathol Mediterr* 45:S68–S86.

Susič N, Žibrat U, Širca S, Strajnar P, Razinger J, Knapič M, Vončina A, Urek G, Gerič Stare B. 2018. Discrimination between abiotic and biotic drought stress in tomatoes using hyperspectral imaging. *Sens Actuators B Chem* 273:842–852.

Teillet PM, Staenz K, Williams DJ. 1997. Effects of spectral, spatial, and radiometric characteristics on remote sensing vegetation indices of forested regions. *Remote Sens Environ* 61:139–149.

Terashima I, Fujita T, Inoue T, Chow WS, Oguchi R. 2009. Green Light Drives Leaf Photosynthesis More Efficiently than Red Light in Strong White Light: Revisiting the Enigmatic Question of Why Leaves are Green. *Plant Cell Physiol* 50:684–697.

Thenkabail PS, Smith RB, de Pauw E. 2000. Hyperspectral Vegetation Indices and Their Relationships with Agricultural Crop Characteristics. *Remote Sens Environ* 71:158–182.

Thenkabail PS, Enclona EA, Ashton MS, van der Meer B. 2004. Accuracy assessments of hyperspectral waveband performance for vegetation analysis applications. *Remote Sens Environ* 91:354–376.

Thenkabail PS, Gumma MK, Teluguntla P, Irshad AM. 2014. Hyperspectral remote sensing of vegetation and agricultural crops. *Photogrammetric Engineering & Remote Sensing (TSI)* 80:695-723

Tokekar P, Hook J vander, Mulla D, Isler V. 2016. Sensor Planning for a Symbiotic UAV and UGV System for Precision Agriculture. *IEEE Transactions on Robotics* 32:1498–1511.

Toth C, Jóźków G. 2016. Remote sensing platforms and sensors: A survey. *ISPRS Journal of Photogrammetry and Remote Sensing* 115:22–36.

Tsouros DC, Bibi S, Sarigiannidis PG. 2019. A Review on UAV-Based Applications for Precision Agriculture. *Information* 10:349.

Tucker CJ. 1979. Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sens Environ* 8:127–150.

Tucker CJ. 1980. Remote sensing of leaf water content in the near infrared. *Remote Sens Environ* 10:23–32.

Van Zyl JL. 1987. Diurnal Variation in Grapevine Water Stress as a Function of Changing Soil Water Status and Meteorological Conditions. *South African Journal of Enology and Viticulture* 8:45–52.

Veysi S, Naseri AA, Hamzeh S, Bartholomeus H. 2017. A satellite based crop water stress index for irrigation scheduling in sugarcane fields. *Agric Water Manag* 189:70–86.

Walter A, Liebisch F, Hund A. 2015. Plant phenotyping: From bean weighing to image analysis. *Plant Methods* 11:1–11.

Walter-Shea EA, Norman JM. 1991. Leaf Optical Properties. In Myneni, R.B., Ross, J. (eds) *Photon-Vegetation Interactions: Applications in Optical Remote Sensing and Plant Ecology* pp. 229–251.

Weiss M, Jacob F, Duveiller G. 2020. Remote sensing for agricultural applications: A meta-review. *Remote Sens Environ* 236:111402.

Whiteside TG, Bartolo RE. 2016. Robust and Repeatable Ruleset Development for Hierarchical Object-Based Monitoring of Revegetation Using High Spatial and Temporal Resolution UAS Data. In *Proceedings of the GEOBIA 2016: Solutions and Synergies, Enschede, Paesi Bassi, 14–16 September 2016*.

Williams LE, Baeza P, Williams LE, Carter S, Lohr Winery J, Wanless M, Vineyards W, Weaver C, Winery C, Simpson J. 2007. Relationships among Ambient Temperature and Vapor Pressure Deficit and Leaf and Stem Water Potentials of Fully Irrigated, Field-Grown Grapevines. *Am J Enol Vitic* 58:173–181.

Winkel T, Rambal S. 1993. Influence of Water Stress on Grapevines Growing in the Field: From Leaf to Whole-Plant Response. *Functional Plant Biology* 20:143–157.

Wisniak J. 2008. Conservation of Energy: Readings on the Origins of the First Law of Thermodynamics. Part I. *Educación química* 19:159–171.

Woebbecke DM, Meyer GE, von Bargen K, Mortensen DA. 1995. Color Indices for Weed Identification Under Various Soil, Residue, and Lighting Conditions. *Transactions of the ASAE* 38:259–269.

Wójtowicz M, Wójtowicz A, Piekarczyk J. 2016. Application of remote sensing methods in agriculture. *Communications in biometry and crop science* 11:31–50.

Wong CYS, Bambach NE, Alsina MM, McElrone AJ, Jones T, Buckley TN, Kustas WP, Magney TS. 2022. Detecting short-term stress and recovery events in a vineyard using tower-based remote sensing of photochemical reflectance index (PRI). *Irrig Sci* 40:683–696.

Wu T, Zhang L, Peng B, Zhang H, Chen Z, Gao M. 2016. Real-time progressive hyperspectral remote sensing detection methods for crop pest and diseases. In: *Remotely*

Sensed Data Compression, Communications, and Processing XII; SPIE: Bellingham, WA, USA. 9874:139–147.

Xiao X, Braswell B, Zhang Q, Boles S, Frolking S, Moore B. 2003. Sensitivity of vegetation indices to atmospheric aerosols: continental-scale observations in Northern Asia. *Remote Sens Environ* 84:385–392.

Xie Q, Dash J, Huete A, Jiang A, Yin G, Ding Y, Peng D, Hall CC, Brown L, Shi Y, et al. 2019. Retrieval of crop biophysical parameters from Sentinel-2 remote sensing imagery. *International Journal of Applied Earth Observation and Geoinformation* 80:187–195.

Xu M, Liu R, Chen JM, Liu Y, Shang R, Ju W, Wu C, Huang W. 2019. Retrieving leaf chlorophyll content using a matrix-based vegetation index combination approach. *Remote Sens Environ* 224:60–73.

Xue J, Su B. 2017. Significant remote sensing vegetation indices: A review of developments and applications. *J Sens* 2017. 2017:1353691.

Zarco-Tejada PJ, Berjón A, López-Lozano R, Miller JR, Martín P, Cachorro V, González MR, de Frutos A. 2005. Assessing vineyard condition with hyperspectral indices: Leaf and canopy reflectance simulation in a row-structured discontinuous canopy. *Remote Sens Environ* 99:271–287.

Zarco-Tejada PJ, González-Dugo V, Berni JAJ. 2012. Fluorescence, temperature and narrow-band indices acquired from a UAV platform for water stress detection using a micro-hyperspectral imager and a thermal camera. *Remote Sens Environ* 117:322–337.

Zarco-Tejada PJ, González-Dugo V, Williams LE, Suárez L, Berni JAJ, Goldhamer D, Fereres E. 2013. A PRI-based water stress index combining structural and chlorophyll effects: Assessment using diurnal narrow-band airborne imagery and the CWSI thermal index. *Remote Sens Environ* 138:38–50.

Zhang J, Rivard B, Sánchez-Azofeifa A, Castro-Esau K. 2006. Intra- and inter-class spectral variability of tropical tree species at La Selva, Costa Rica: Implications for species identification using HYDICE imagery. *Remote Sens Environ* 105:129–141.

Zhang L, Sun X, Wu T, Zhang H. 2015. An Analysis of Shadow Effects on Spectral Vegetation Indexes Using a Ground-Based Imaging Spectrometer. *IEEE Geoscience and Remote Sensing Letters* 12:2188–2192.

Zhao X, Zhang J, Huang Y, Tian Y, Yuan L. 2022. Detection and discrimination of disease and insect stress of tea plants using hyperspectral imaging combined with wavelet analysis. *Comput Electron Agric* 193:106717.

Zhou Z, Majeed Y, Diverres Naranjo G, Gambacorta EMT. 2021. Assessment for crop water stress with infrared thermal imagery in precision agriculture: A review and future prospects for deep learning applications. *Comput Electron Agric* 182:106019.

8 ALLEGATO 1

Potenziale stem – entrambe le date

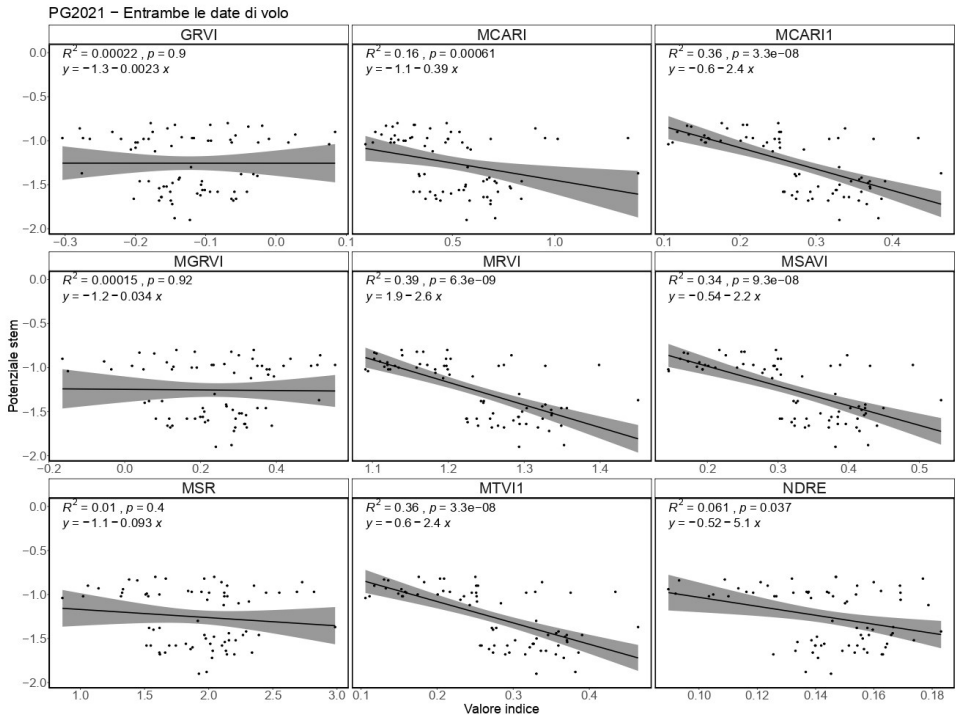

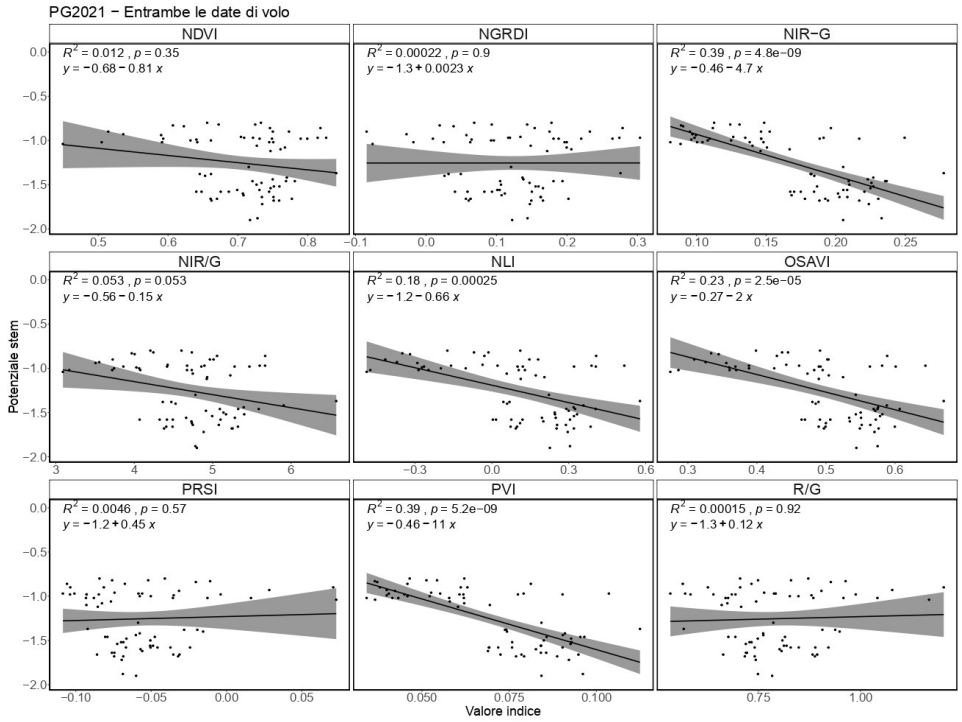

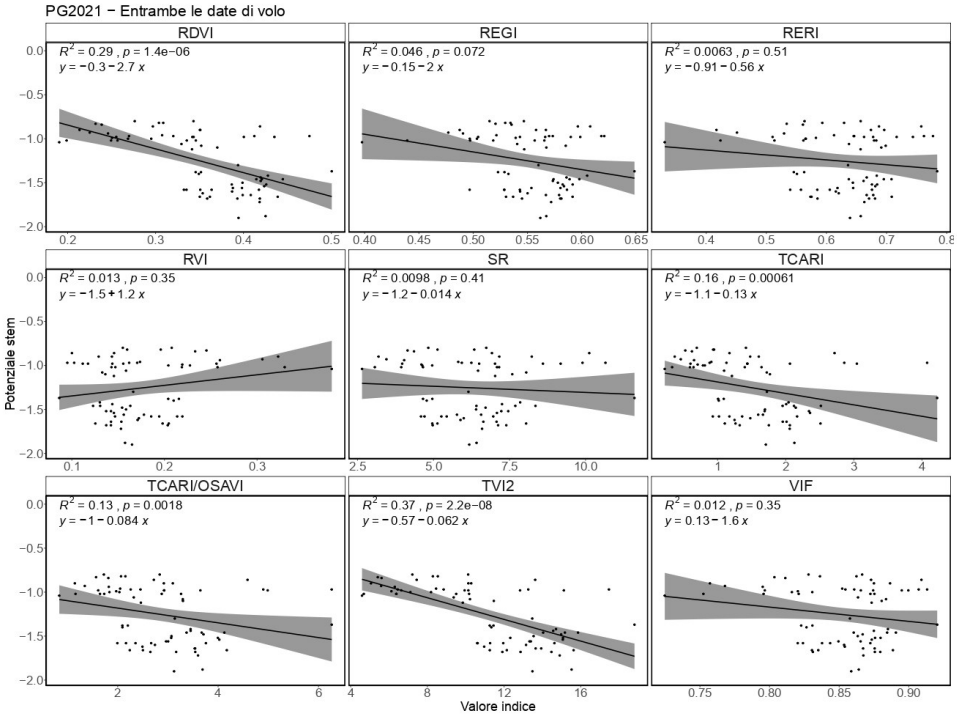
PG2021 − Entrambe le date di volo
RDVI
R^2 = 0.29 , p = 1.4e−06
y = −0.3 − 2.7 x
REGI
R^2 = 0.046 , p = 0.072
y = −0.15 − 2 x
RERI
R^2 = 0.0063 , p = 0.51
y = −0.91 − 0.56 x
RVI
R^2 = 0.013 , p = 0.35
y = −1.5 + 1.2 x
SR
R^2 = 0.0098 , p = 0.41
y = −1.2 − 0.014 x
TCARI
R^2 = 0.16 , p = 0.00061
y = −1.1 − 0.13 x
TCARI/OSAVI
R^2 = 0.13 , p = 0.0018
y = −1 − 0.084 x
TVI2
R^2 = 0.37 , p = 2.2e−08
y = −0.57 − 0.062 x
VIF
R^2 = 0.012 , p = 0.35
y = 0.13 − 1.6 x
Potenziale stem
Valore indice

Regressione polinomiale – entrambe le date

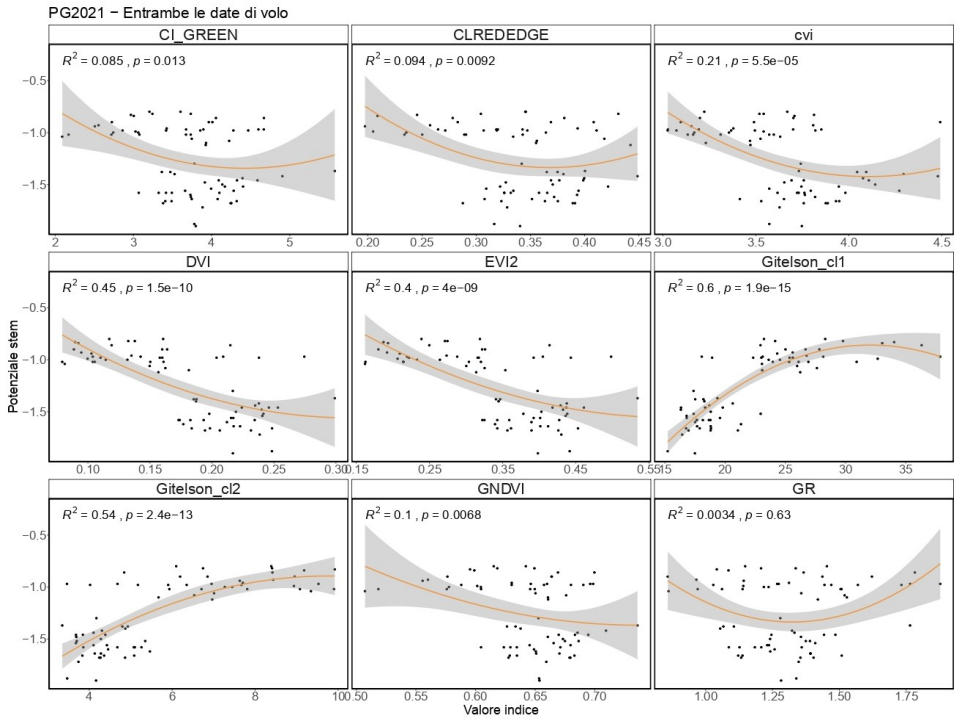

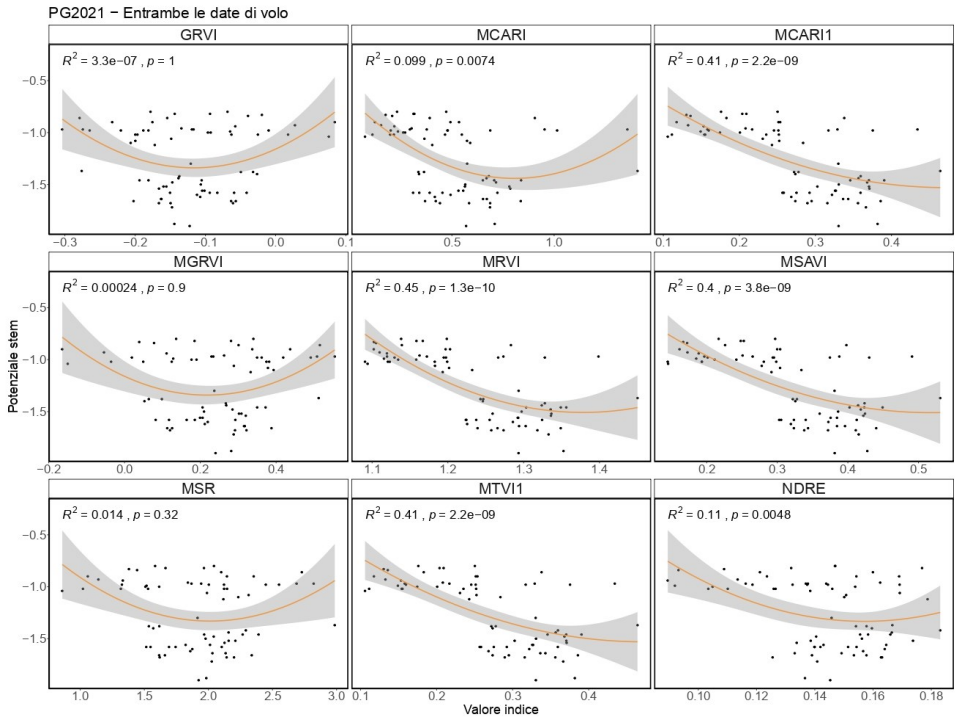

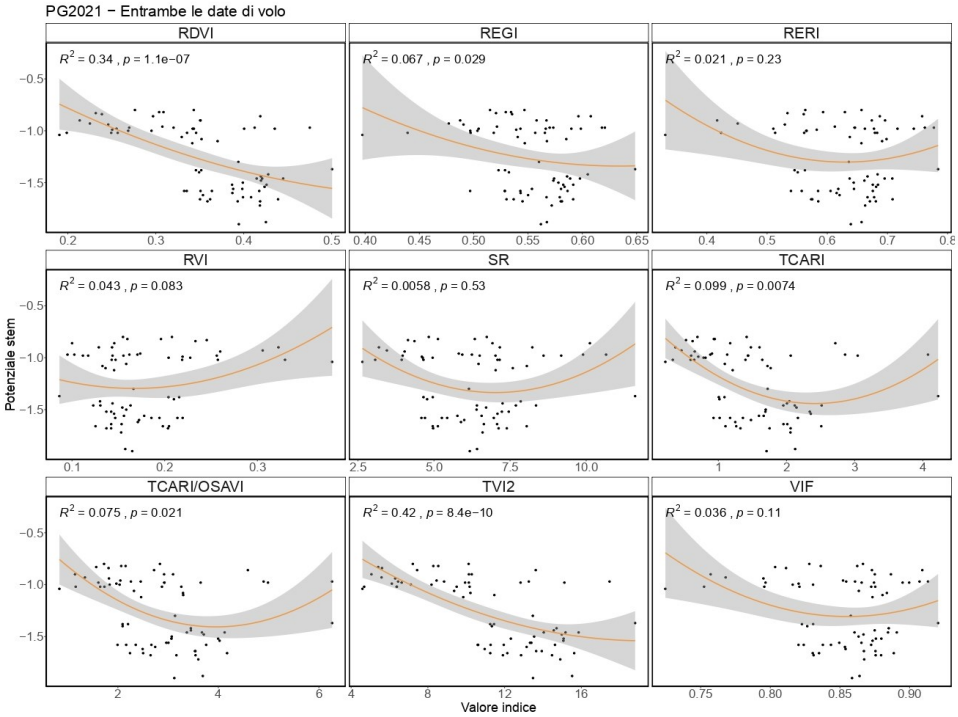
PG2021 − Entrambe le date di volo
RDVI
R^2 = 0.34 , p = 1.1e−07
REGI
R^2 = 0.067 , p = 0.029
RERI
R^2 = 0.021 , p = 0.23
RVI
R^2 = 0.043 , p = 0.083
SR
R^2 = 0.0058 , p = 0.53
TCARI
R^2 = 0.099 , p = 0.0074
TCARI/OSAVI
R^2 = 0.075 , p = 0.021
TVI2
R^2 = 0.42 , p = 8.4e−10
VIF
R^2 = 0.036 , p = 0.11
Potenziale stem
Valore indice

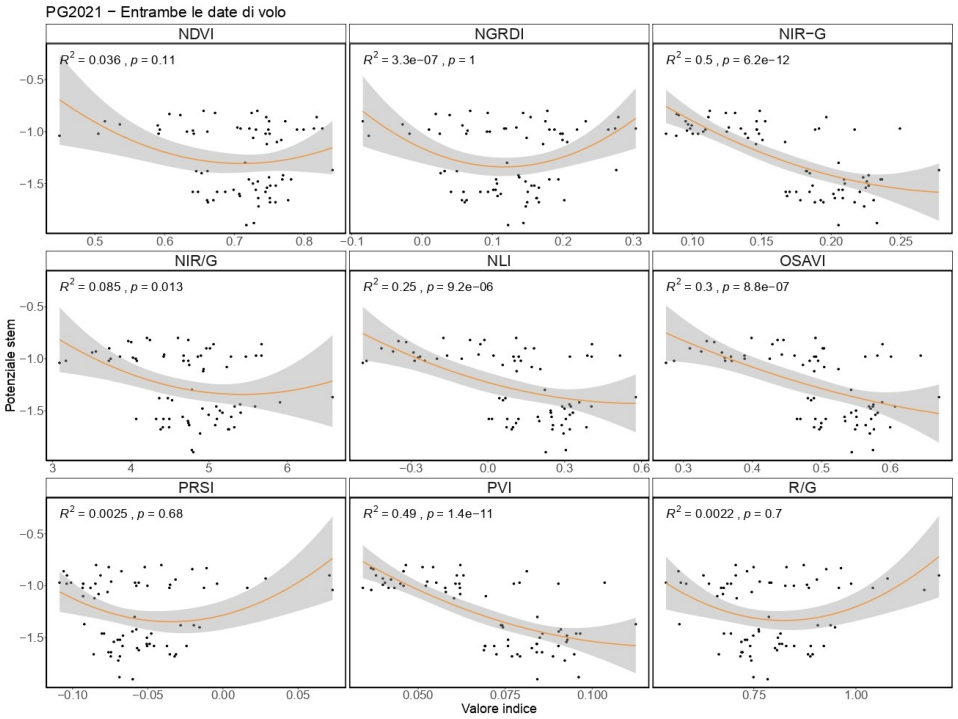
PG2021 − Entrambe le date di volo
NDVI
R^2 = 0.036 , p = 0.11
NGRDI
R^2 = 3.3e−07 , p = 1
NIR−G
R^2 = 0.5 , p = 6.2e−12
NIR/G
R^2 = 0.085 , p = 0.013
NLI
R^2 = 0.25 , p = 9.2e−06
OSAVI
R^2 = 0.3 , p = 8.8e−07
PRSI
R^2 = 0.0025 , p = 0.68
PVI
R^2 = 0.49 , p = 1.4e−11
R/G
R^2 = 0.0022 , p = 0.7
Potenziale stem
Valore indice

Potenziale stem - 29(07/2021

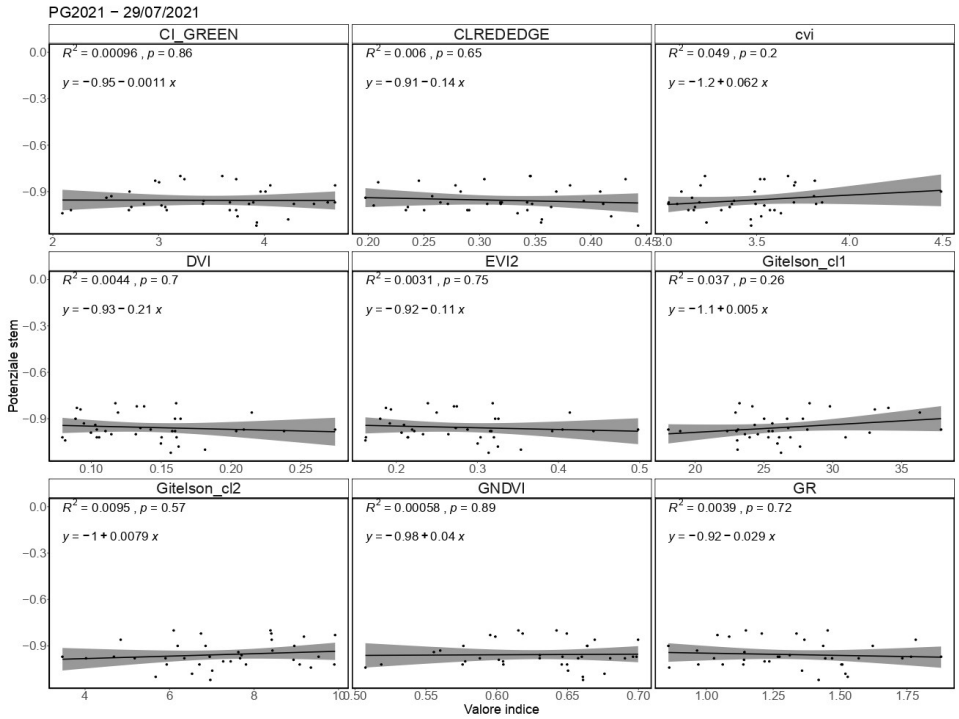

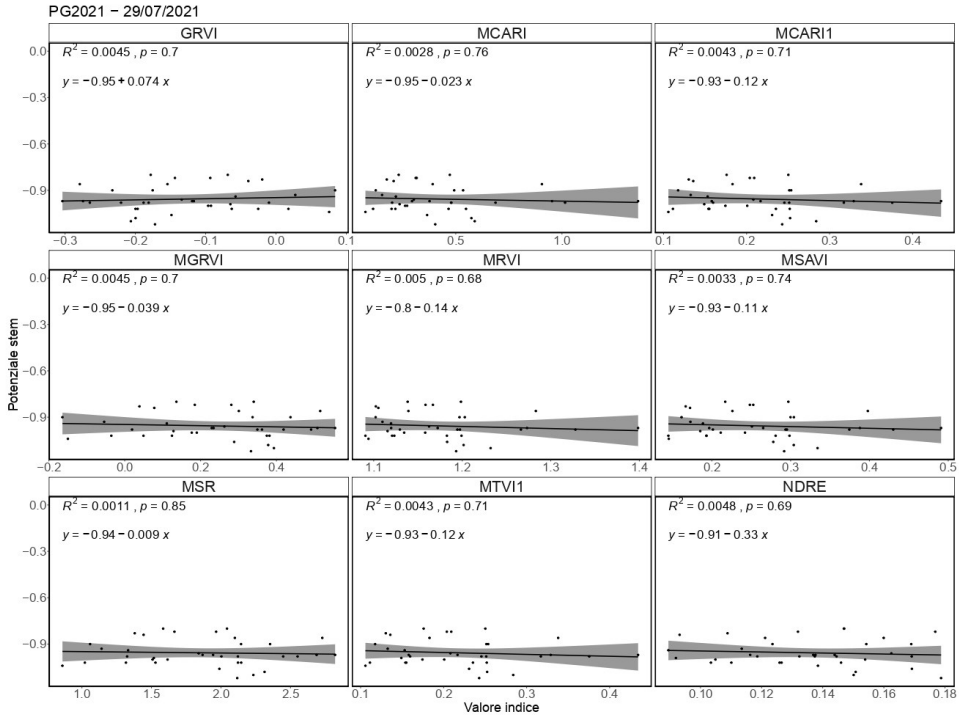

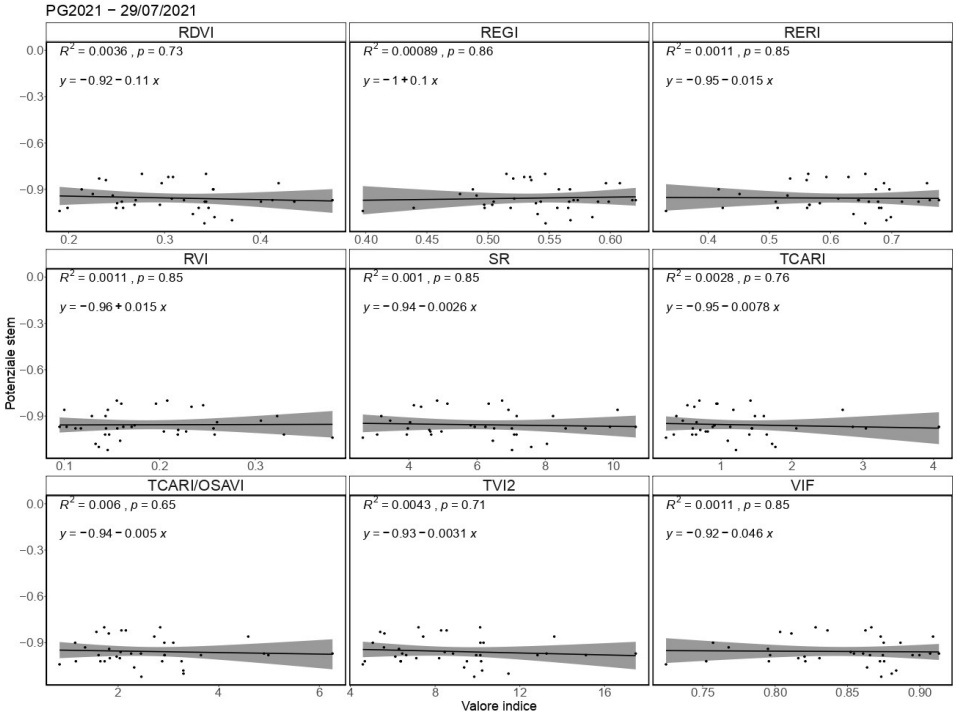
PG2021 − 29/07/2021
RDVI
R^2 = 0.0036 , p = 0.73
y = −0.92 − 0.11 x
REGI
R^2 = 0.00089 , p = 0.86
y = −1 + 0.1 x
RERI
R^2 = 0.0011 , p = 0.85
y = −0.95 − 0.015 x
RVI
R^2 = 0.0011 , p = 0.85
y = −0.96 + 0.015 x
SR
R^2 = 0.001 , p = 0.85
y = −0.94 − 0.0026 x
TCARI
R^2 = 0.0028 , p = 0.76
y = −0.95 − 0.0078 x
TCARI/OSAVI
R^2 = 0.006 , p = 0.65
y = −0.94 − 0.005 x
TVI2
R^2 = 0.0043 , p = 0.71
y = −0.93 − 0.0031 x
VIF
R^2 = 0.0011 , p = 0.85
y = −0.92 − 0.046 x
Potenziale stem
Valore indice

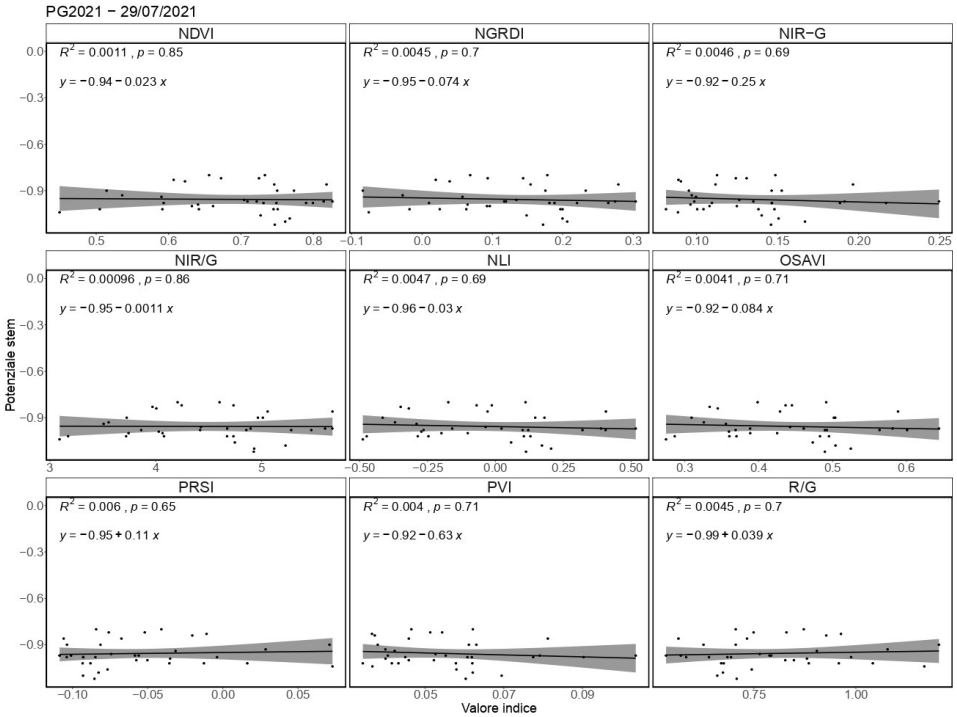
PG2021 − 29/07/2021
NDVI
R^2 = 0.0011 , p = 0.85
y = −0.94 − 0.023 x
NGRDI
R^2 = 0.0045 , p = 0.7
y = −0.95 − 0.074 x
NIR−G
R^2 = 0.0046 , p = 0.69
y = −0.92 − 0.25 x
NIR/G
R^2 = 0.00096 , p = 0.86
y = −0.95 − 0.0011 x
NLI
R^2 = 0.0047 , p = 0.69
y = −0.96 − 0.03 x
OSAVI
R^2 = 0.0041 , p = 0.71
y = −0.92 − 0.084 x
PRSI
R^2 = 0.006 , p = 0.65
y = −0.95 + 0.11 x
PVI
R^2 = 0.004 , p = 0.71
y = −0.92 − 0.63 x
R/G
R^2 = 0.0045 , p = 0.7
y = −0.99 + 0.039 x
Potenziale stem
Valore indice

Potenziale stem - 24/08/2021

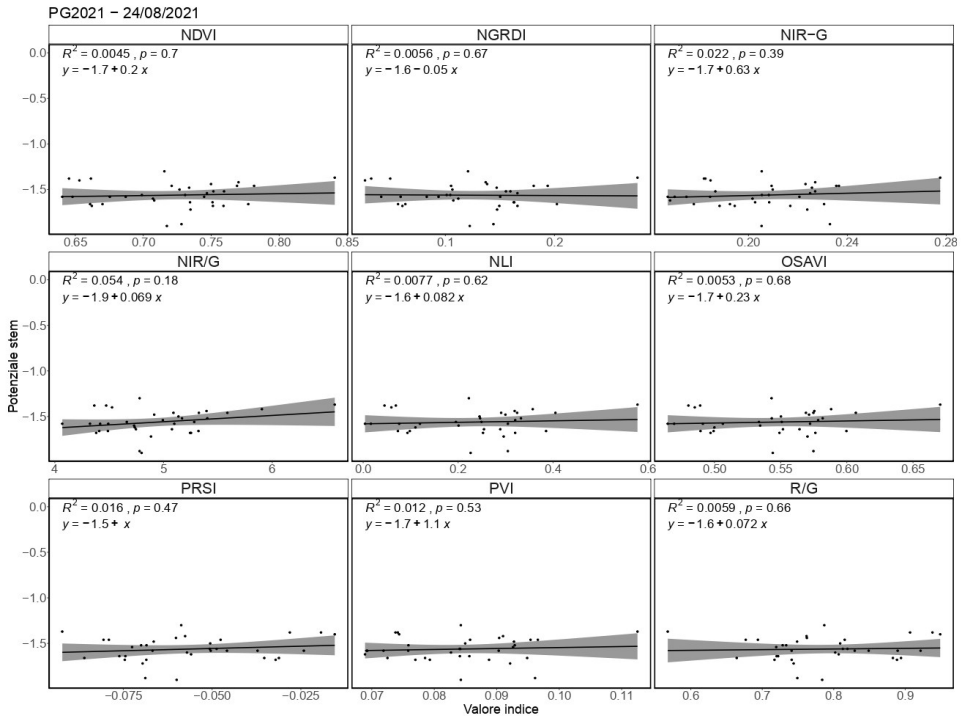

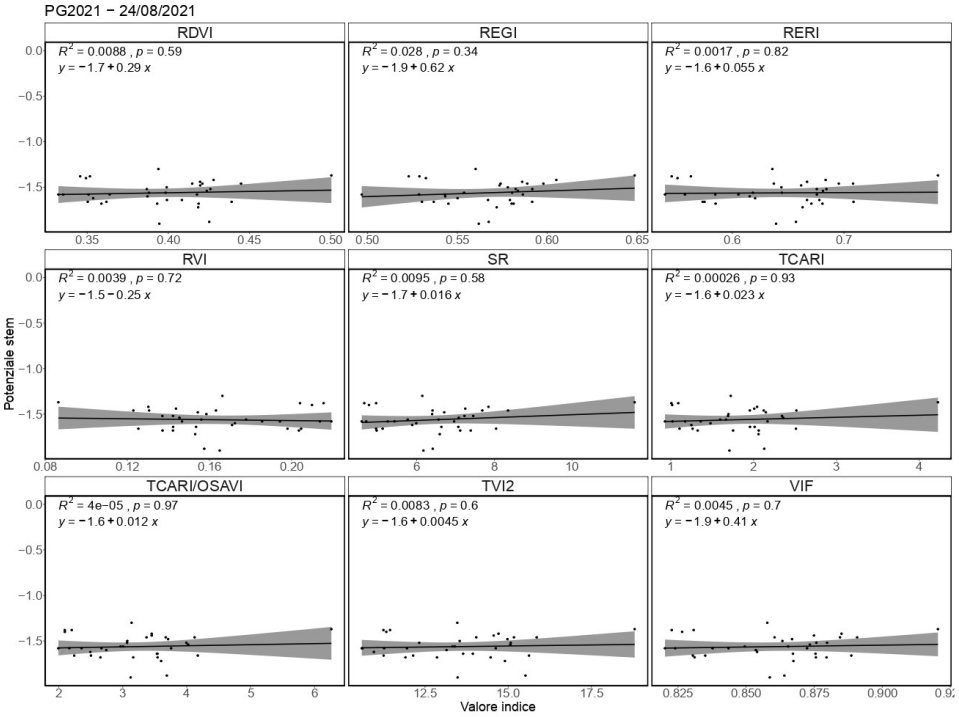

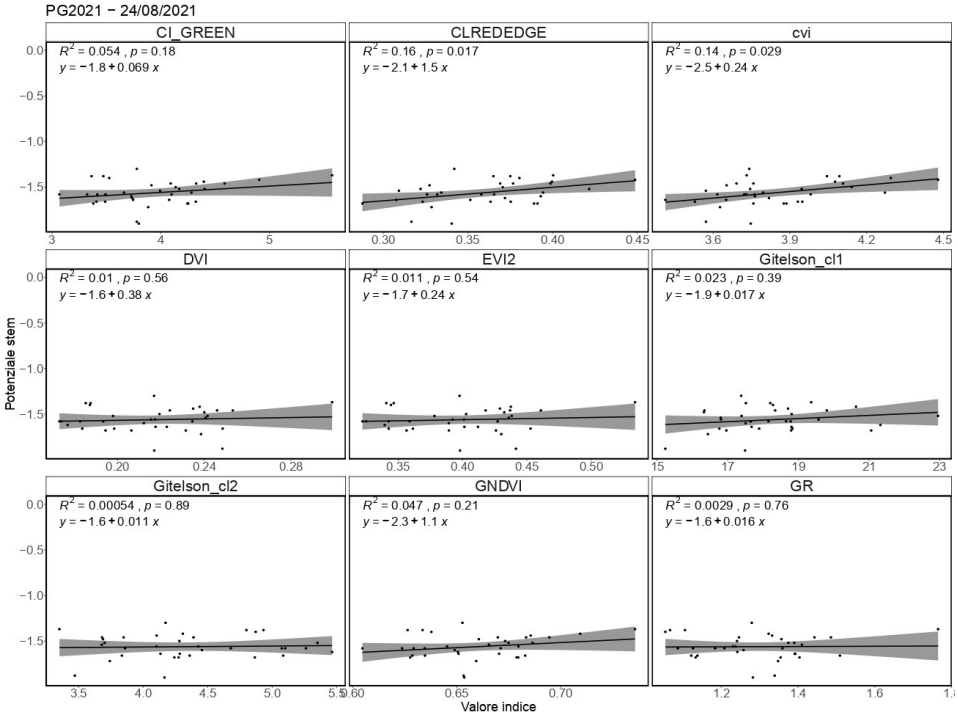
PG2021 − 24/08/2021
CI_GREEN
R^2 = 0.054 , p = 0.18
y = −1.8 + 0.069 x
CLREDEDGE
R^2 = 0.16 , p = 0.017
y = −2.1 + 1.5 x
cvi
R^2 = 0.14 , p = 0.029
y = −2.5 + 0.24 x
DVI
R^2 = 0.01 , p = 0.56
y = −1.6 + 0.38 x
EVI2
R^2 = 0.011 , p = 0.54
y = −1.7 + 0.24 x
Gitelson_cl1
R^2 = 0.023 , p = 0.39
y = −1.9 + 0.017 x
Gitelson_cl2
R^2 = 0.00054 , p = 0.89
y = −1.6 + 0.011 x
GNDVI
R^2 = 0.047 , p = 0.21
y = −2.3 + 1.1 x
GR
R^2 = 0.0029 , p = 0.76
y = −1.6 + 0.016 x
Potenziale stem
Valore indice

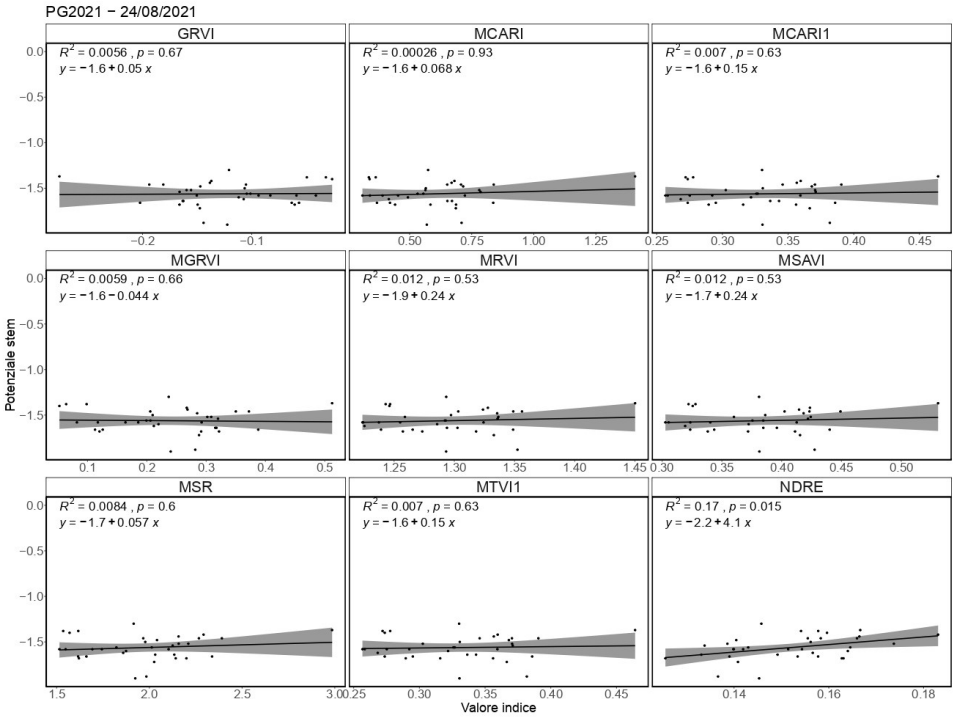
PG2021 − 24/08/2021
GRVI
R^2 = 0.0056 , p = 0.67
y = −1.6 + 0.05 x
MCARI
R^2 = 0.00026 , p = 0.93
y = −1.6 + 0.068 x
MCARI1
R^2 = 0.007 , p = 0.63
y = −1.6 + 0.15 x
MGRVI
R^2 = 0.0059 , p = 0.66
y = −1.6 − 0.044 x
MRVI
R^2 = 0.012 , p = 0.53
y = −1.9 + 0.24 x
MSAVI
R^2 = 0.012 , p = 0.53
y = −1.7 + 0.24 x
MSR
R^2 = 0.0084 , p = 0.6
y = −1.7 + 0.057 x
MTVI1
R^2 = 0.007 , p = 0.63
y = −1.6 + 0.15 x
NDRE
R^2 = 0.17 , p = 0.015
y = −2.2 + 4.1 x
Potenziale stem
Valore indice

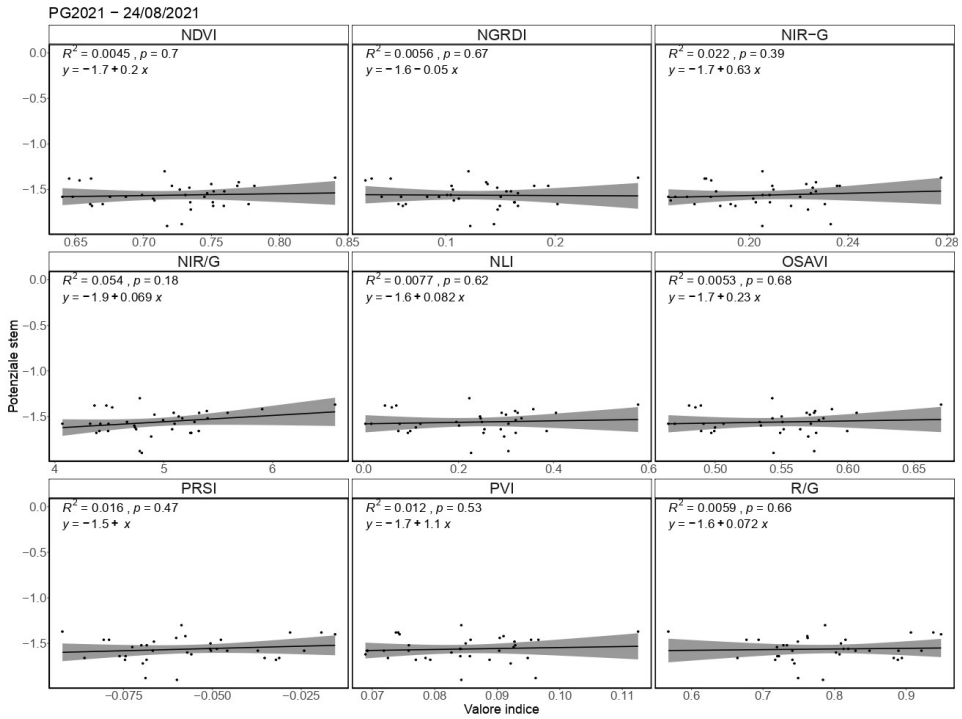
PG2021 − 24/08/2021
NDVI
R^2 = 0.0045 , p = 0.7
y = −1.7 + 0.2 x
NGRDI
R^2 = 0.0056 , p = 0.67
y = −1.6 − 0.05 x
NIR−G
R^2 = 0.022 , p = 0.39
y = −1.7 + 0.63 x
NIR/G
R^2 = 0.054 , p = 0.18
y = −1.9 + 0.069 x
NLI
R^2 = 0.0077 , p = 0.62
y = −1.6 + 0.082 x
OSAVI
R^2 = 0.0053 , p = 0.68
y = −1.7 + 0.23 x
PRSI
R^2 = 0.016 , p = 0.47
y = −1.5 + x
PVI
R^2 = 0.012 , p = 0.53
y = −1.7 + 1.1 x
R/G
R^2 = 0.0059 , p = 0.66
y = −1.6 + 0.072 x
Potenziale stem
Valore indice

Potenziale leaf - 29/07/2021

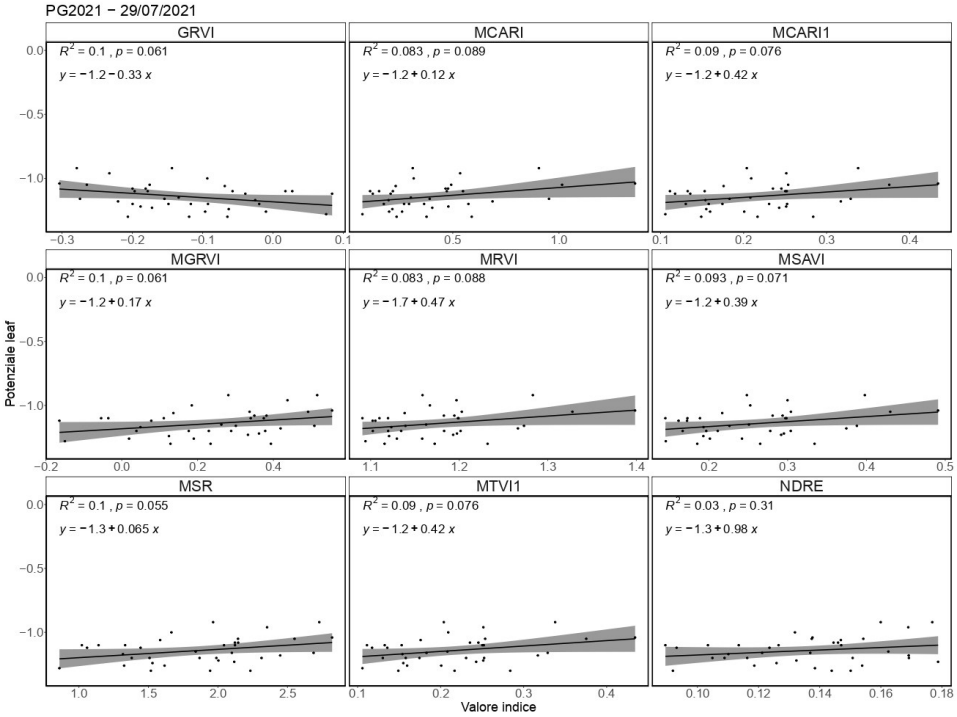

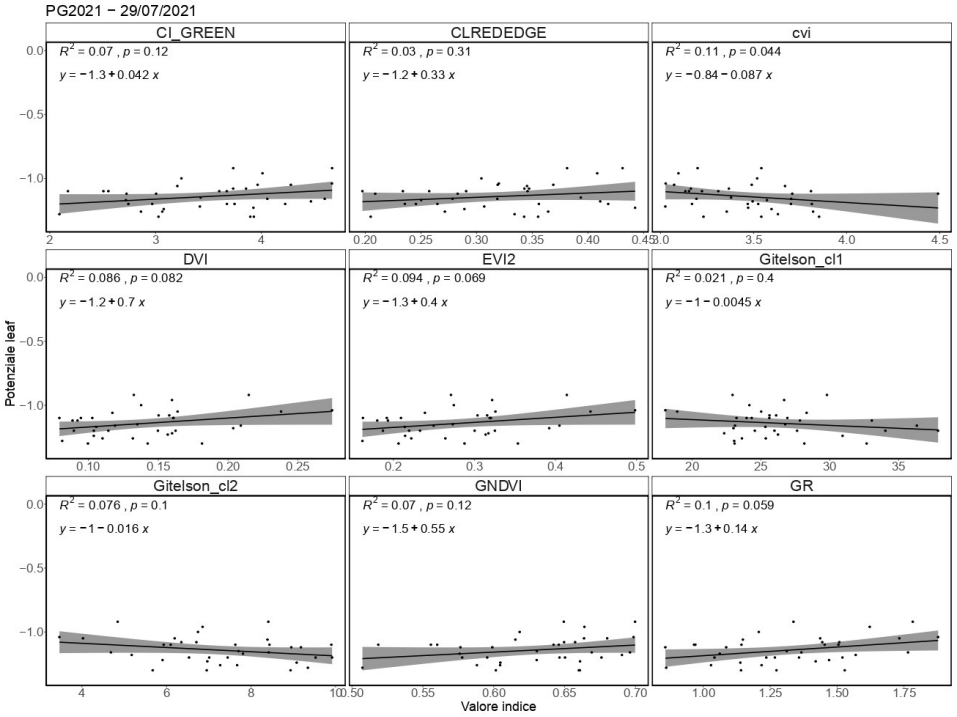

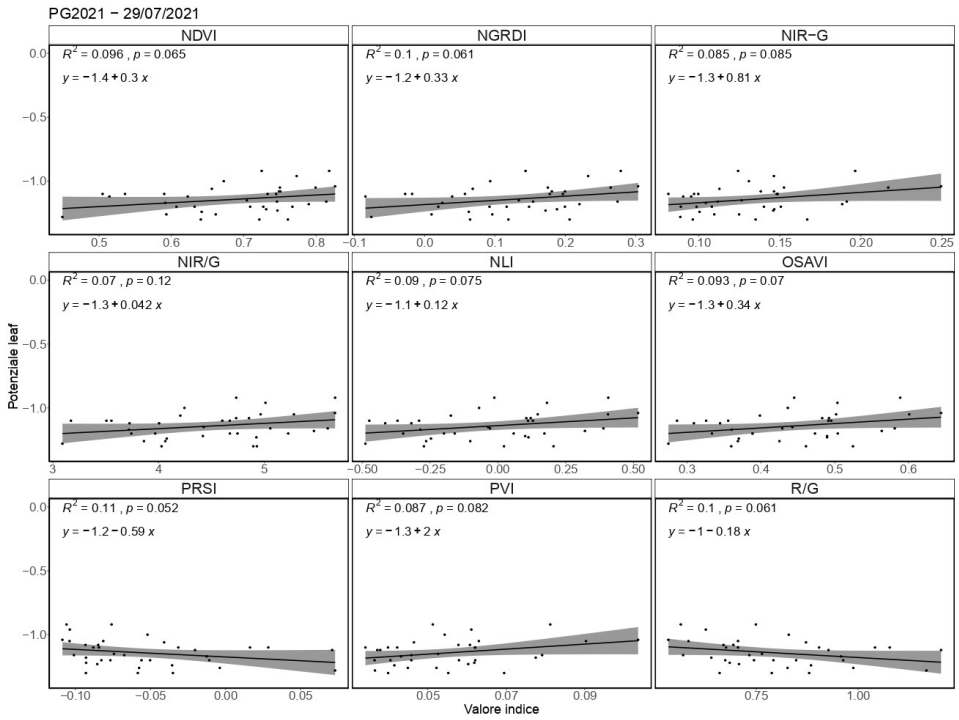
PG2021 − 29/07/2021
NDVI
R^2 = 0.096 , p = 0.065
y = −1.4 + 0.3 x
NGRDI
R^2 = 0.1 , p = 0.061
y = −1.2 + 0.33 x
NIR−G
R^2 = 0.085 , p = 0.085
y = −1.3 + 0.81 x
NIR/G
R^2 = 0.07 , p = 0.12
y = −1.3 + 0.042 x
NLI
R^2 = 0.09 , p = 0.075
y = −1.1 + 0.12 x
OSAVI
R^2 = 0.093 , p = 0.07
y = −1.3 + 0.34 x
PRSI
R^2 = 0.11 , p = 0.052
y = −1.2 − 0.59 x
PVI
R^2 = 0.087 , p = 0.082
y = −1.3 + 2 x
R/G
R^2 = 0.1 , p = 0.061
y = −1 − 0.18 x
Potenziale leaf
Valore indice

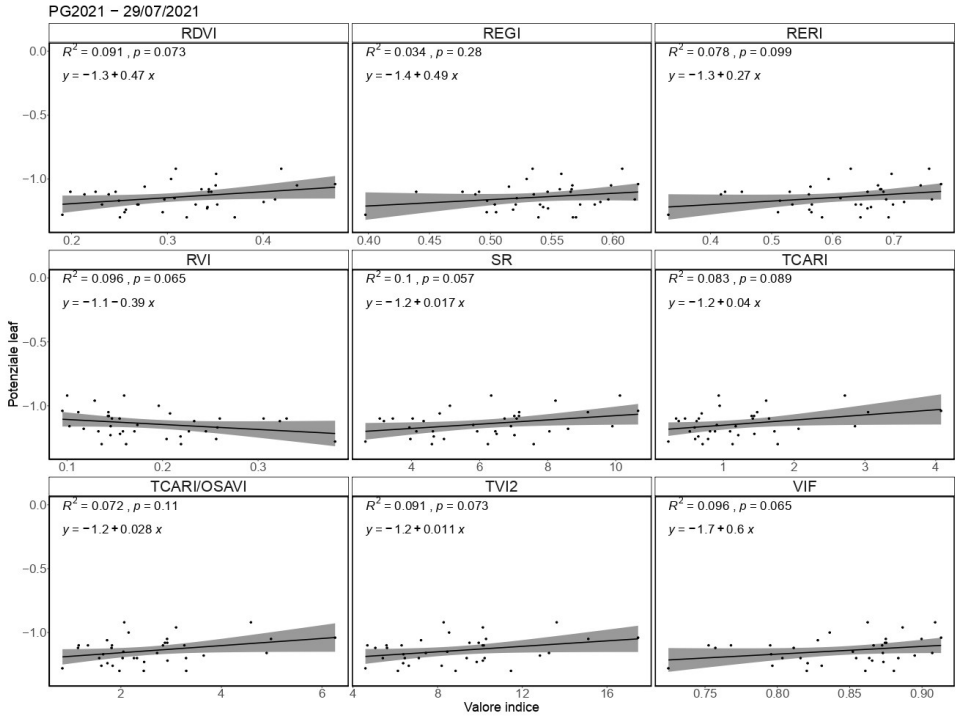
PG2021 − 29/07/2021
RDVI
R^2 = 0.091 , p = 0.073
y = −1.3 + 0.47 x
REGI
R^2 = 0.034 , p = 0.28
y = −1.4 + 0.49 x
RERI
R^2 = 0.078 , p = 0.099
y = −1.3 + 0.27 x
RVI
R^2 = 0.096 , p = 0.065
y = −1.1 − 0.39 x
SR
R^2 = 0.1 , p = 0.057
y = −1.2 + 0.017 x
TCARI
R^2 = 0.083 , p = 0.089
y = −1.2 + 0.04 x
TCARI/OSAVI
R^2 = 0.072 , p = 0.11
y = −1.2 + 0.028 x
TVI2
R^2 = 0.091 , p = 0.073
y = −1.2 + 0.011 x
VIF
R^2 = 0.096 , p = 0.065
y = −1.7 + 0.6 x
Potenziale leaf
Valore indice

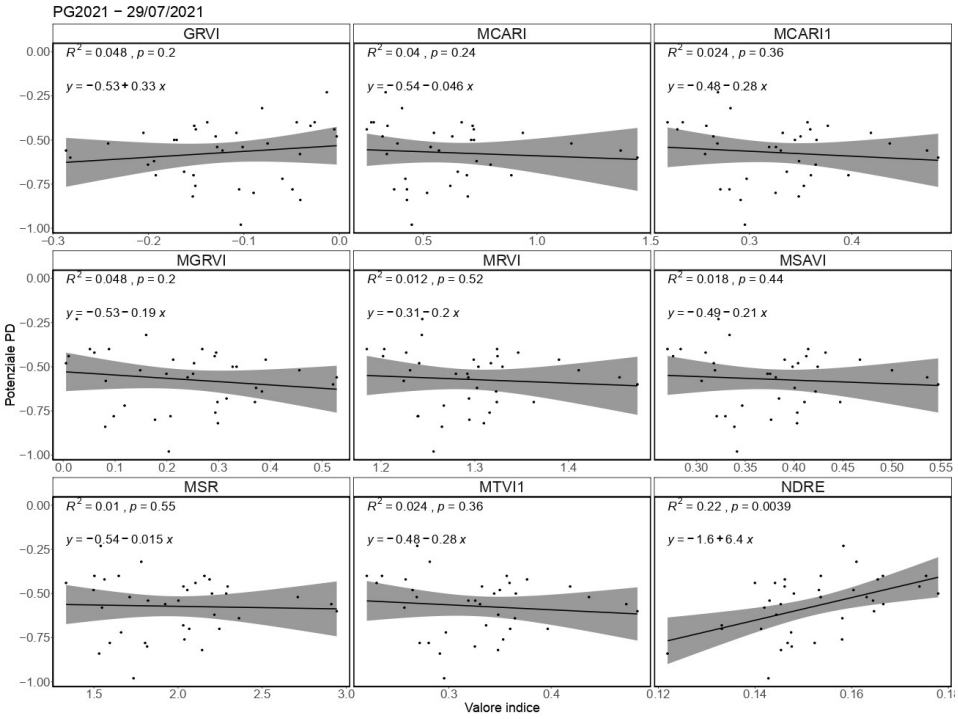
PG2021 − 29/07/2021
GRVI
R^2 = 0.048 , p = 0.2
y = −0.53 + 0.33 x
MCARI
R^2 = 0.04 , p = 0.24
y = −0.54 − 0.046 x
MCARI1
R^2 = 0.024 , p = 0.36
y = −0.48 − 0.28 x
MGRVI
R^2 = 0.048 , p = 0.2
y = −0.53 − 0.19 x
MRVI
R^2 = 0.012 , p = 0.52
y = −0.31 − 0.2 x
MSAVI
R^2 = 0.018 , p = 0.44
y = −0.49 − 0.21 x
MSR
R^2 = 0.01 , p = 0.55
y = −0.54 − 0.015 x
MTVI1
R^2 = 0.024 , p = 0.36
y = −0.48 − 0.28 x
NDRE
R^2 = 0.22 , p = 0.0039
y = −1.6 + 6.4 x
Potenziale PD
Valore indice

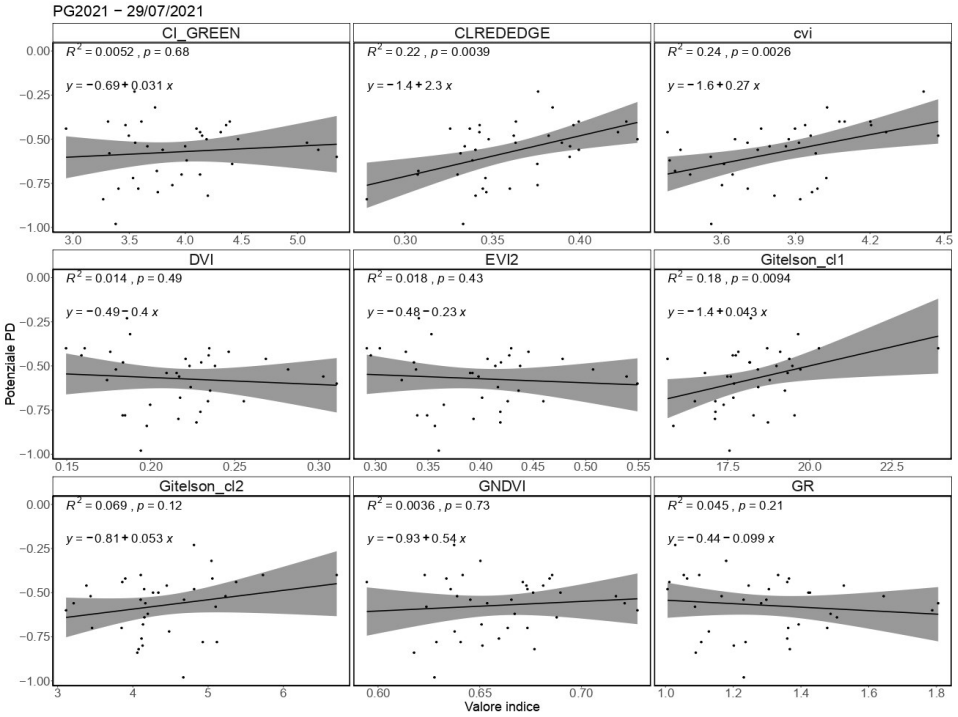
PG2021 − 29/07/2021
CI_GREEN
R^2 = 0.0052 , p = 0.68
y = −0.69 + 0.031 x
CLREDEDGE
R^2 = 0.22 , p = 0.0039
y = −1.4 + 2.3 x
cvi
R^2 = 0.24 , p = 0.0026
y = −1.6 + 0.27 x
DVI
R^2 = 0.014 , p = 0.49
y = −0.49 − 0.4 x
EVI2
R^2 = 0.018 , p = 0.43
y = −0.48 − 0.23 x
Gitelson_cl1
R^2 = 0.18 , p = 0.0094
y = −1.4 + 0.043 x
Gitelson_cl2
R^2 = 0.069 , p = 0.12
y = −0.81 + 0.053 x
GNDVI
R^2 = 0.0036 , p = 0.73
y = −0.93 + 0.54 x
GR
R^2 = 0.045 , p = 0.21
y = −0.44 − 0.099 x
Potenziale PD
Valore indice

28

Potenziale pre-dawn – 24/08/2021

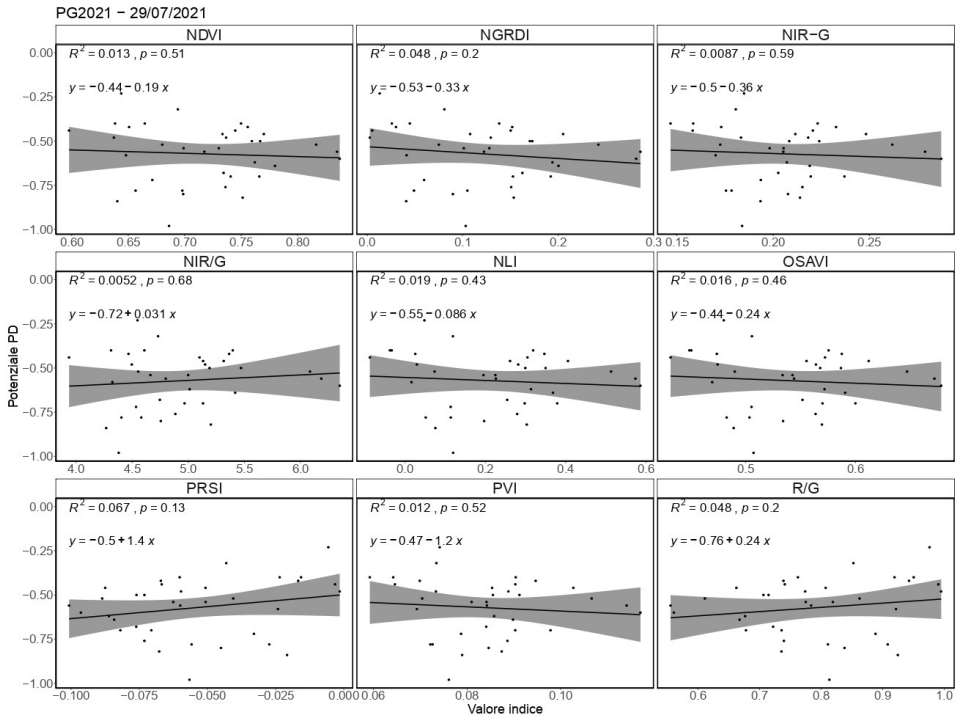

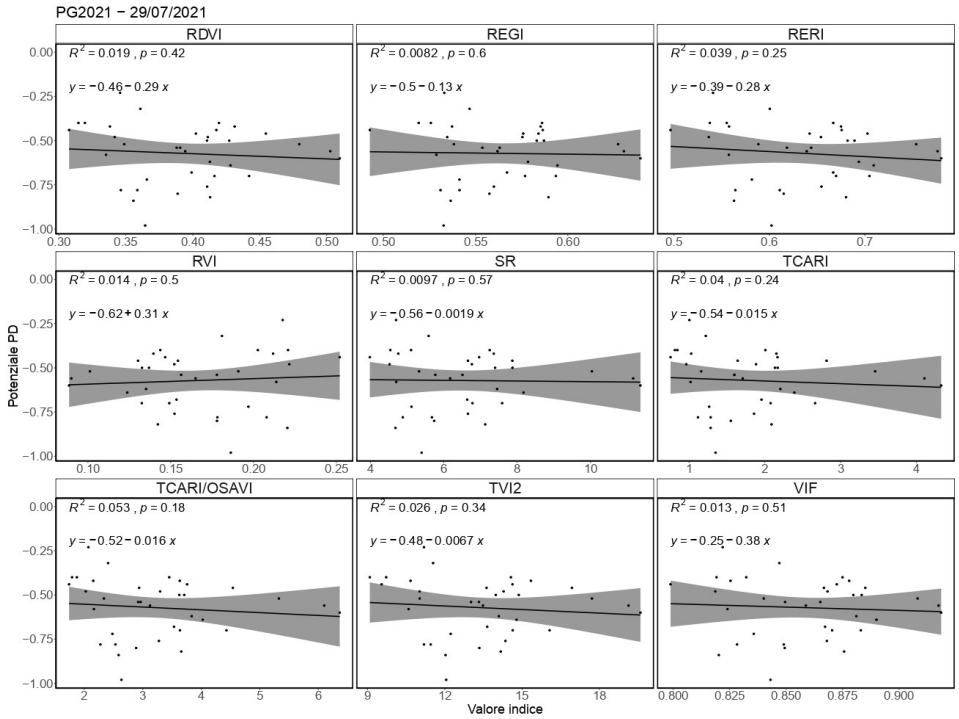

Boxplot di discriminazione tra trattamenti WW, MS e SS – entrambe le date

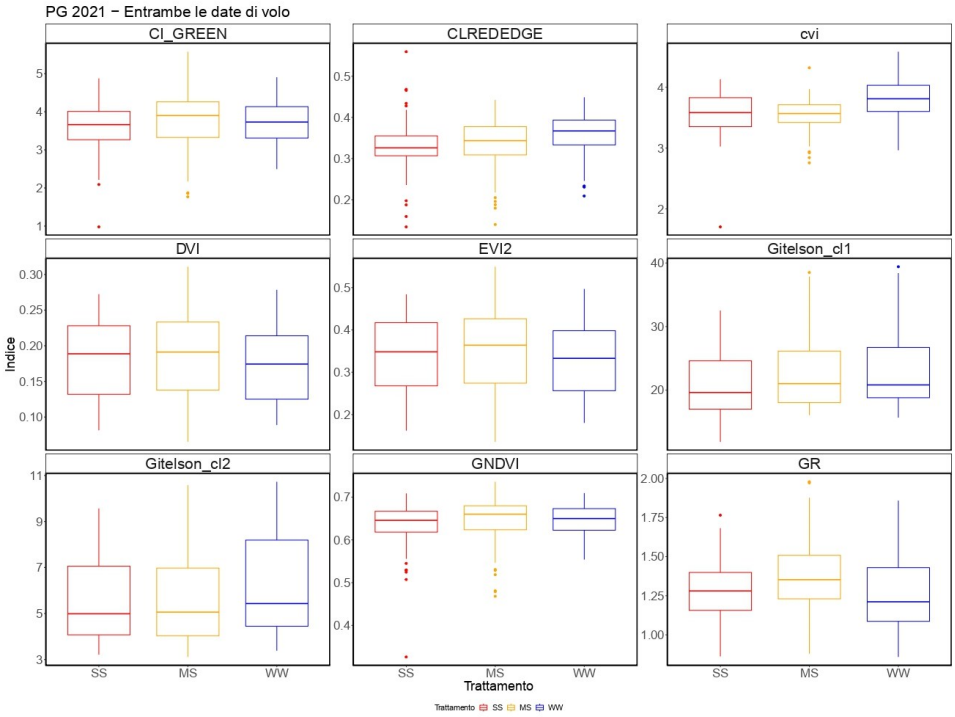

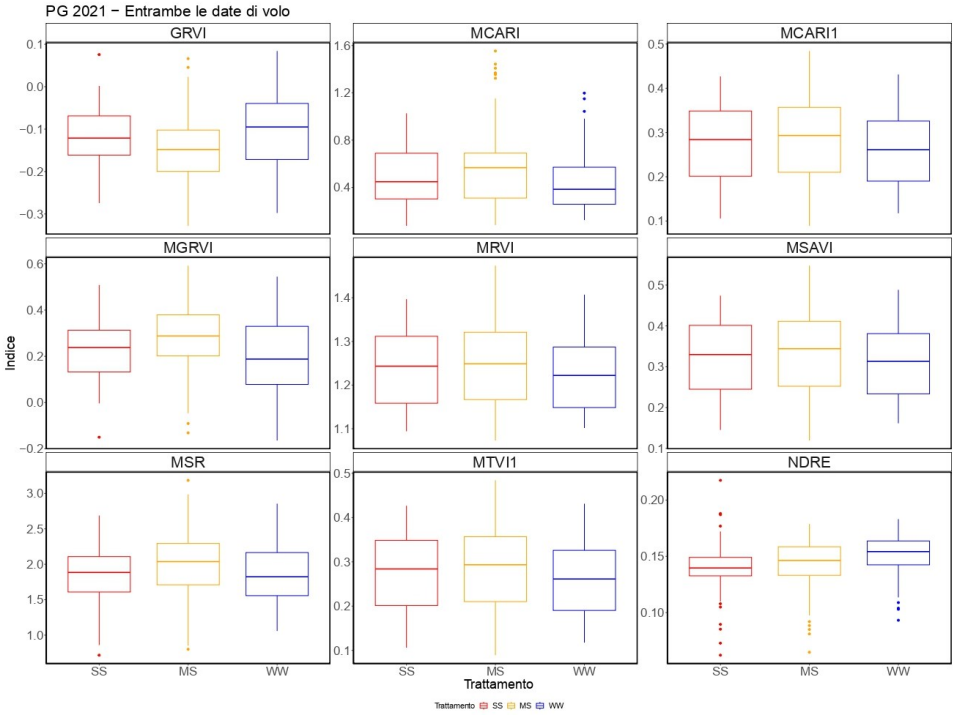

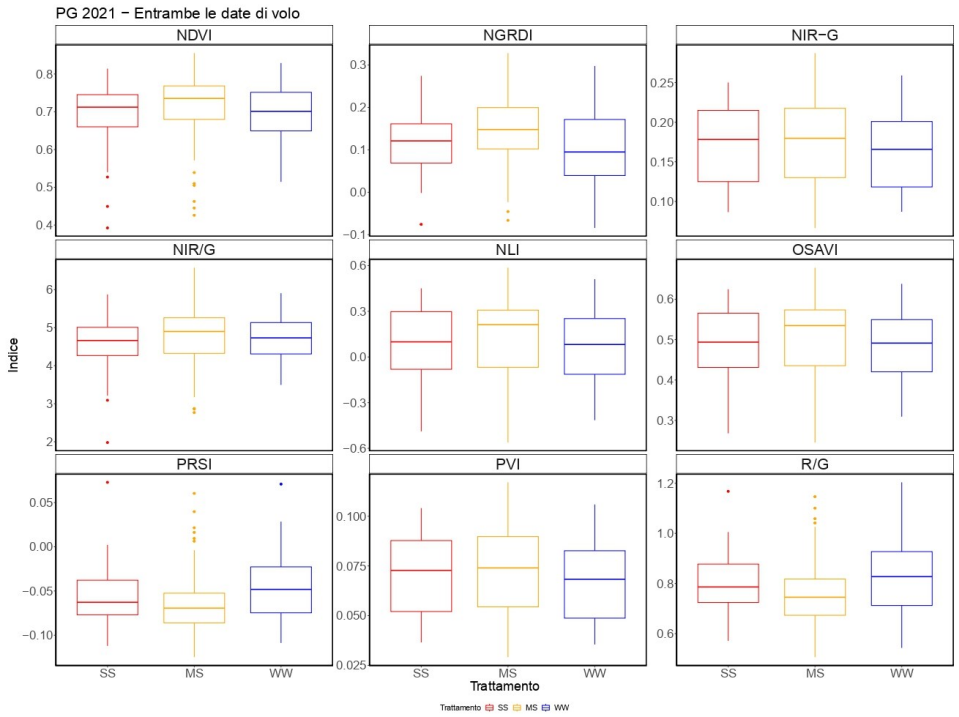
PG 2021 − Entrambe le date di volo
NDVI
NGRDI
NIR−G
NIR/G
NLI
OSAVI
PRSI
PVI
R/G
Indice
SS
MS
WW
Trattamento
Trattamento SS MS WW

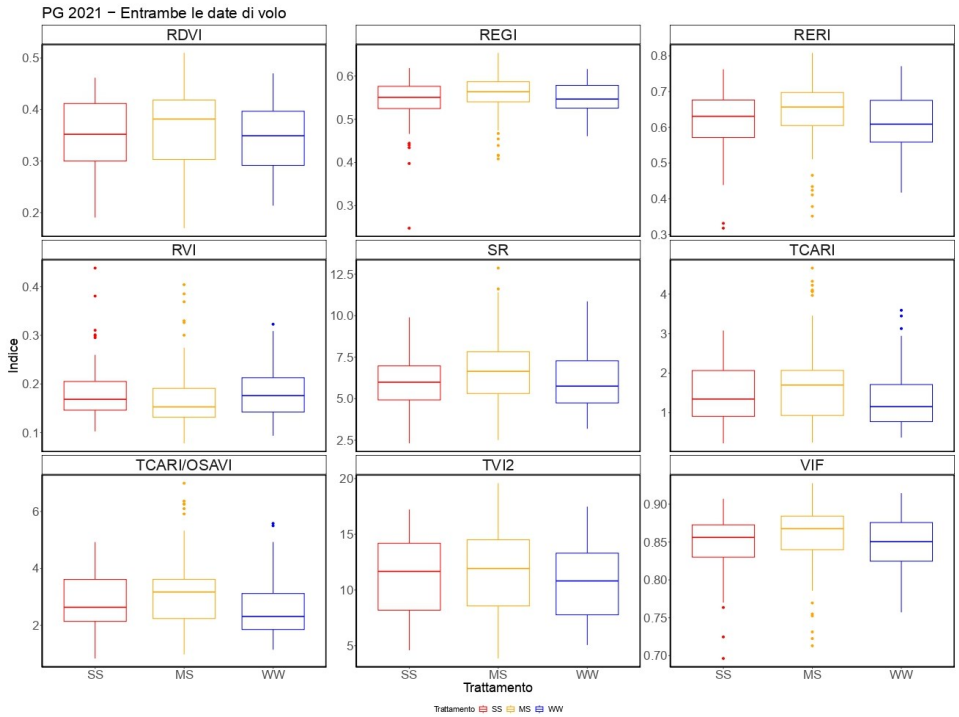
PG 2021 − Entrambe le date di volo
RDVI
REGI
RERI
RVI
SR
TCARI
TCARI/OSAVI
TVI2
VIF
Indice
SS
MS
WW
Trattamento
Trattamento SS MS WW

Boxplot di discriminazione tra trattamenti WW, MS e SS – 29/07/2021

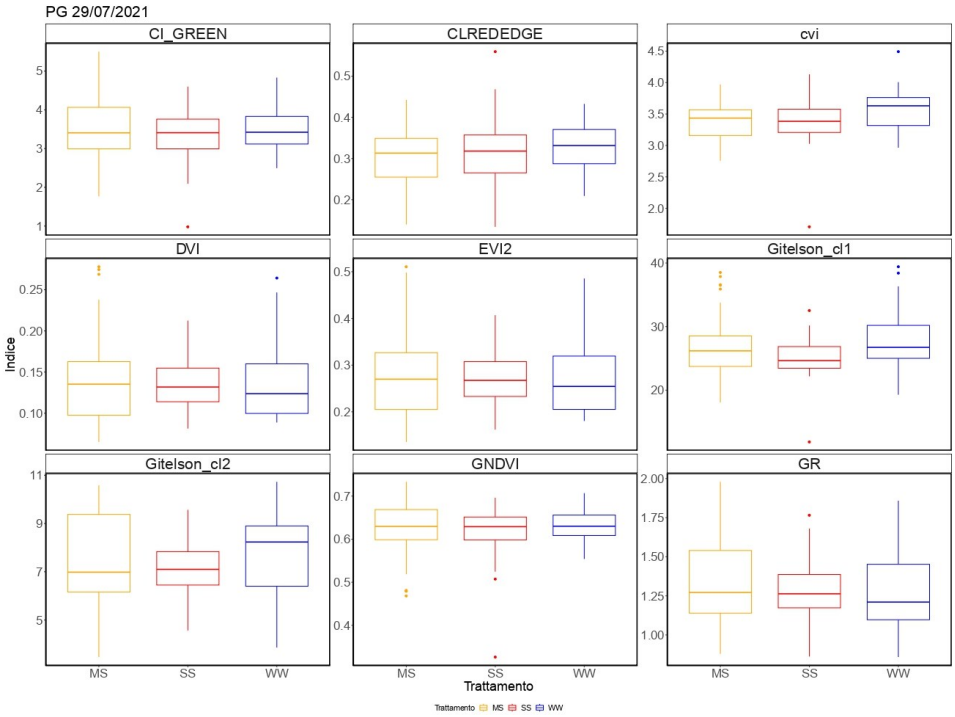

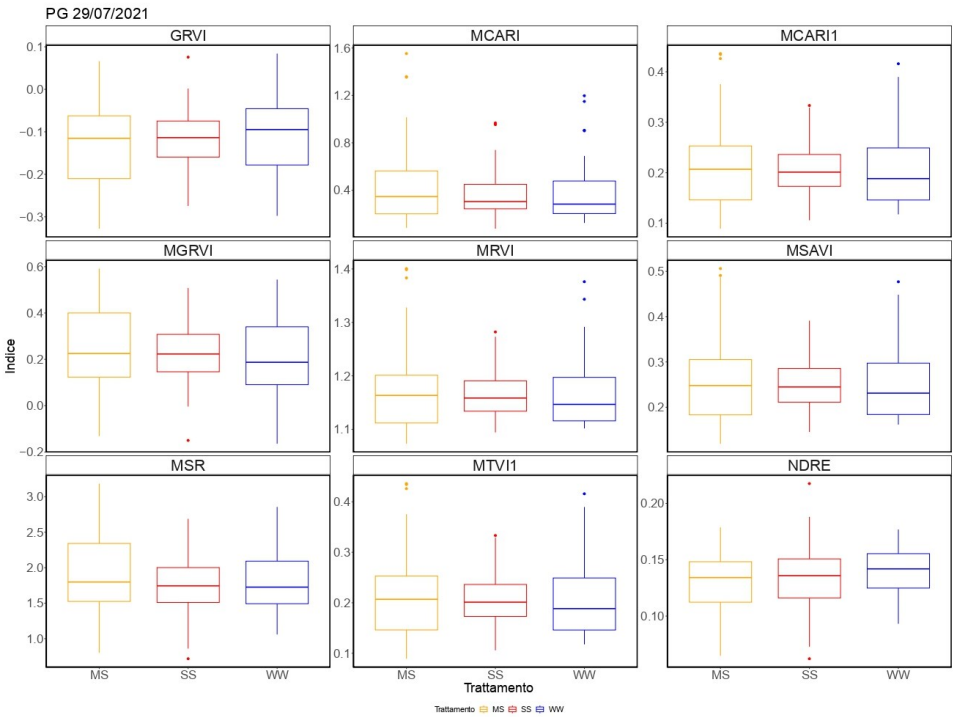

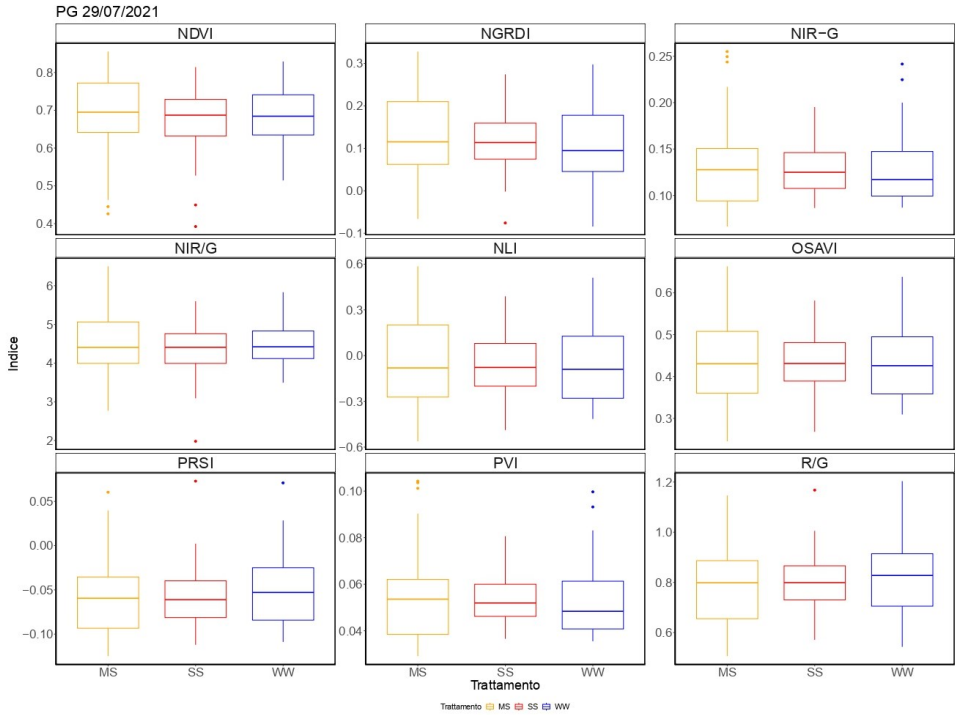
PG 29/07/2021
NDVI
NGRDI
NIR−G
NIR/G
NLI
OSAVI
PRSI
PVI
R/G
Indice
MS
SS
WW
Trattamento
Trattamento MS SS WW

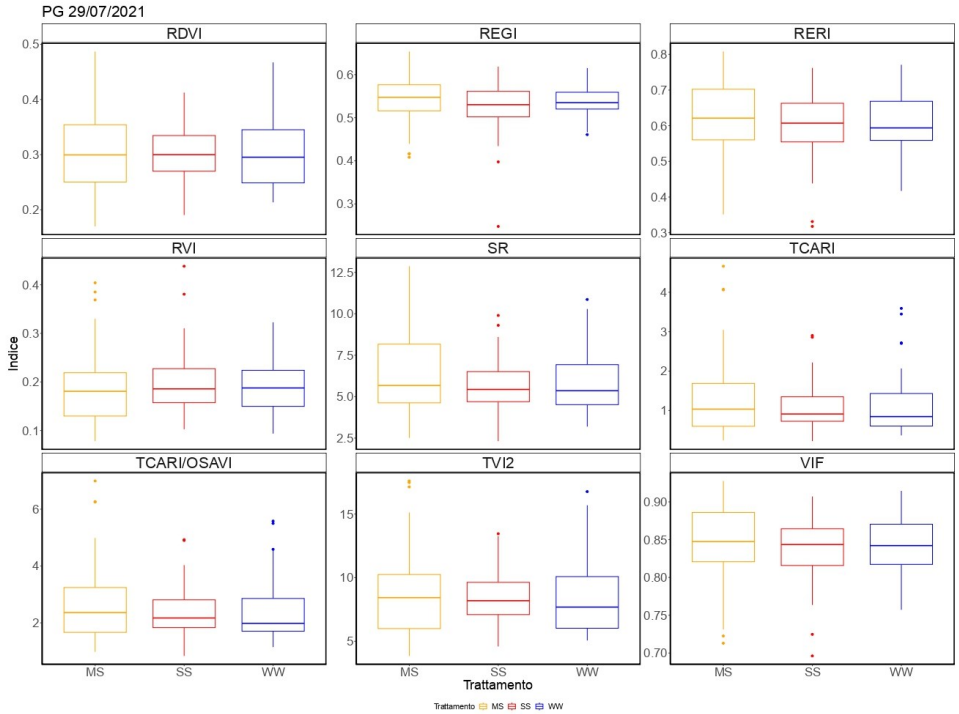
PG 29/07/2021
RDVI
REGI
RERI
RVI
SR
TCARI
TCARI/OSAVI
TVI2
VIF
Indice
MS
SS
WW
Trattamento
Trattamento MS SS WW

Boxplot di discriminazione tra trattamenti WW, MS e SS – 24/08/2021

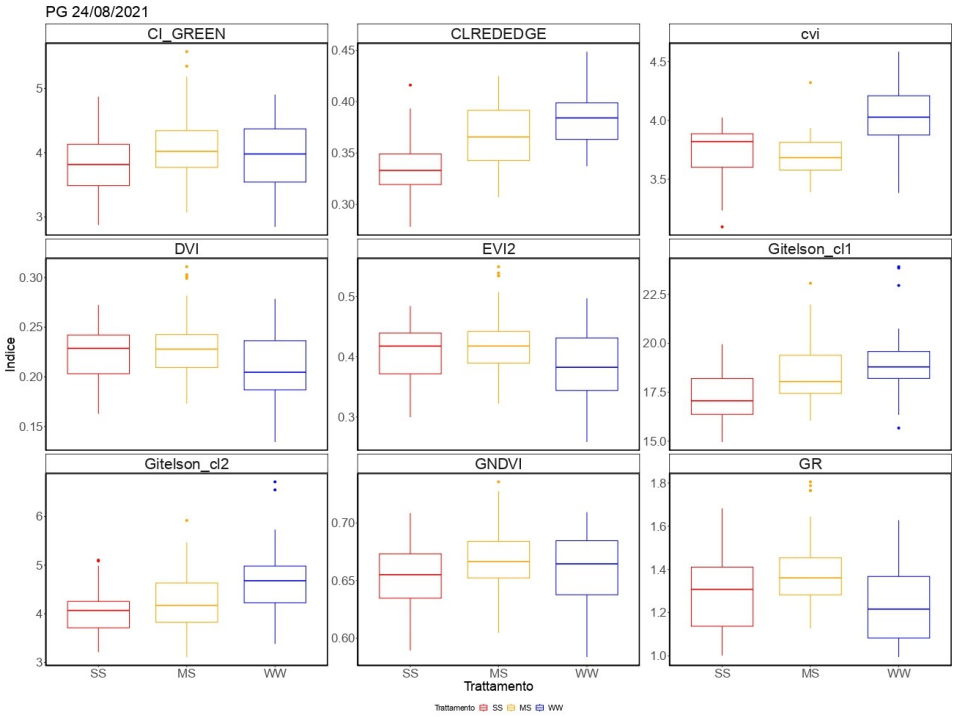

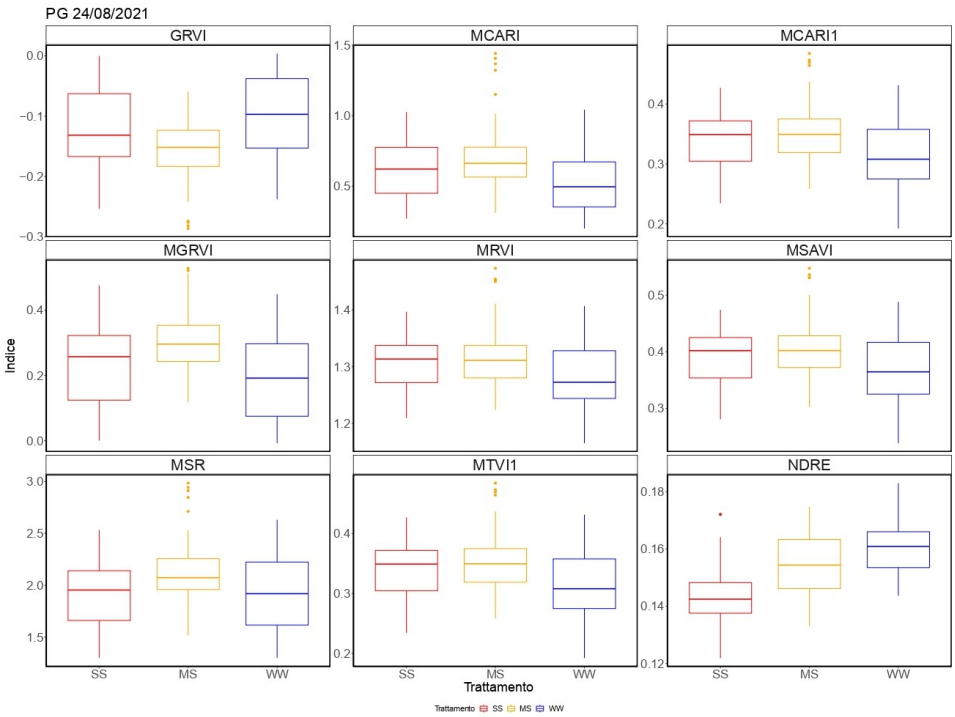

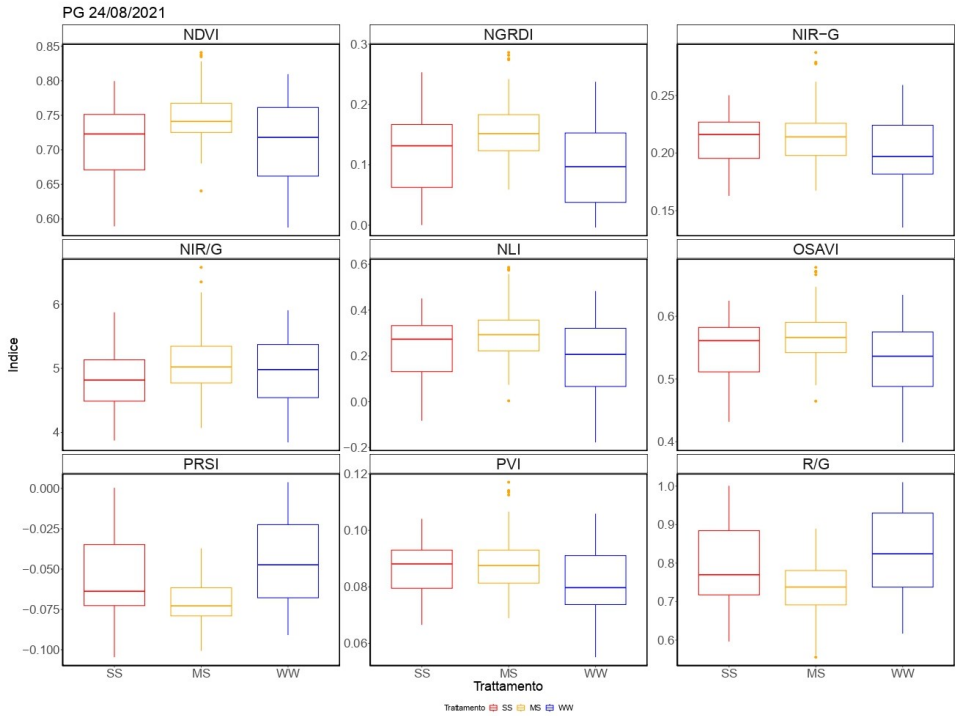
PG 24/08/2021
NDVI
NGRDI
NIR−G
NIR/G
NLI
OSAVI
PRSI
PVI
R/G
Indice
SS
MS
WW
Trattamento
Trattamento SS MS WW

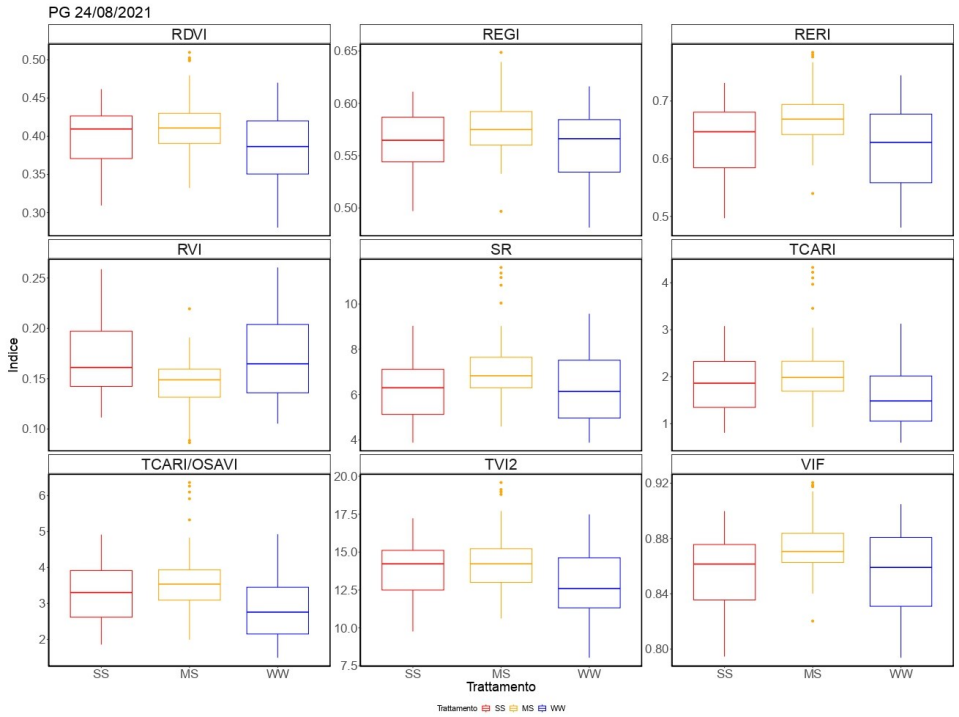
PG 24/08/2021
RDVI
REGI
RERI
RVI
SR
TCARI
TCARI/OSAVI
TVI2
VIF
Indice
SS
MS
WW
Trattamento
Trattamento SS MS WW

Potenziale stem glera Precenicco – entrambe le date

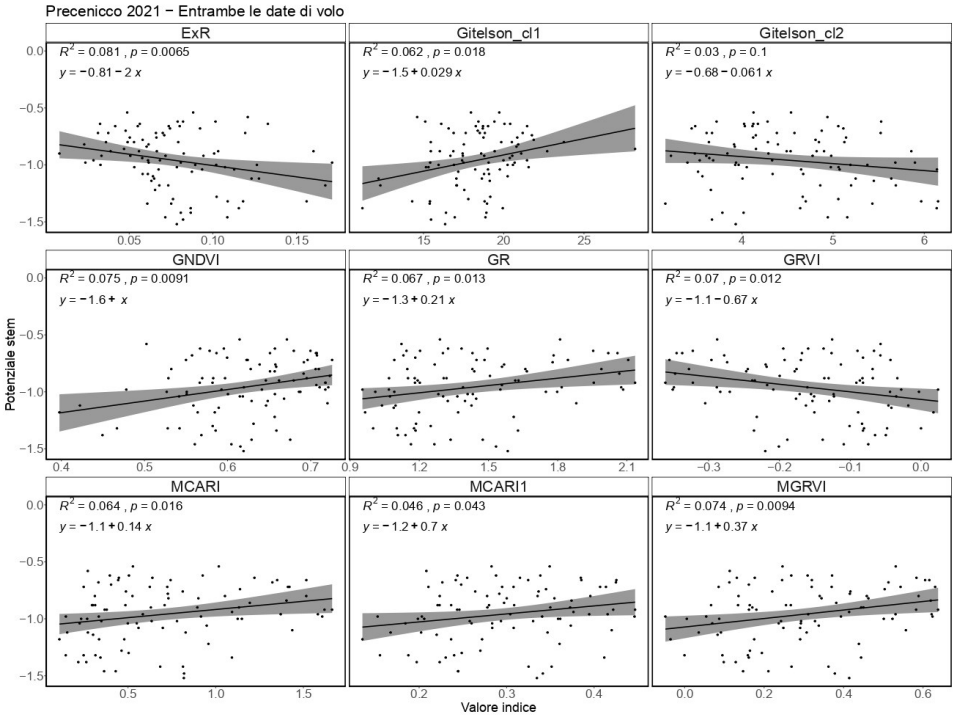

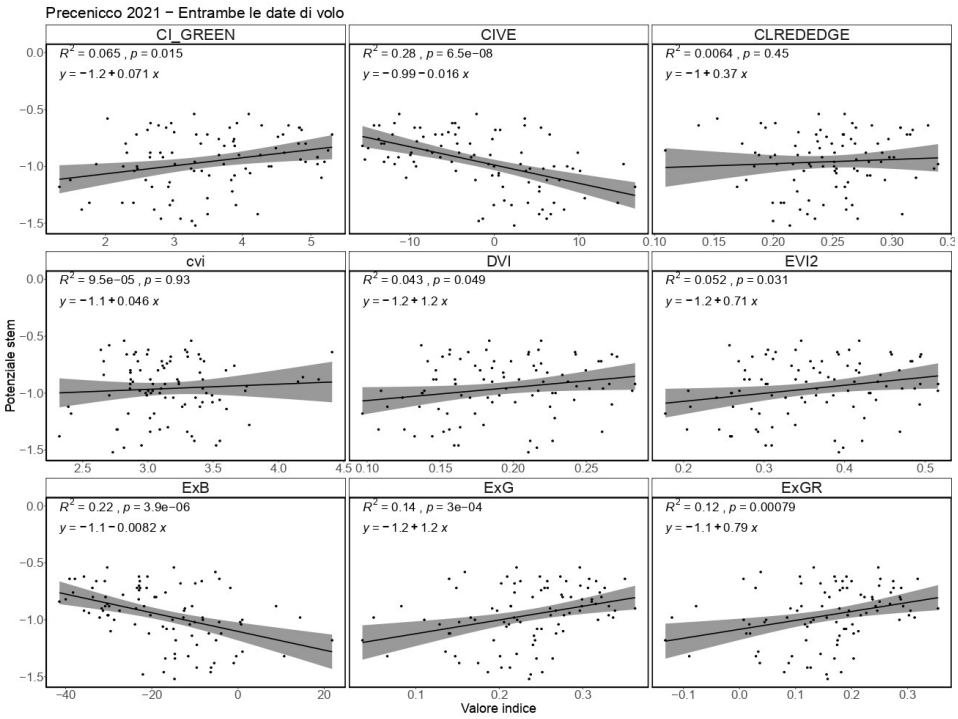

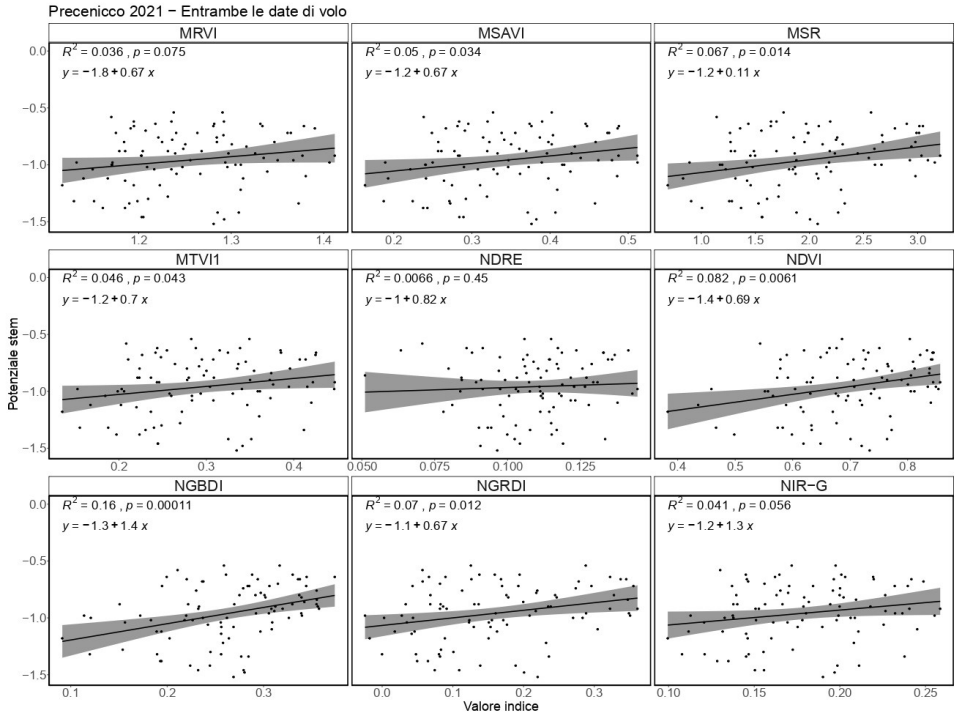
Precenicco 2021 − Entrambe le date di volo
MRVI
R^2 = 0.036 , p = 0.075
y = −1.8 + 0.67 x
MSAVI
R^2 = 0.05 , p = 0.034
y = −1.2 + 0.67 x
MSR
R^2 = 0.067 , p = 0.014
y = −1.2 + 0.11 x
MTVI1
R^2 = 0.046 , p = 0.043
y = −1.2 + 0.7 x
NDRE
R^2 = 0.0066 , p = 0.45
y = −1 + 0.82 x
NDVI
R^2 = 0.082 , p = 0.0061
y = −1.4 + 0.69 x
NGBDI
R^2 = 0.16 , p = 0.00011
y = −1.3 + 1.4 x
NGRDI
R^2 = 0.07 , p = 0.012
y = −1.1 + 0.67 x
NIR−G
R^2 = 0.041 , p = 0.056
y = −1.2 + 1.3 x
Potenziale stem
Valore indice

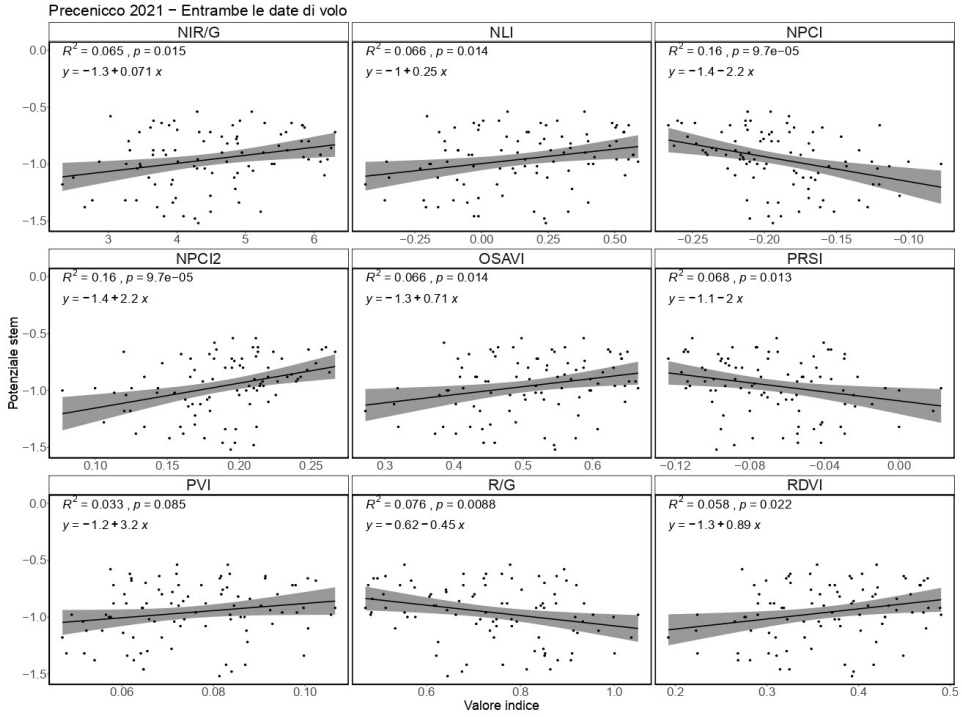
Precenicco 2021 − Entrambe le date di volo
NIR/G
R^2 = 0.065 , p = 0.015
y = −1.3 + 0.071 x
NLI
R^2 = 0.066 , p = 0.014
y = −1 + 0.25 x
NPCI
R^2 = 0.16 , p = 9.7e−05
y = −1.4 − 2.2 x
NPCI2
R^2 = 0.16 , p = 9.7e−05
y = −1.4 + 2.2 x
OSAVI
R^2 = 0.066 , p = 0.014
y = −1.3 + 0.71 x
PRSI
R^2 = 0.068 , p = 0.013
y = −1.1 − 2 x
PVI
R^2 = 0.033 , p = 0.085
y = −1.2 + 3.2 x
R/G
R^2 = 0.076 , p = 0.0088
y = −0.62 − 0.45 x
RDVI
R^2 = 0.058 , p = 0.022
y = −1.3 + 0.89 x
Potenziale stem
Valore indice

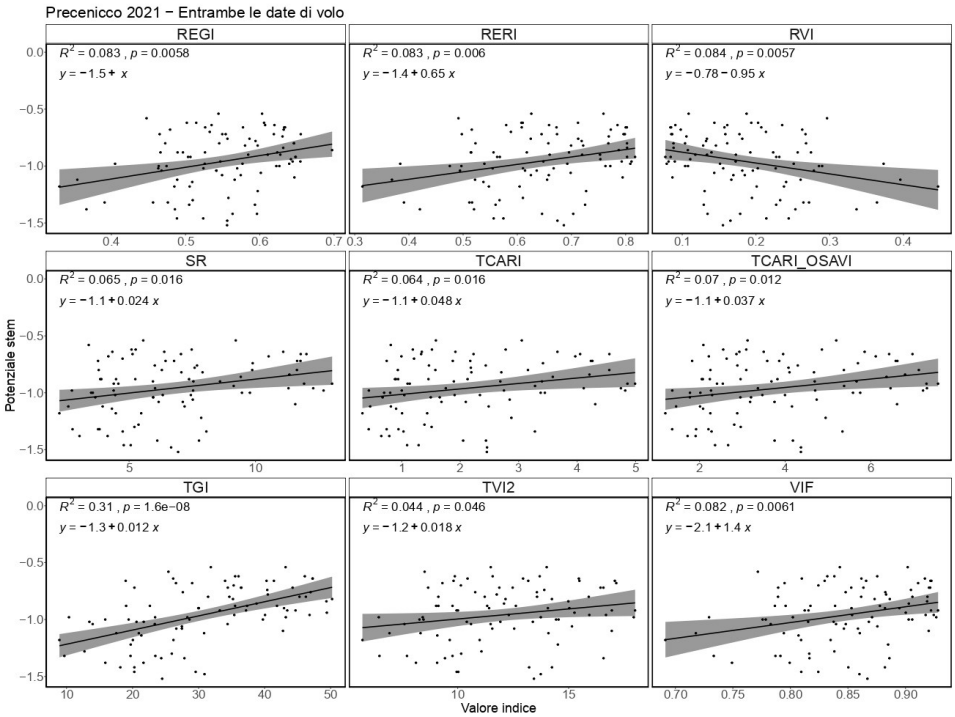
Precenicco 2021 − Entrambe le date di volo
REGI
R^2 = 0.083 , p = 0.0058
y = −1.5 + x
RERI
R^2 = 0.083 , p = 0.006
y = −1.4 + 0.65 x
RVI
R^2 = 0.084 , p = 0.0057
y = −0.78 − 0.95 x
SR
R^2 = 0.065 , p = 0.016
y = −1.1 + 0.024 x
TCARI
R^2 = 0.064 , p = 0.016
y = −1.1 + 0.048 x
TCARI_OSAVI
R^2 = 0.07 , p = 0.012
y = −1.1 + 0.037 x
TGI
R^2 = 0.31 , p = 1.6e−08
y = −1.3 + 0.012 x
TVI2
R^2 = 0.044 , p = 0.046
y = −1.2 + 0.018 x
VIF
R^2 = 0.082 , p = 0.0061
y = −2.1 + 1.4 x
Potenziale stem
Valore indice

Potenziale stem glera Precenicco – 29/07/2021

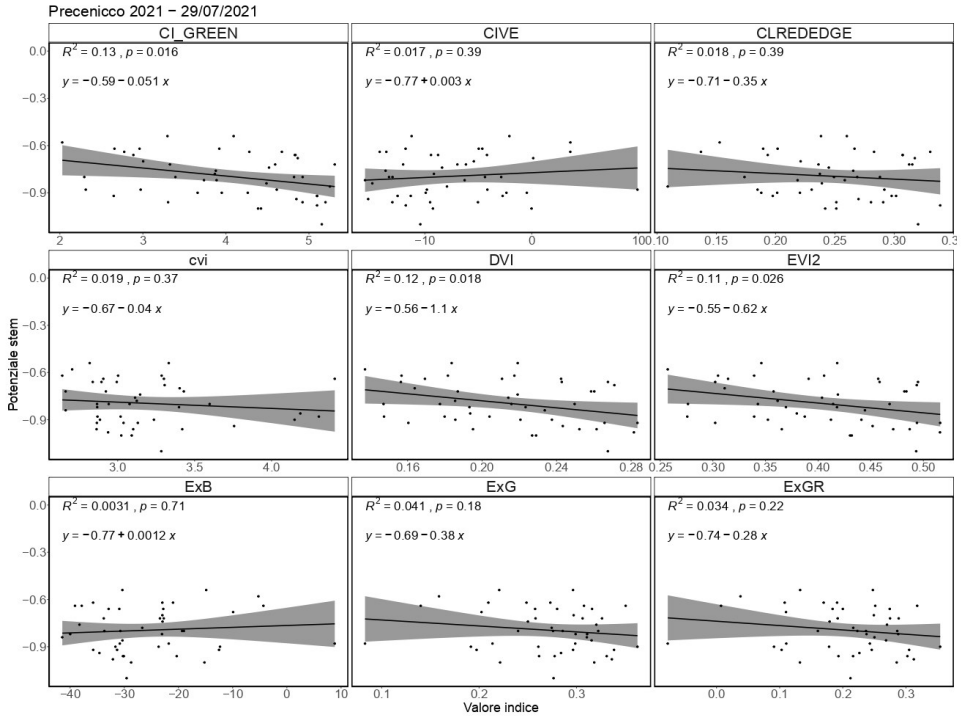

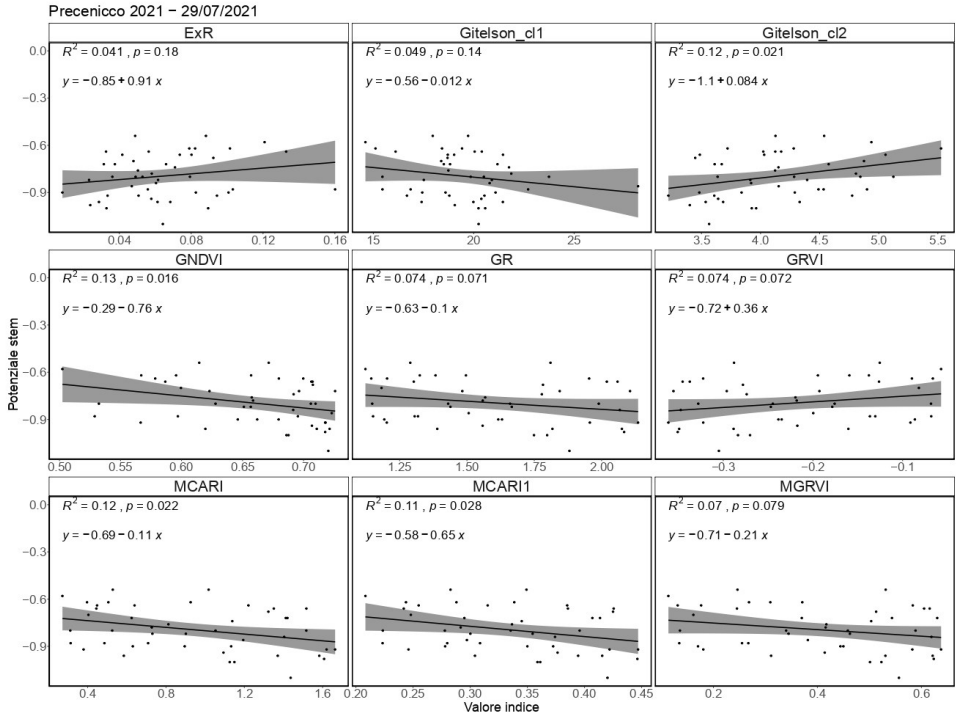

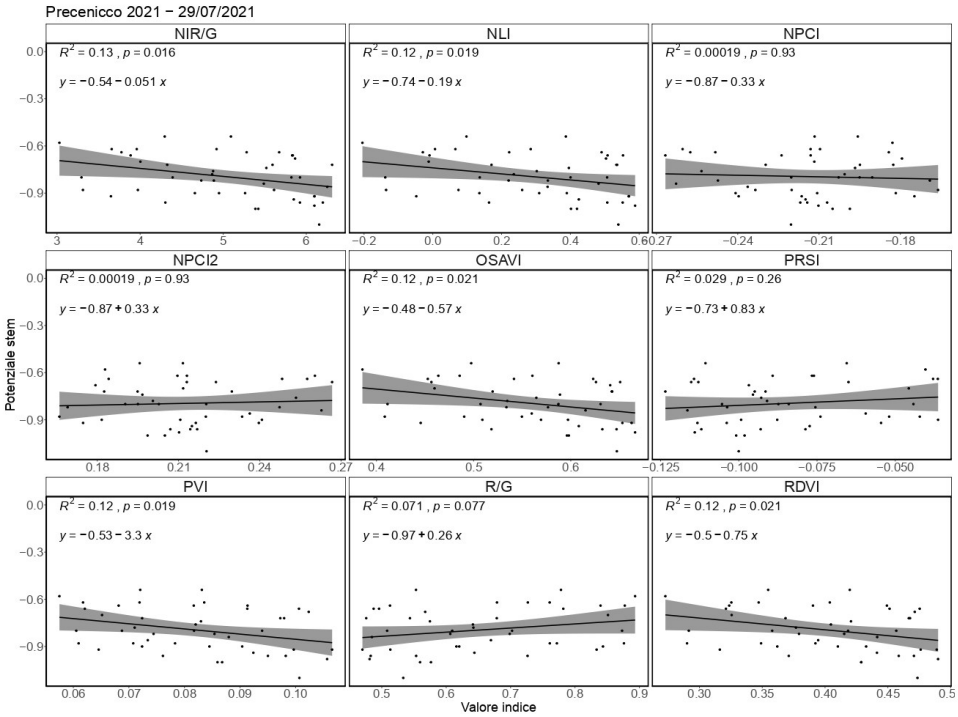
Precenicco 2021 − 29/07/2021
NIR/G
R^2 = 0.13 , p = 0.016
y = −0.54 − 0.051 x
NLI
R^2 = 0.12 , p = 0.019
y = −0.74 − 0.19 x
NPCI
R^2 = 0.00019 , p = 0.93
y = −0.87 − 0.33 x
NPCI2
R^2 = 0.00019 , p = 0.93
y = −0.87 + 0.33 x
OSAVI
R^2 = 0.12 , p = 0.021
y = −0.48 − 0.57 x
PRSI
R^2 = 0.029 , p = 0.26
y = −0.73 + 0.83 x
PVI
R^2 = 0.12 , p = 0.019
y = −0.53 − 3.3 x
R/G
R^2 = 0.071 , p = 0.077
y = −0.97 + 0.26 x
RDVI
R^2 = 0.12 , p = 0.021
y = −0.5 − 0.75 x
Potenziale stem
Valore indice

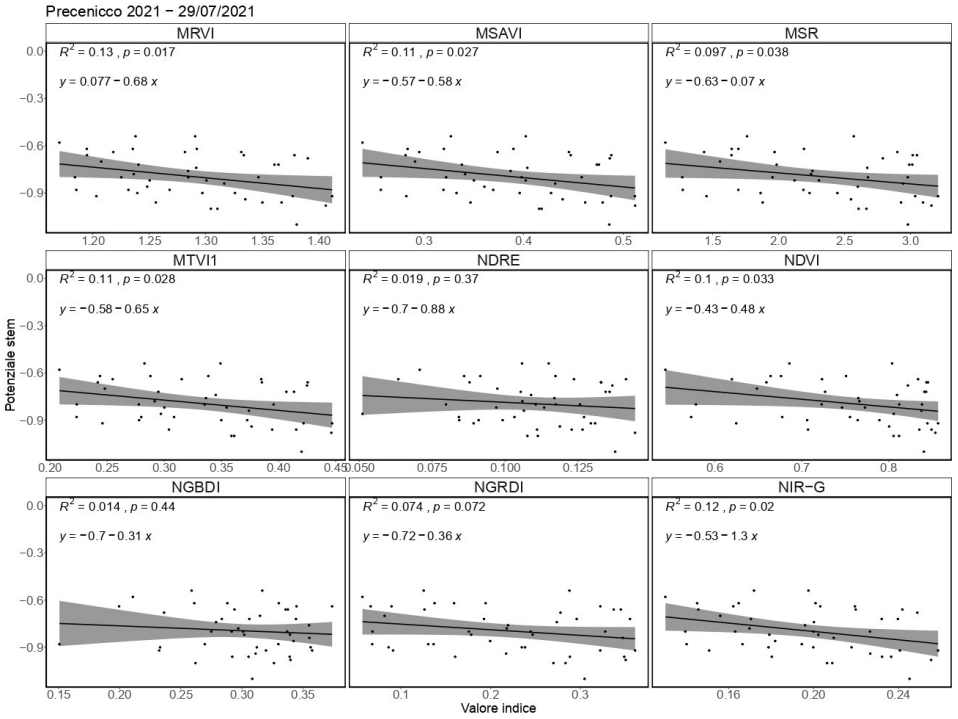
Precenicco 2021 − 29/07/2021
MRVI
R^2 = 0.13 , p = 0.017
y = 0.077 − 0.68 x
MSAVI
R^2 = 0.11 , p = 0.027
y = −0.57 − 0.58 x
MSR
R^2 = 0.097 , p = 0.038
y = −0.63 − 0.07 x
MTVI1
R^2 = 0.11 , p = 0.028
y = −0.58 − 0.65 x
NDRE
R^2 = 0.019 , p = 0.37
y = −0.7 − 0.88 x
NDVI
R^2 = 0.1 , p = 0.033
y = −0.43 − 0.48 x
NGBDI
R^2 = 0.014 , p = 0.44
y = −0.7 − 0.31 x
NGRDI
R^2 = 0.074 , p = 0.072
y = −0.72 − 0.36 x
NIR−G
R^2 = 0.12 , p = 0.02
y = −0.53 − 1.3 x
Potenziale stem
Valore indice

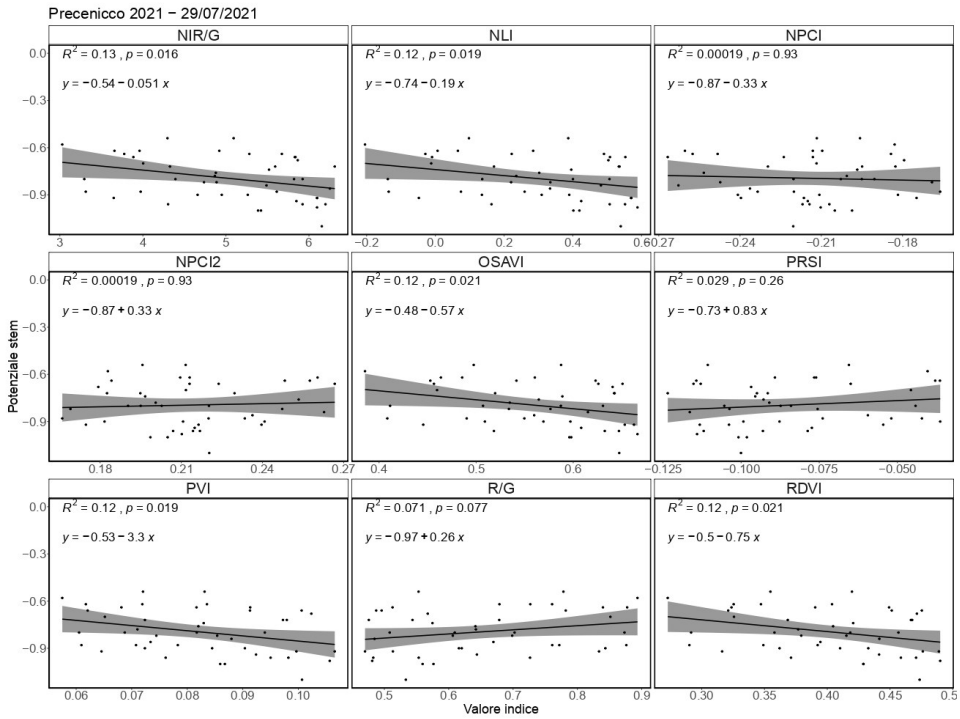
Precenicco 2021 − 29/07/2021
NIR/G
R^2 = 0.13 , p = 0.016
y = −0.54 − 0.051 x
NLI
R^2 = 0.12 , p = 0.019
y = −0.74 − 0.19 x
NPCI
R^2 = 0.00019 , p = 0.93
y = −0.87 − 0.33 x
NPCI2
R^2 = 0.00019 , p = 0.93
y = −0.87 + 0.33 x
OSAVI
R^2 = 0.12 , p = 0.021
y = −0.48 − 0.57 x
PRSI
R^2 = 0.029 , p = 0.26
y = −0.73 + 0.83 x
PVI
R^2 = 0.12 , p = 0.019
y = −0.53 − 3.3 x
R/G
R^2 = 0.071 , p = 0.077
y = −0.97 + 0.26 x
RDVI
R^2 = 0.12 , p = 0.021
y = −0.5 − 0.75 x
Potenziale stem
Valore indice

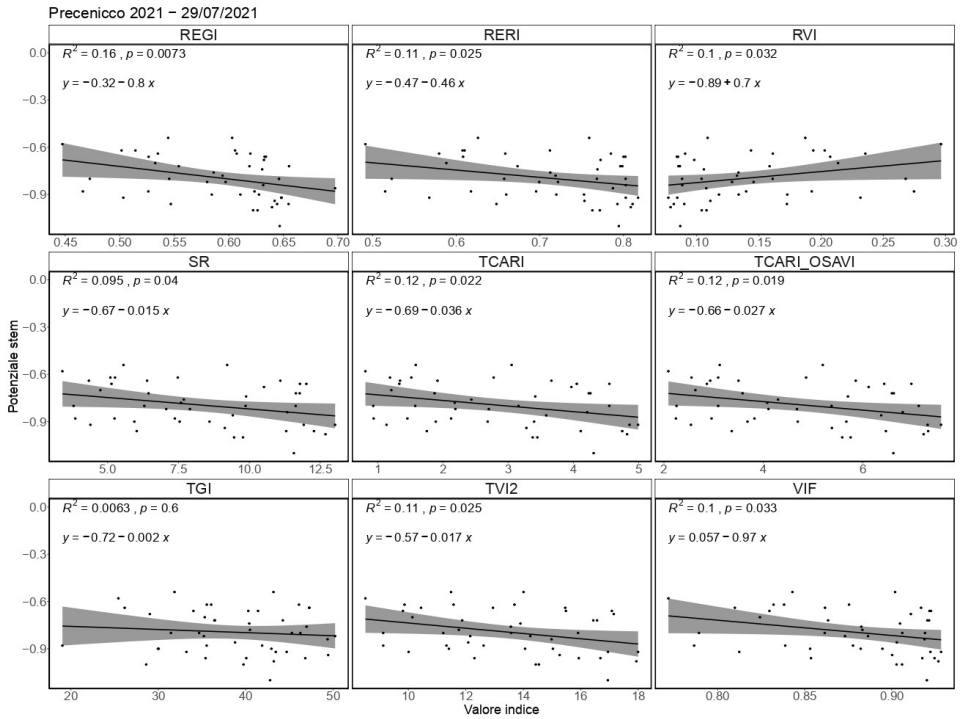
Precenicco 2021 − 29/07/2021
REGI
R^2 = 0.16 , p = 0.0073
y = −0.32 − 0.8 x
RERI
R^2 = 0.11 , p = 0.025
y = −0.47 − 0.46 x
RVI
R^2 = 0.1 , p = 0.032
y = −0.89 + 0.7 x
SR
R^2 = 0.095 , p = 0.04
y = −0.67 − 0.015 x
TCARI
R^2 = 0.12 , p = 0.022
y = −0.69 − 0.036 x
TCARI_OSAVI
R^2 = 0.12 , p = 0.019
y = −0.66 − 0.027 x
TGI
R^2 = 0.0063 , p = 0.6
y = −0.72 − 0.002 x
TVI2
R^2 = 0.11 , p = 0.025
y = −0.57 − 0.017 x
VIF
R^2 = 0.1 , p = 0.033
y = 0.057 − 0.97 x
Potenziale stem
Valore indice

Potenziale stem glera Precenicco – 24/08/2021

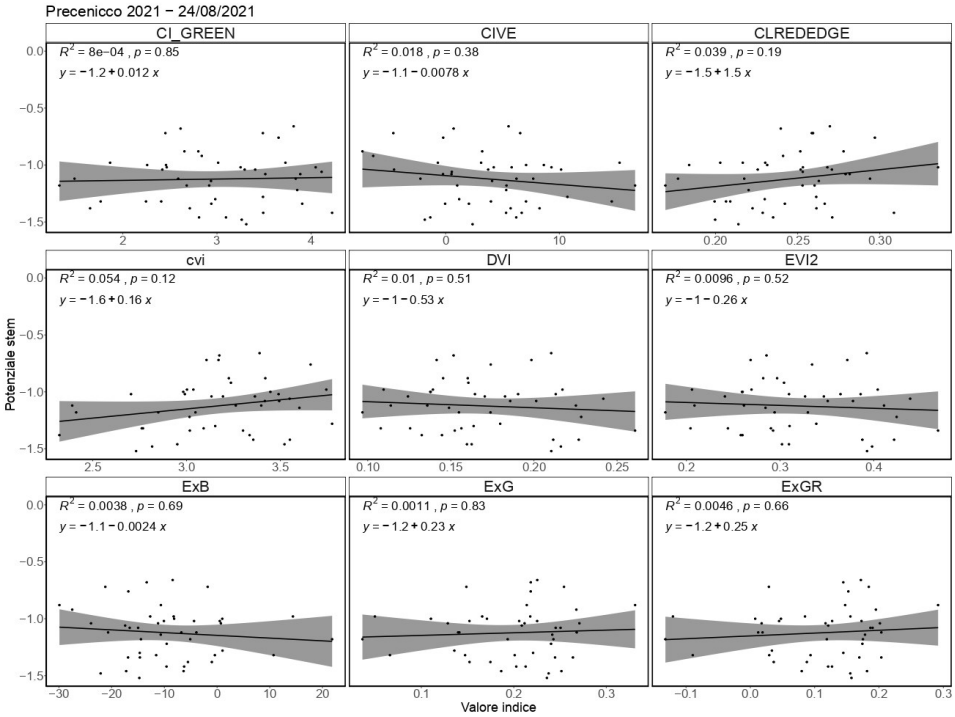

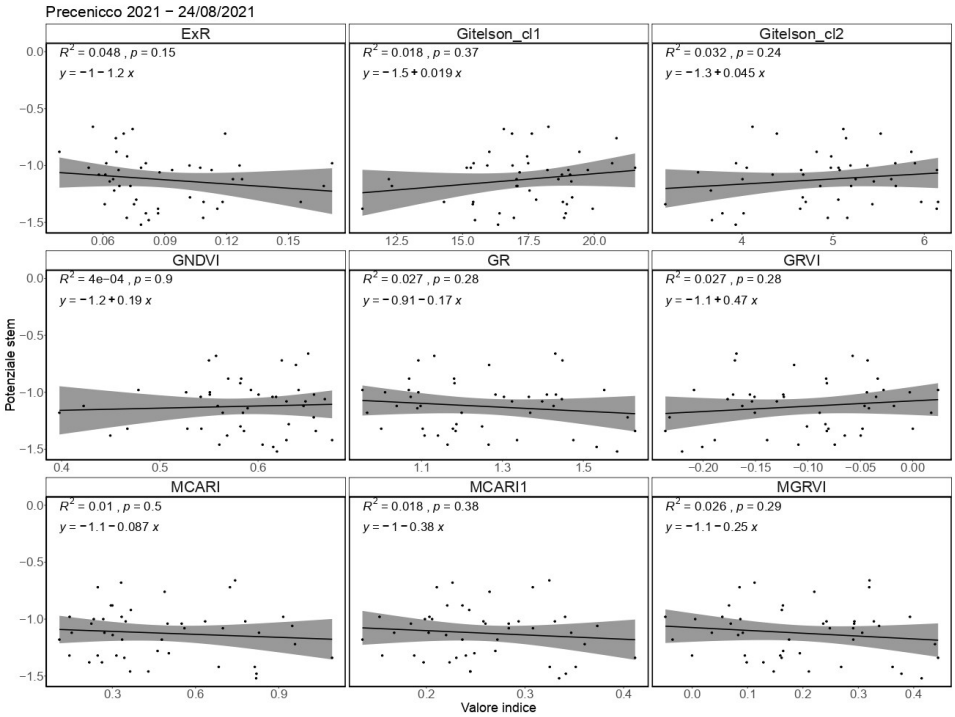

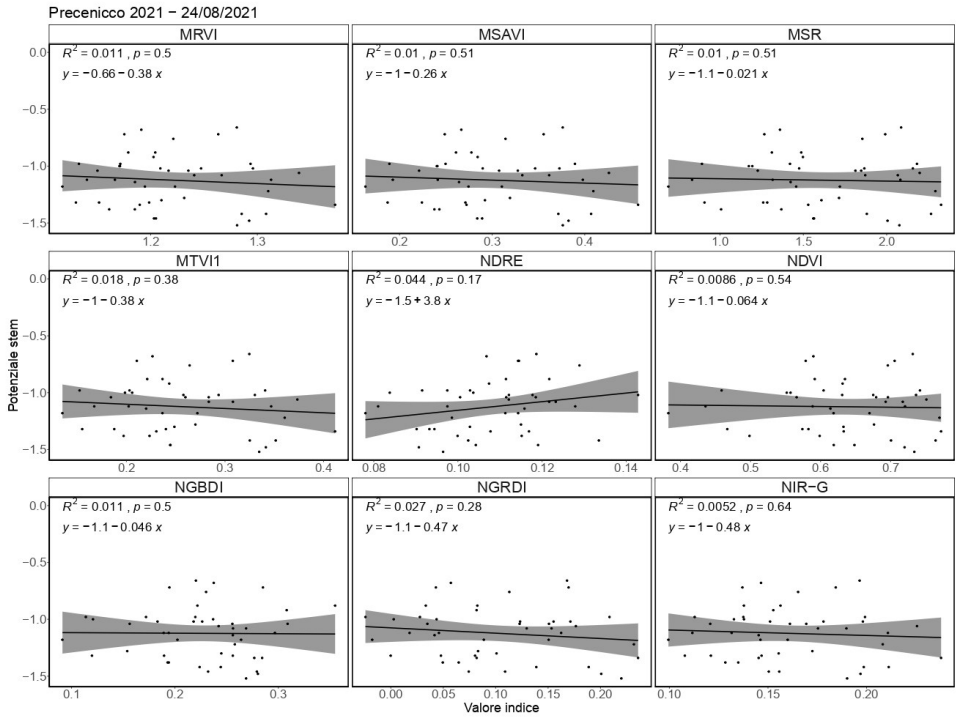
Precenicco 2021 − 24/08/2021
MRVI
R^2 = 0.011 , p = 0.5
y = −0.66 − 0.38 x
MSAVI
R^2 = 0.01 , p = 0.51
y = −1 − 0.26 x
MSR
R^2 = 0.01 , p = 0.51
y = −1.1 − 0.021 x
MTVI1
R^2 = 0.018 , p = 0.38
y = −1 − 0.38 x
NDRE
R^2 = 0.044 , p = 0.17
y = −1.5 + 3.8 x
NDVI
R^2 = 0.0086 , p = 0.54
y = −1.1 − 0.064 x
NGBDI
R^2 = 0.011 , p = 0.5
y = −1.1 − 0.046 x
NGRDI
R^2 = 0.027 , p = 0.28
y = −1.1 − 0.47 x
NIR−G
R^2 = 0.0052 , p = 0.64
y = −1 − 0.48 x
Potenziale stem
Valore indice

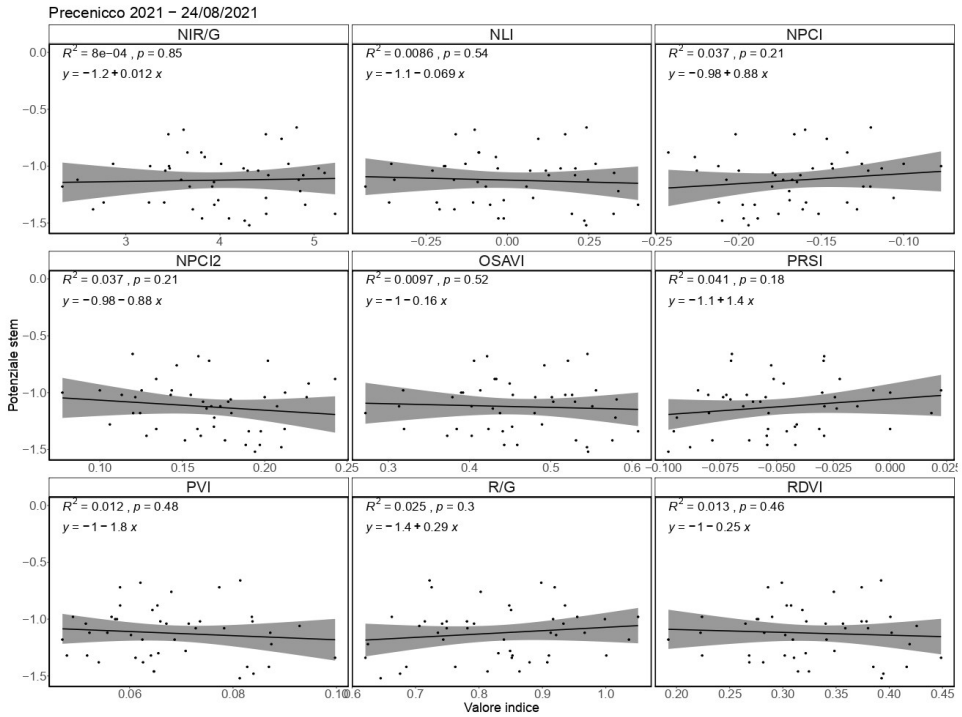
Precenicco 2021 − 24/08/2021
NIR/G
R^2 = 8e−04 , p = 0.85
y = −1.2 + 0.012 x
NLI
R^2 = 0.0086 , p = 0.54
y = −1.1 − 0.069 x
NPCI
R^2 = 0.037 , p = 0.21
y = −0.98 + 0.88 x
NPCI2
R^2 = 0.037 , p = 0.21
y = −0.98 − 0.88 x
OSAVI
R^2 = 0.0097 , p = 0.52
y = −1 − 0.16 x
PRSI
R^2 = 0.041 , p = 0.18
y = −1.1 + 1.4 x
PVI
R^2 = 0.012 , p = 0.48
y = −1 − 1.8 x
R/G
R^2 = 0.025 , p = 0.3
y = −1.4 + 0.29 x
RDVI
R^2 = 0.013 , p = 0.46
y = −1 − 0.25 x
Potenziale stem
Valore indice

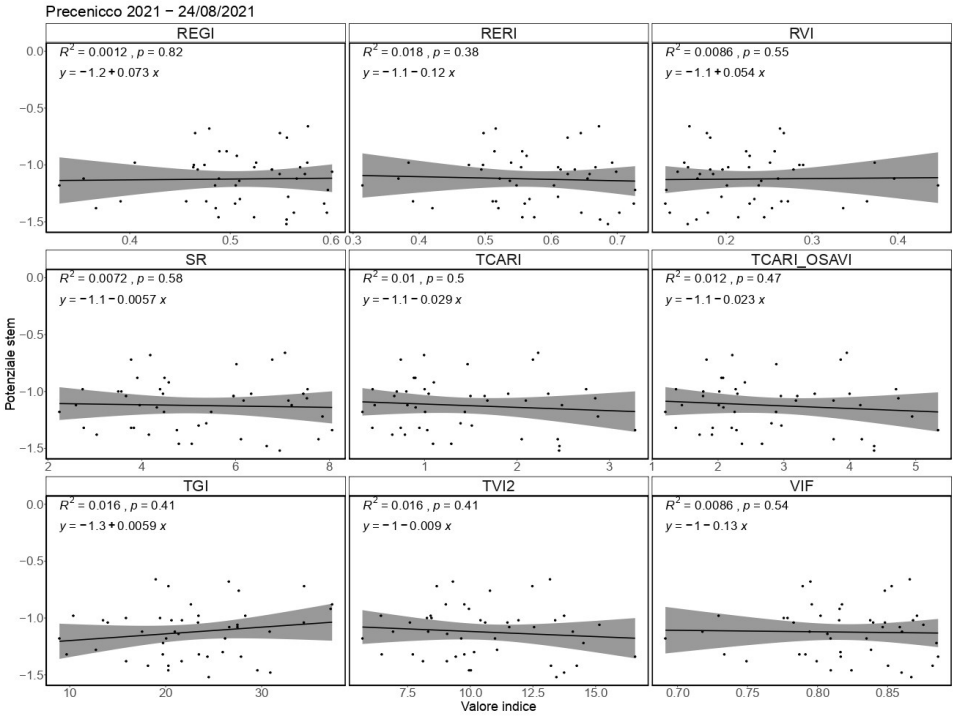
Precenicco 2021 − 24/08/2021
REGI
R^2 = 0.0012 , p = 0.82
y = −1.2 + 0.073 x
RERI
R^2 = 0.018 , p = 0.38
y = −1.1 − 0.12 x
RVI
R^2 = 0.0086 , p = 0.55
y = −1.1 + 0.054 x
SR
R^2 = 0.0072 , p = 0.58
y = −1.1 − 0.0057 x
TCARI
R^2 = 0.01 , p = 0.5
y = −1.1 − 0.029 x
TCARI_OSAVI
R^2 = 0.012 , p = 0.47
y = −1.1 − 0.023 x
TGI
R^2 = 0.016 , p = 0.41
y = −1.3 + 0.0059 x
TVI2
R^2 = 0.016 , p = 0.41
y = −1 − 0.009 x
VIF
R^2 = 0.0086 , p = 0.54
y = −1 − 0.13 x
Potenziale stem
Valore indice

Esca Precenicco – entrambe le date

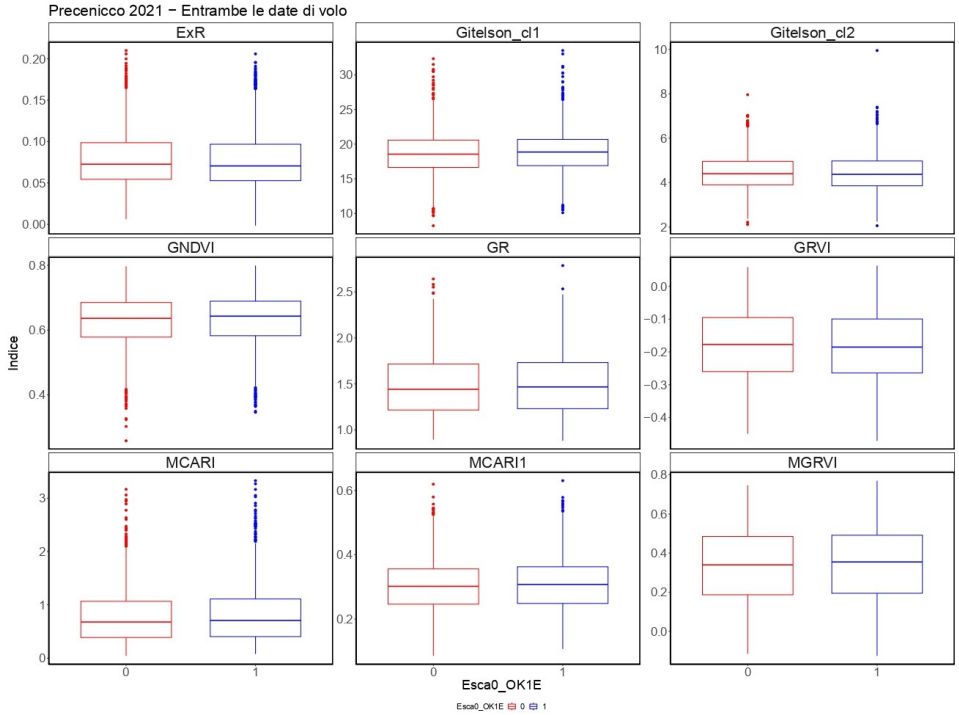

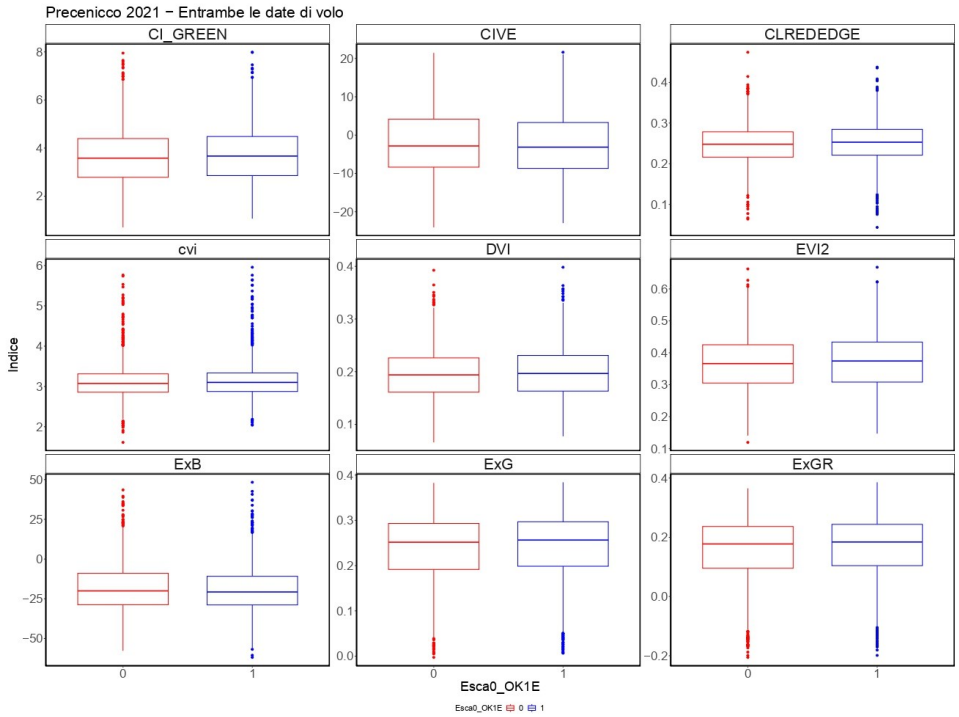

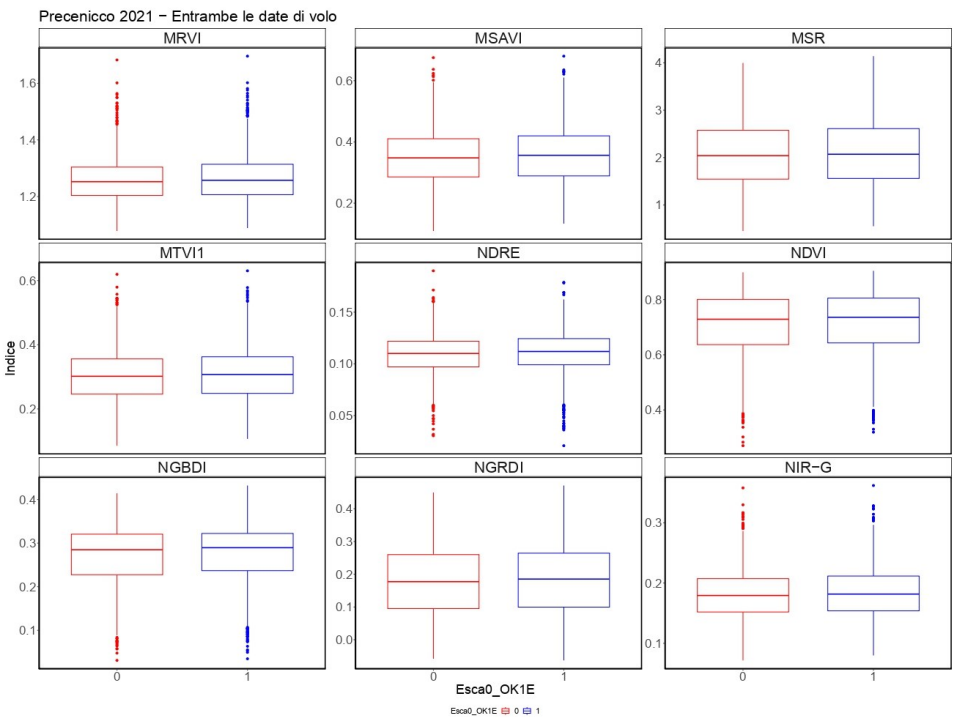
Precenicco 2021 − Entrambe le date di volo
MRVI
MSAVI
MSR
MTVI1
NDRE
NDVI
NGBDI
NGRDI
NIR−G
Indice
Esca0_OK1E
Esca0_OK1E 0 1

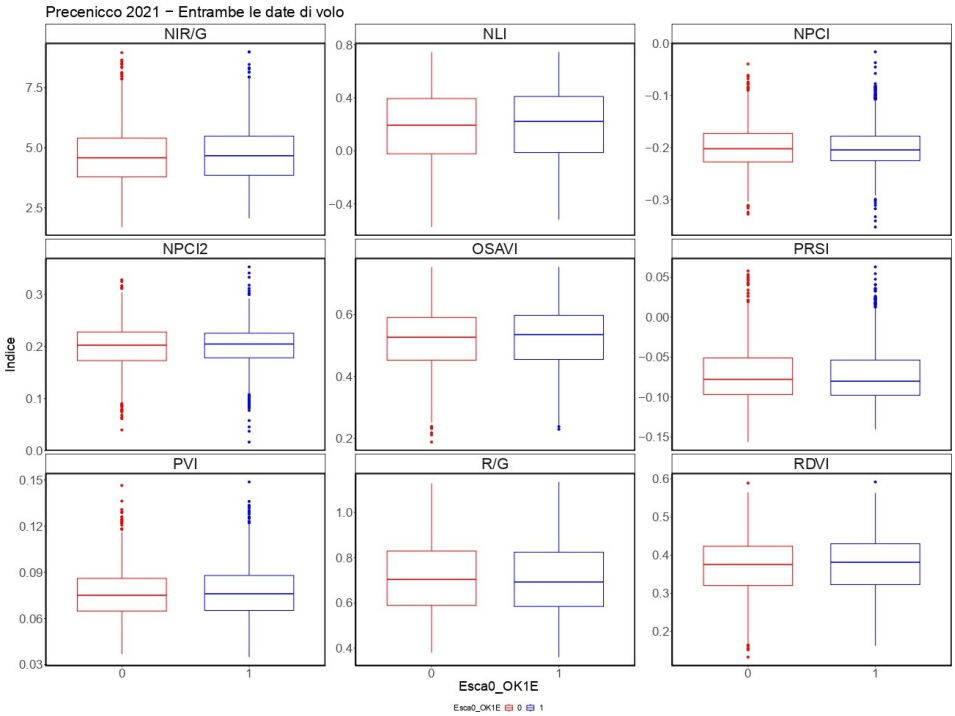
Precenicco 2021 − Entrambe le date di volo
NIR/G
NLI
NPCI
NPCI2
OSAVI
PRSI
PVI
R/G
RDVI
Indice
Esca0_OK1E
Esca0_OK1E 0 1

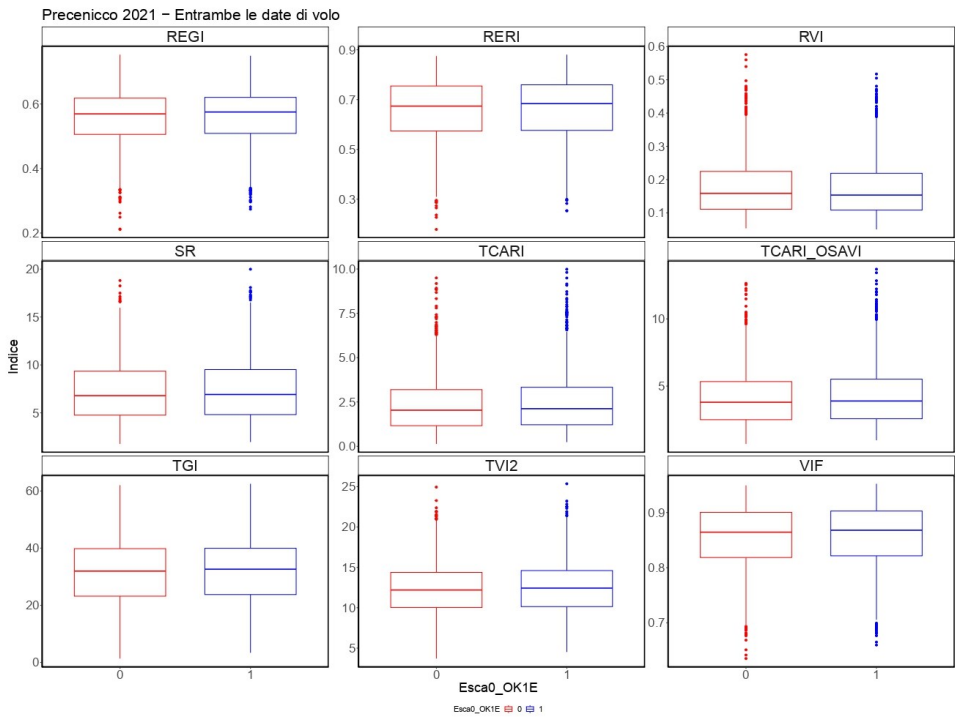
Precenicco 2021 − Entrambe le date di volo
REGI
RERI
RVI
SR
TCARI
TCARI_OSAVI
TGI
TVI2
VIF
Indice
Esca0_OK1E
Esca0_OK1E 0 1

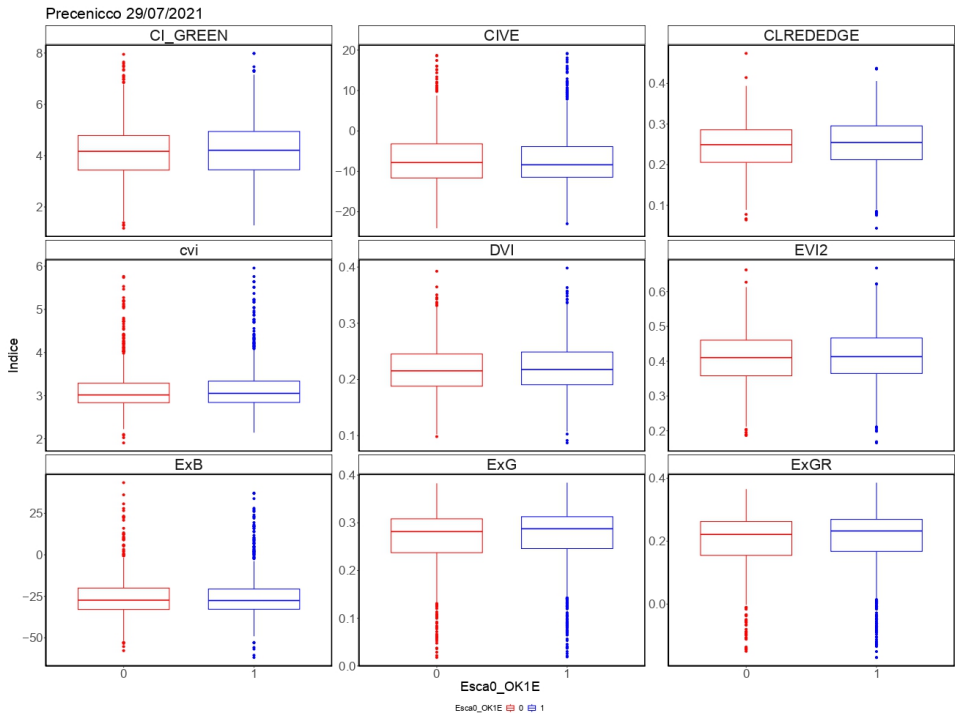
Precenicco 29/07/2021
CI_GREEN
CIVE
CLREDEDGE
cvi
DVI
EVI2
ExB
ExG
ExGR
Indice
Esca0_OK1E
Esca0_OK1E 0 1

Esca Precenicco – 29/07/2021

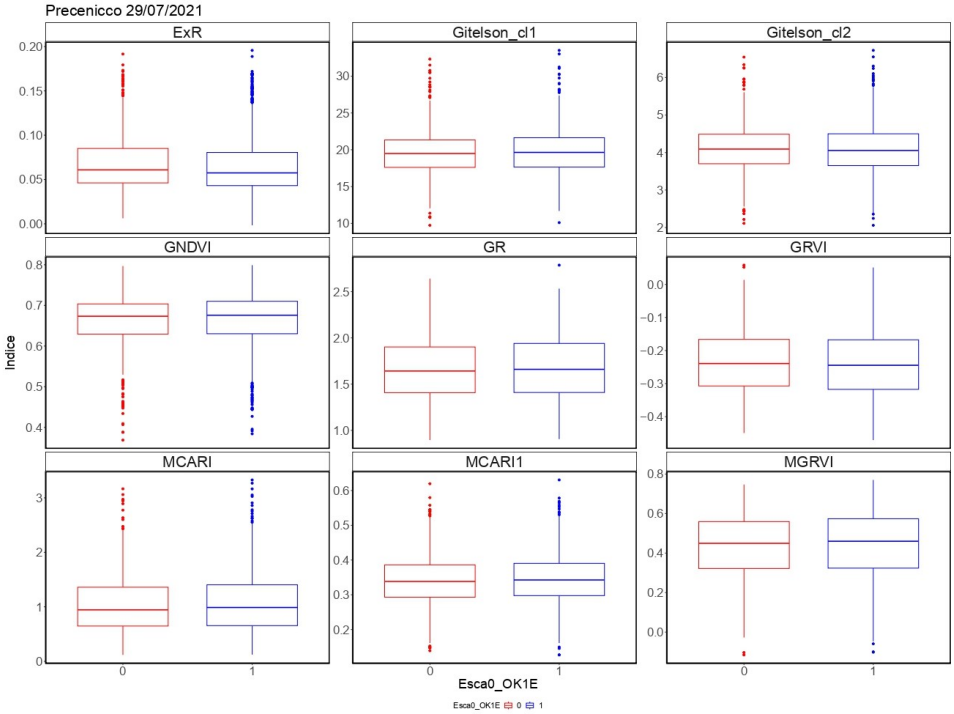

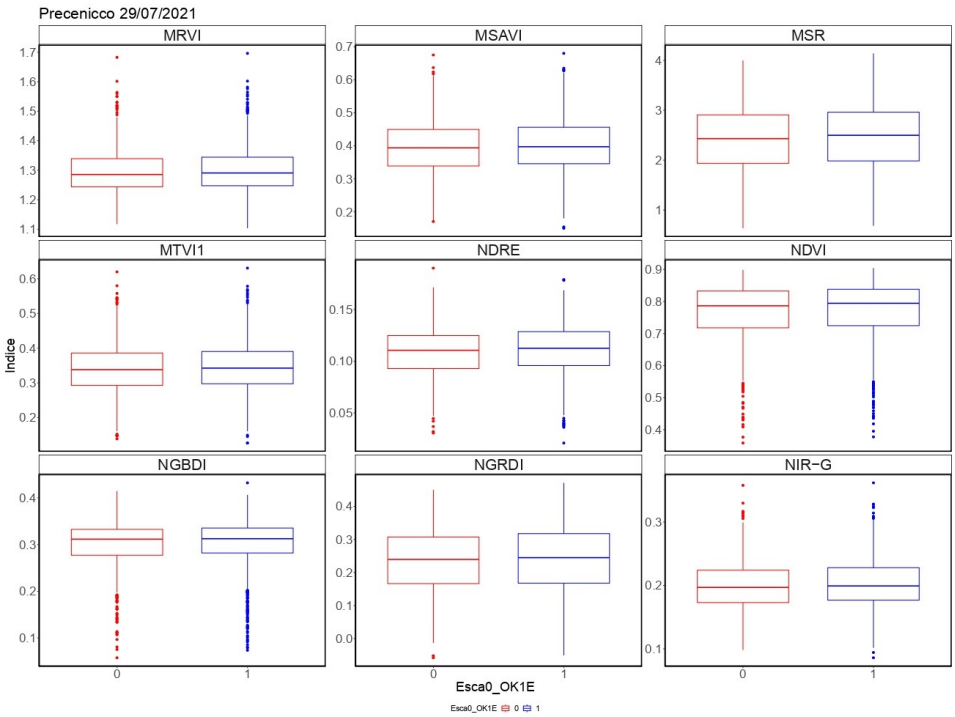

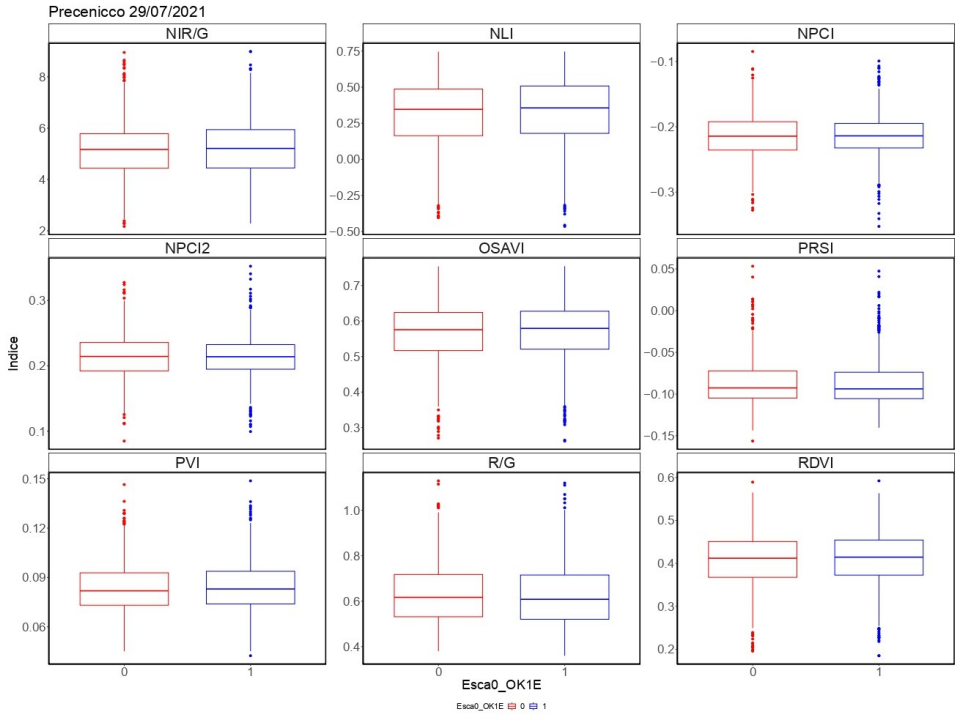
Precenicco 29/07/2021
NIR/G
NLI
NPCI
NPCI2
OSAVI
PRSI
PVI
R/G
RDVI
Indice
Esca0_OK1E
Esca0_OK1E 0 1

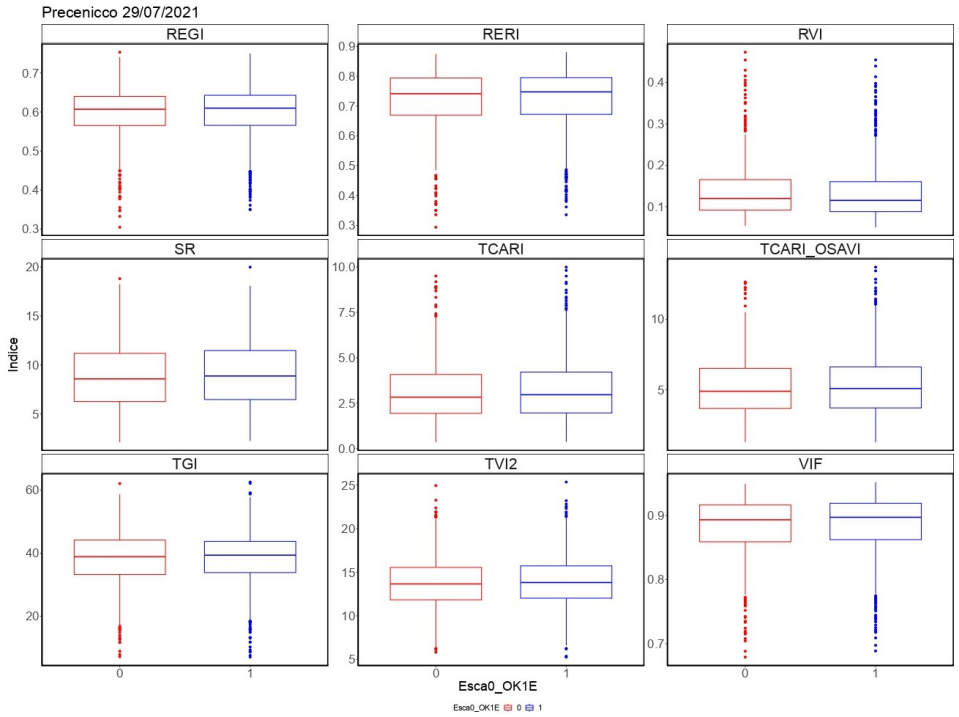
Precenicco 29/07/2021
REGI
RERI
RVI
SR
TCARI
TCARI_OSAVI
TGI
TVI2
VIF
Indice
Esca0_OK1E
Esca0_OK1E 0 1

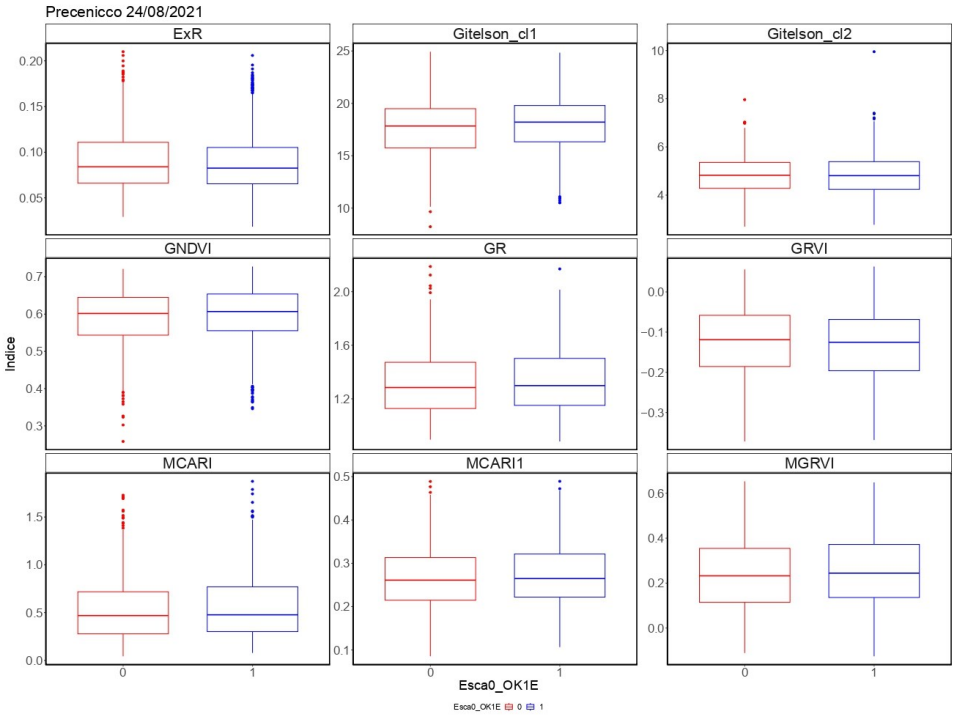
Precenicco 24/08/2021
ExR
Gitelson_cl1
Gitelson_cl2
GNDVI
GR
GRVI
MCARI
MCARI1
MGRVI
Indice
Esca0_OK1E
Esca0_OK1E 0 1

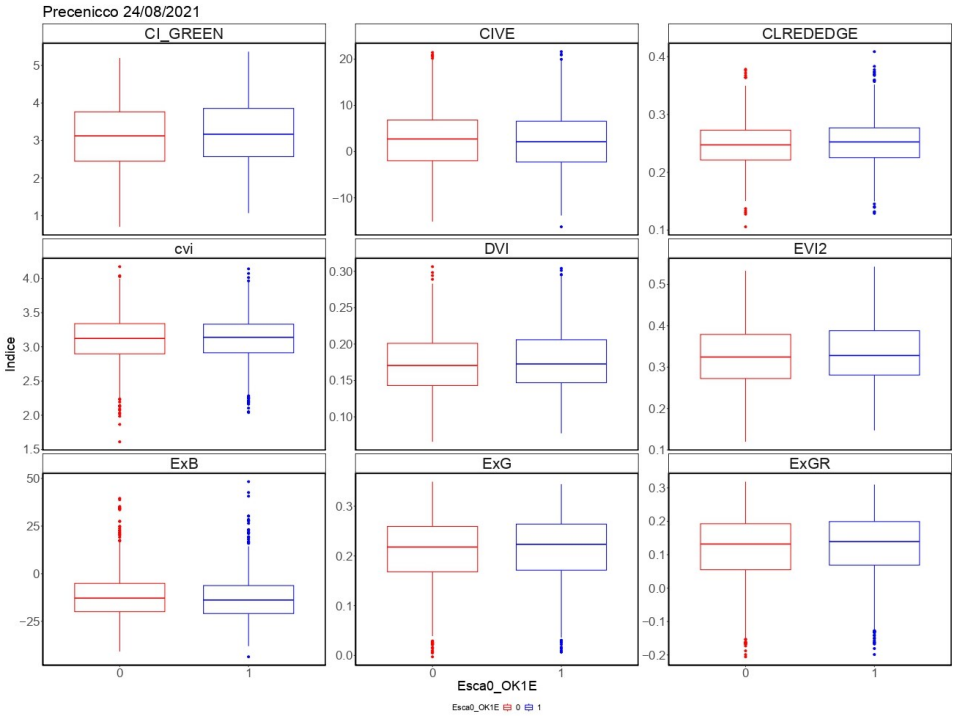
Precenicco 24/08/2021
CI_GREEN
CIVE
CLREDEDGE
cvi
DVI
EVI2
ExB
ExG
ExGR
Indice
Esca0_OK1E
Esca0_OK1E 0 1
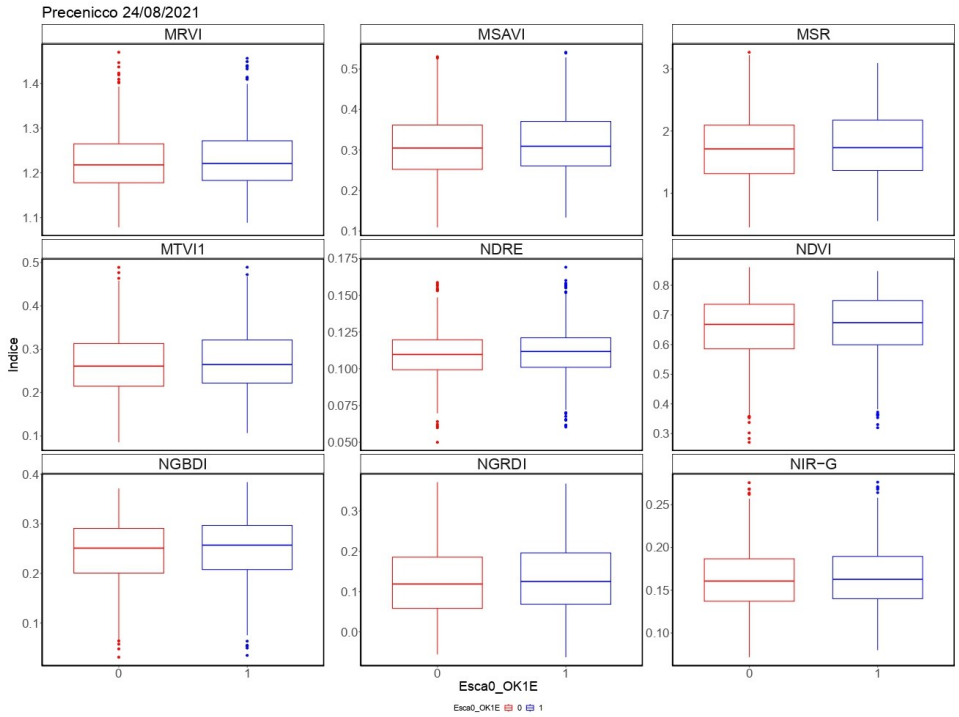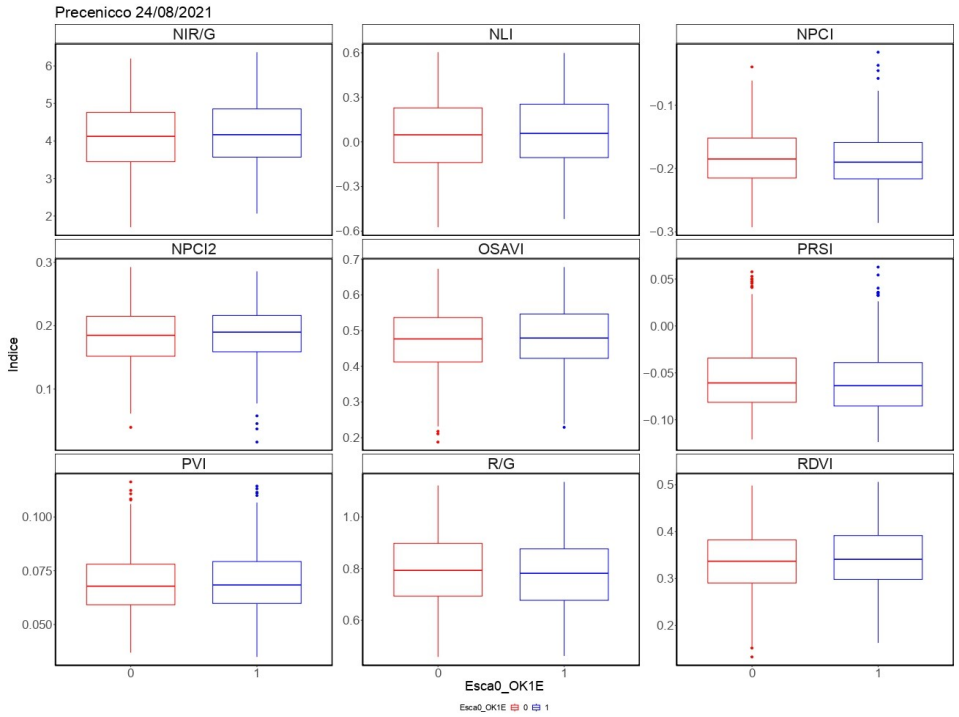
Esca Precenicco – 24/08/2021