

Monitoraggio operativo delle aree irrigate in Campania mediante l'utilizzo di dati di osservazione HLS.

Salvatore Falanga Bolognesi ^(a), Oscar Rosario Belfiore ^(a), Daniela De Medici ^(a), Carlo De Michele ^(a), Guido D'Urso ^(b)

^(a) Ariespace S.r.l. Spin off Company Università degli studi di Napoli Federico II, Centro Direzionale IS. A3, 80143 Napoli, Italia, tel+39 08119 56 42 82, fax +39 081 19 56 42 23, e-mail: salvatore.falanga@ariespace.com; oscar.belfiore@ariespace.com; daniela.demedici@ariespace.com; carlo.demichele@ariespace.com;

^(b) Dipartimento di Agraria, Università degli studi di Napoli Federico II, via Università 100, 80055, Italia, tel: +39 081 25 39 418, e-mail: durso@unina.it

Parole chiave: Harmonized Landsat 8-Sentinel-2, Classificazione di immagini satellitari, Machine Learning Algorithm, Aree Irrigate, Evapotraspirazione Potenziale, IRRISAT®.

Abstract

La mancanza di dati accurati e aggiornati sulle aree irrigate e dei relativi volumi irrigui ostacola la piena attuazione della direttiva quadro sulle acque e la sua conformità, soprattutto nelle regioni mediterranee. Questo studio illustra le procedure utilizzate nel progetto DIANA ed applicate all'interno dei Consorzi di Bonifica della regione Campania durante la stagione irrigua 2018, al fine di mappare le aree irrigate e stimare il corrispondente fabbisogno idrico. In tale studio sono state processate 202 tile derivanti dal prodotto Harmonized Landsat 8-Sentinel-2 (HLS) (57 per Landsat 8 e 145 per Sentinel-2). Per queste è stato derivato l'indice di vegetazione NDVI (Normalized Differential Vegetation Index) e successivamente si è operato uno smoothing ed un gap-filling. In zone aride e semi-aride l'analisi dell'andamento dell'indice NDVI comparato con le precipitazioni può consentire di distinguere più facilmente una coltura irrigata da una non irrigata (rainfed). A tal fine è stato considerato il prodotto di precipitazione satellitare globale ad alta risoluzione (4 km) PERSIANN-CCS. La fase successiva è stata la valutazione degli andamenti delle precipitazioni e dell'NDVI per i 2992 punti verità, suddivise per le classi erbaceo, arboreo, suolo nudo o ordinamento asciutto (rainfed). Lo step successivo ha riguardato la classificazione delle aree irrigate, a partire dalle serie multitemporali di NDVI e di precipitazione cumulata e le ground truth, in un processo di classificazione supervisionato, basato su algoritmi di machine learning. Le prestazioni delle classificazioni sono state valutate mediante le comuni metriche statistiche ricavate dalla matrice di confusione, utilizzando esclusivamente campioni di validazione. Verranno mostrati i risultati relativi alla stagione irrigua 2018, in cui è stata eseguita la valutazione di accuratezza delle procedure proposte con dati di verità a terra relativi alle aree effettivamente irrigate.

1. Introduzione

La mancanza di dati precisi e aggiornati riguardanti le aree irrigate e le corrispondenti quantità di irrigazione sta ostacolando la piena attuazione della

direttiva quadro sulle acque (WFD) e la sua conformità soprattutto nelle regioni del Mediterraneo. Nella maggior parte dei casi, i dati statistici acquisiti mediante indagini periodiche, hanno lo scopo di fornire un quadro a scala nazionale, ma sono piuttosto imprecisi a scala regionale e locale, che sono i dati più rilevanti per la gestione delle risorse idriche nei bacini idrografia. Il Ministero dell'Agricoltura italiano ha adottato azioni specifiche (Decreto 31/07/2015) per il monitoraggio periodico delle aree e dei volumi di irrigazione per migliorare la conformità alla Direttiva Acque.

Questo studio mostra le procedure che sono state utilizzate nell'ambito del Progetto DIANA (<http://diana-h2020.eu/en/>) e applicate ai Consorzi di irrigazione e di bonifica del territorio situato nella regione Campania (Sud Italia) durante la stagione irrigua 2018 (da aprile a ottobre), con l'obiettivo di mappare l'estensione effettiva delle aree irrigate e di valutare le corrispondenti quantità di irrigazione.

1.1 Il progetto HLS (Harmonized Landsat Sentinel-2)

I dati satellitari multispettrali derivati dal satellite della NASA Landsat 8 (LC8) e dal satellite dell'ESA Sentinel-2 (S2) rappresentano una preziosa fonte di informazioni per la loro vasta gamma spettrale, che va dal visibile all'infrarosso ad onde corte, e per l'elevato tempo di rivisitazione. Le caratteristiche spettrali e spaziali dei due satelliti (LC8 e S2) sono simili e l'utilizzo combinato può portare ad un numero più elevato di osservazioni e ad una maggiore precisione nelle analisi. Il progetto HLS (Claverie et al., 2018) ha lo scopo di "allineare" i dati di entrambi i programmi satellitari in modo che il loro uso combinato sia più semplice. L'obiettivo finale è quello di rimuovere le differenze tra i due sensori (OLI per LC8 e MSI per S2) in termini di bande spettrali e di geometria di acquisizione, al fine di ottenere una copertura globale della superficie terrestre con un intervallo di tempo di 2-3 giorni con una risoluzione spaziale di 30 m. Il flusso di lavoro per i dati HLS è schematizzato in Figura 1.

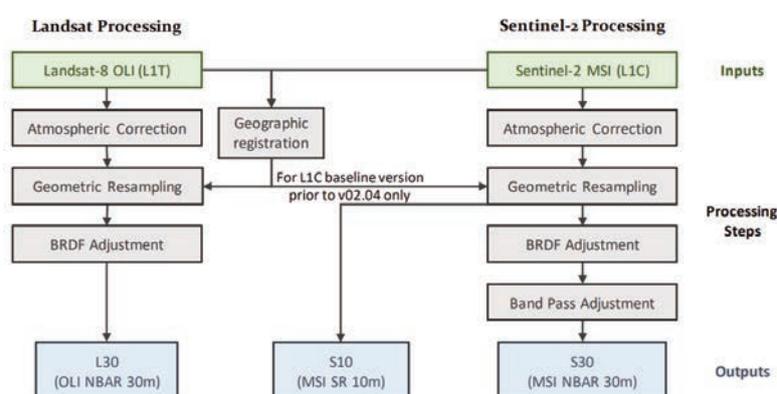


Figura 1 – Workflow di produzione dei dati HLS a partire da immagini multispettrali dai sensori OLI (LC8) ed MSI (S2).

Fondamentalmente, il processo che porta ai prodotti HLS finali inizia dai prodotti L1T (LC8 OLI) ed L1C (S2 MSI), sui quali viene applicato lo stesso algoritmo di correzione atmosferica; quindi i dati di Landsat vengono suddivisi geograficamente secondo il *tiling* S2; i dati di entrambi vengono quindi ricampionati geometricamente, utilizzando il pacchetto di co-registrazione

automatizzata AROP (Gao et al., 2009). Poiché gli angoli di acquisizione dei due sensori (OLI e MSI), per un determinato target a terra, presenta delle differenze, al fine di evitare discrepanze è necessario una normalizzazione (funzione di distribuzione della riflettanza bidirezionale o BRDF). L'ultimo passo è la regolazione della funzione di risposta spettrale delle bande, mediante un adattamento lineare tra bande spettrali equivalenti, applicata ai soli dati S2, utilizzando le bande spettrali OLI come riferimento (Claverie et al., 2018). I dati risultanti (Figura 1) sono L30 (OLI NBAR 30m), S10 (MSI SR 10m) e S30 (MSI NBAR 30m), ma solo il primo e il terzo prodotto saranno considerati parte del set di dati in questo lavoro.

2. Materiali e metodi

2.1 Dati satellitari

L'area di studio è la regione Campania, (Italia meridionale) e il periodo considerato è la stagione irrigua 2018 (Aprile-Ottobre). A tale scopo sono stati utilizzate serie multi-temporali derivanti dal prodotto HLS. La selezione delle date è stata operata sulle singole quattro *tiles* (T33TVE, T33TVF, T33TWE, T33TWF) ricadenti nell'area di studio (Fig. 2).



Figura 2 – Tiles HLS ed area di Studio (regione Campania).

Sono state selezionate 202 date, sulla base della copertura nuvolosa (inferiore al 20%) e prendendo in conto dati S2 per acquisizioni contemporanee a LC8. Nella Tabella 1 sono riportati i dati HLS utilizzati, per ciascuna *tiles* ricadente nell'area di studio, con i tempi di rivisitazione medi (TRm) in giorni.

Tabella 1 – Dati HLS considerati

Satellite/Tile	T33TVE	T33TVF	T33TWE	T33TWF	Totale
L30	11	16	17	13	57
S30	31	58	28	28	145
Totale	42	74	45	41	202
TRm (giorni)	8.7	4.9	8.1	8.9	

2.2 Pre-processing dei dati satellitari

Per ogni *tiles* sono state selezionate la banda del rosso (RED) (0,64 μm - 0,67 μm) e del vicino infrarosso NIR (0,85 μm - 0,88 μm), riportate in Tabella 2, utilizzate per la derivazione dell'indice di vegetazione NDVI (Tucker et al., 1979).

Tabella 2 – Caratteristiche delle bande acquisite dai due sensori (OLI e MSI) per il prodotto HLS (HLS Product User's Guide Product Version 1.4).

Nome Banda	OLI N° banda	MSI N° banda	HLS codice banda L8	HLS codice banda S2	Lunghezza d'onda (micron)
Coastal Aerosol	1	1	band01	B01	0.43-0.45*
Blue	2	2	band02	B02	0.45-0.51*
Green	3	3	band03	B03	0.53-0.59*
Red	4	4	band04	B04	0.64-0.67*
Red-Edge 1	-	5	-	B05	0.69-0.71**
Red-Edge 2	-	6	-	B06	0.73-0.75**
Red-Edge 3	-	7	-	B07	0.77-0.79**
NIR Broad	-	8	-	B08	0.78-0.88**
NIR Narrow	5	8A	band05	B8A	0.85-0.88*
SWIR 1	6	11	band06	B11	1.57-1.65*
SWIR 2	7	12	band07	B12	2.11-2.29*
Water vapor	-	9	-	B09	0.93-0.95**
Cirrus	9	10	band09	B10	1.36-1.38*

Il *quality layer* (QA), in formato raster, è un dato ancillare presente nel dataset HLS ed è derivato mediante l'applicativo FMASK (Zhu et al., 2015), la cui codifica è riportata in Tabella 3. Sulla base di tali informazioni, dal QA, selezionando i valori interi riportati in Tabella 4, è possibile una codifica in *Land* (1) e *no-Land* (0). Al fine di garantire una significativa riduzione del rumore e di artefatti derivanti da nuvole non rilevate e condizioni atmosferiche sfavorevoli, l'NDVI è stato sottoposto a un processo di *smoothing* e *gap-filling*. I calcoli sono stati eseguiti utilizzando la funzione *Whittaker smoother* (WS) (Eilers, 2003), disponibile nel pacchetto MODIS (Mattiuzzi et al., 2013) nell'ambiente R (R Core Team, 2013). Il processo di filtraggio con WS implica l'impostazione di alcuni parametri: numero di iterazioni, fissato a 1 (corrispondente a 2 cicli in esecuzione); lambda (parametro di smoothing), impostato su 2; numero di giorni, inteso come intervallo temporale di salvataggio dei dati di output (filtrati), è stato fissato pari a 5. Dopo il processo di filtraggio, con l'obiettivo di minimizzare gli effetti di bordo, è stato applicato uno *shape constraint*, basato su un'analisi statistica della serie NDVI non filtrata. Il prodotto finale di questa fase è una serie NDVI multi-temporale filtrata (senza nuvole), con un intervallo temporale di 5 giorni (n° 75 osservazioni durante l'anno 2018), tale da preservare le fenologie delle colture e tale da normalizzare le differenze nei tempi di rivisitazione, differenti per le quattro tiles afferenti l'area di studio.

Tabella 3 – Quality layer del dataset HLS, derivata dall’algoritmo FMASK.

Numero di Bit	QA descrizione	Combinazione di Bit	Descrizione
7-6	Aerosol Quality	00	Climatology
		01	Low
		10	Average
		11	High
5	Water	1	Yes
		0	No
4	Snow/ice	1	Yes
		0	No
3	Cloud Shadow	1	Yes
		0	No
2	Adjacent cloud	1	Yes
		0	No
1	Cloud	1	Yes
		0	No
0	Cirrus	1	Yes
		0	No

Tabella 4 – Valori interi selezionati dal quality layer (QA) per la derivazione della mappa binaria land (1), no-land (0).

Valore intero	bit 7	bit 6	bit 5	bit 4	bit 3	bit 2	bit 1	bit 0
0	0	0	0	0	0	0	0	0
4	0	0	0	0	0	1	0	0
64	0	1	0	0	0	0	0	0
68	0	1	0	0	0	1	0	0
128	1	0	0	0	0	0	0	0
132	1	0	0	0	0	1	0	0
192	1	1	0	0	0	0	0	0
196	1	1	0	0	0	1	0	0



Figura 3 – Tile T33TVF (Landsat 8) acquisita nel DoY 48 (2018): NDVI originale (sinistra); Maschera binaria (Land = 1, no-Land = 0) (centro); NDVI filtrato (destra)

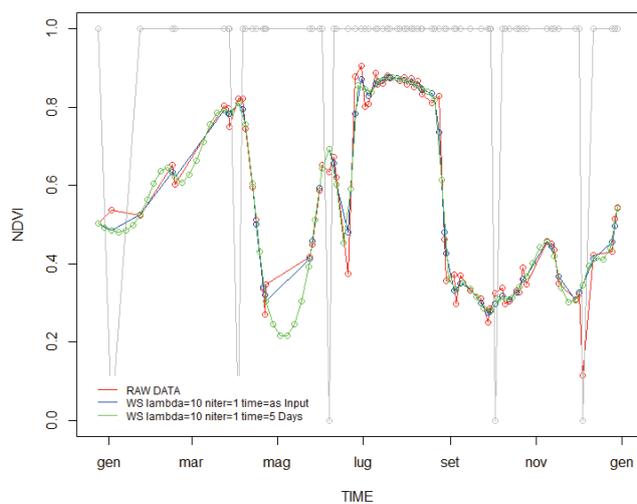


Figura 4 – NDVI e precipitazioni cumulate per coltura erbacea (maïs).

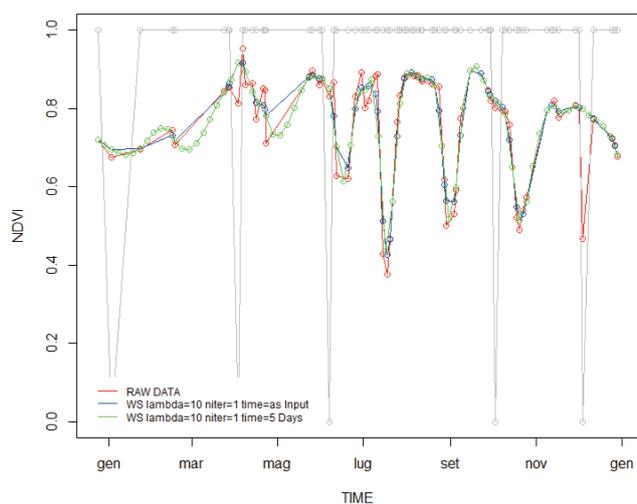


Figura 5 – NDVI e precipitazioni cumulate per coltura erbacea (erba medica).

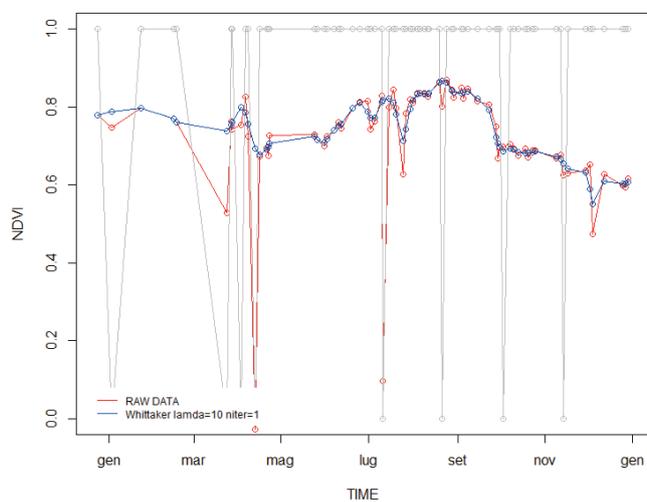


Figura 6 – NDVI e precipitazioni cumulate per tipo di coltura arborea.

Nelle figure 4, 5 e 6 la linea grigia assume due valori (0 e 1) in corrispondenza dell'NDVI con presenza di nuvole e senza nuvole, inoltre in blu e in verde sono indicati gli andamenti dell'NDVI secondo le date in output al filtraggio (5 giorni) rispetto alle date in input (date di acquisizione satellitare): tale confronto è utile a capire se l'intervallo temporale di salvataggio dei dati di output (filtrati), fissato pari a 5, riesce a preservare la fenologia delle colture di riferimento (legate alle verità acquisite in campo). Poiché, successivamente all'operazione di filtraggio, ciascuna *tiles* relativa all'area di studio possiede la stessa data, è stato possibile eseguita un'aggregazione spaziale a scala regionale: per ogni data in output a WS le quattro *tiles* sono state unite in un unico dato raster mediante mosaicatura operata in GDAL (Figura 7). Il prodotto finale è risultato come una serie temporale di 75 osservazioni nell'anno 2018 (Figura 7).

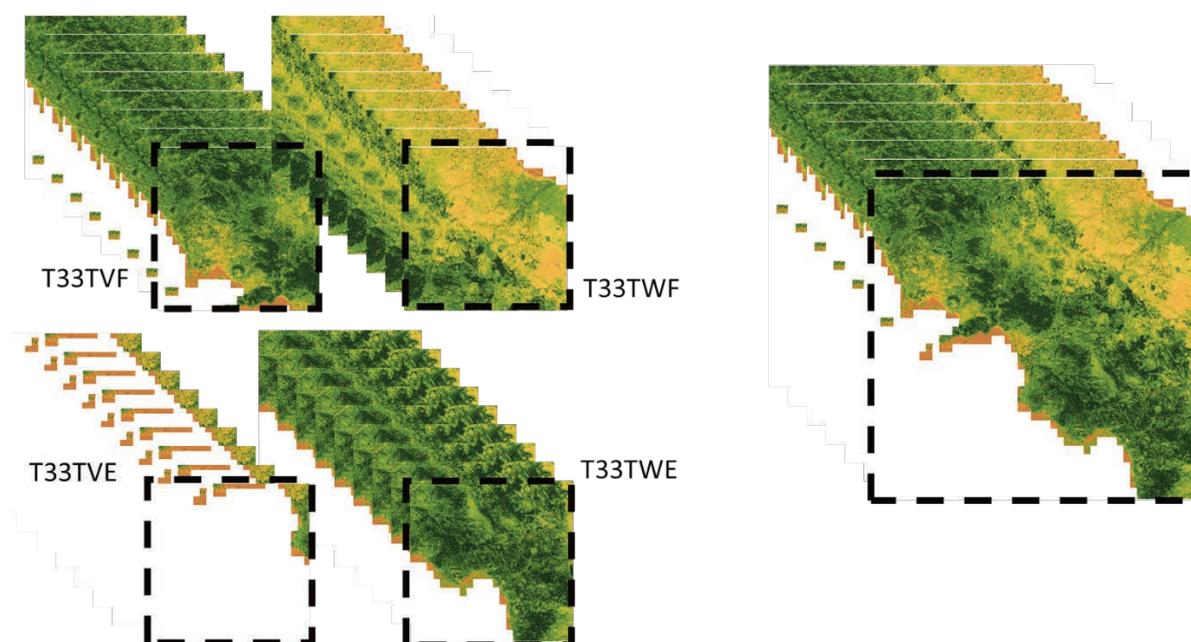


Figura 7 – Tiles coinvolte nel processo di aggregazione spaziale (sinistra) e prodotto finale dell'aggregazione spaziale (serie temporale di 75 osservazioni).

2.3. Verità acquisite in campo

Le verità, raccolte nell'area di studio mediante ispezioni dirette, utilizzando un tablet e un'app GIS (MAPIT) (Figura 8), sono state quindi separate nelle tre classi (tabella 5): suolo nudo e/o ordinamento asciutto (classe 0), colture erbacee (classe1), colture arboree (classe 2).



Figura 8 – Distribuzione per tiles delle verità raccolte in campo nei consorzi di bonifica (linea verde tratteggiata), all'interno dei limiti regionali (linea ciano continua).

Tabella 5 – Numero verità raccolte in campo, acquisite per tiles e per classe.

Classe/Tile	T33TVE	T33TVF	T33TWE	T33TWF	Totale
0	39	233	33	31	336
1	378	1179	244	96	1897
2	50	626	72	11	759
Totale	467	2038	349	138	2992

2.4. Pre-processamento del dato di precipitazione

Nelle aree aride e semi-aride, dove la crescita ottimale delle colture è possibile solo per irrigazione, l'analisi dell'andamento dell' NDVI rispetto alle precipitazioni può garantire una più facile discriminazione tra colture irrigate e colture non irrigate (*rainfed*). Per consentire questa analisi, è stato preso in considerazione il *PERSIANN-Cloud Classification System (PERSIANN-CCS)*, un prodotto di precipitazione satellitare globale in tempo reale ad alta risoluzione ($0.04^\circ \times 0.04^\circ$ o 4 km x 4 km), sviluppato dal Center for Hydrometeorology and Remote Sensing (CHRS) presso l'Università della California, Irvine (UCI).

Il prodotto PERSIANN-CCS è stato sottoposto ad un'aggregazione temporale (cumulati a 5 giorni secondo le date della serie multi-temporale NDVI filtrate), ad un ritaglio e ri-proiezione secondo la griglia HLS (unione di piastrelle T33TVF, T33TWF, T33TVE, T33TWE), derivata dalla griglia S2 (Figura 8).

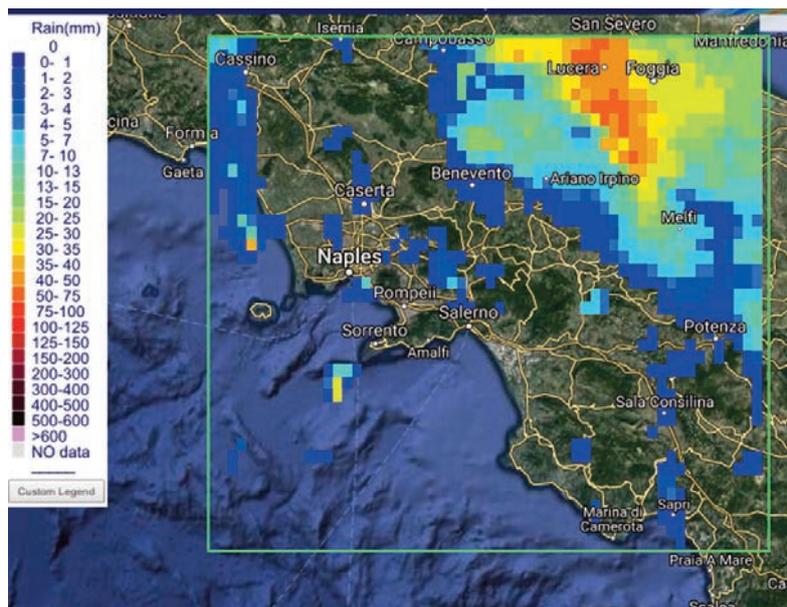


Figura 9 - *PERSIANN-Cloud Classification System (PERSIANN-CCS)* (<https://chrsdata.eng.uci.edu/>), all'estensione dell'area di studio.

Il prodotto di questo pre-processing è stato utilizzato per migliorare la discriminazione tra le aree irrigate e non irrigate, come precedentemente menzionato (paragrafo 2.5), ma sarà anche usato come secondo gruppo che prende parte all'input della classificazione finale (paragrafo 2.6).

2.5. Discriminazione tra colture *rainfed* e colture irrigate

L'analisi dell'andamento delle serie temporali NDVI rispetto alle precipitazioni cumulate consente la discriminazione tra aree in cui la vegetazione cresce in quanto irrigata (colture irrigate) ed aree in cui la vegetazione cresce in quanto alimentate dalla pioggia (colture *rainfed* o non irrigate): quando l'andamento delle serie temporali NDVI è in fase con le precipitazioni cumulate, la coltura è considerata "non irrigata", in quanto la crescita della coltura è strettamente correlato agli eventi di pioggia (Figura 10, a sinistra); viceversa per le serie temporali NDVI non sincronizzate con le precipitazioni cumulate, l'area è stata considerata "irrigata" poiché la crescita della coltura risulta strettamente legata all'irrigazione in quanto indipendente dal regime pluviometrico (Figura 10, a destra) .

2.6. Classificazione delle aree irrigate

Una volta definita la distinzione tra aree irrigate e non-irrigate a scala di punto pixel acquisito in campo, è stata implementata la classificazione delle aree irrigate per l'intera area di studio. Secondo la letteratura, gli approcci basati su *supervised classification* sono generalmente più accurati degli approcci basati su *unsupervised classification*.

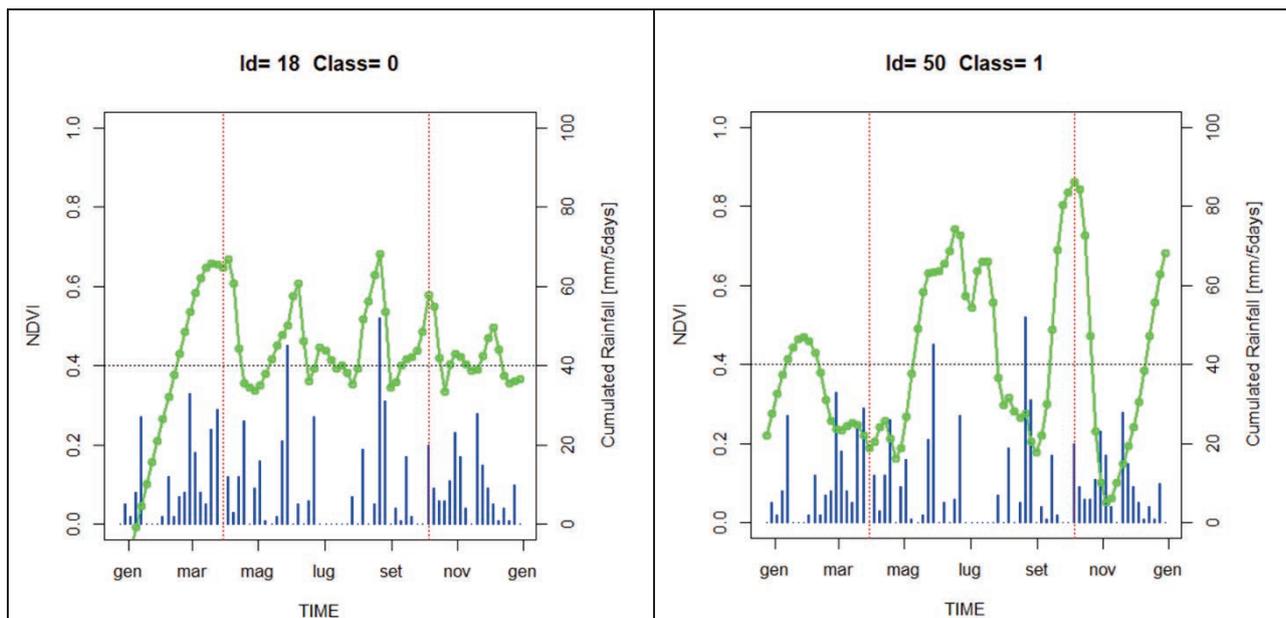


Figura 10 - Serie storiche combinate di VI (NDVI) e precipitazioni accumulate, finalizzate a migliorare la discriminazione tra vegetazione alimentata dalla pioggia e vegetazione irrigata. A sinistra, classe 0 (suolo nudo o coltura rainfed) con NDVI in fase con la precipitazione cumulata; a destra, classe 1 (coltura irrigua), NDVI non in fase con la precipitazione cumulata.

La classificazione è stata eseguita utilizzando sei differenti tipi di algoritmi di ML *supervised classification* al fine di utilizzare quello in grado di fornire la massima precisione. Gli algoritmi, elencati nella Tabella 6, addestrati (e quindi applicati), sono già stati ampiamente testati nelle classificazioni delle immagini satellitari. Oltre ai sei classificatori, sono state applicati quattro diversi *pre-processing* relativi alla selezione dei *dati di training*, conducendo a quattro diversi scenari, come mostrato nella Tabella 7.

Tabella 6 – Algoritmi e pacchetti utilizzati nel processo di classificazione.

Algoritmo	Package	Riferimento bibliografico
Random Forest (RF)	Ranger	(Wright et al.,2017)
Support Vector Machine (SVM) – RBF Kernel	Kernlab	(Karatzoglou et al.,2016)
Single Decision Trees (DT)	Rpart	(Therneau et al.,2017)
Boosted (DT)	C50	(Kuhn et al.,2015)
Artificial Neural Networks (ANN)	Nnet	(Ripley et al.,2016)
K-Nearest Neighbours (k-NN)	Caret	(Kuhn et al.,2015)

Tabella 7 – Scenari per tipologia di pre-processing dei dati di training.

Scenario	Pre-processing
1	None
2	Balanced training data
3	Feature selection
4	Balanced training data + feature selection

Più in dettaglio:

Lo scenario 1 comporta una classificazione eseguita con dati di *training* "originali" e numero di dati di input (*features* o covariate) pari al numero iniziale (75 date per l'indice NDVI e 75 date per la pioggia cumulata derivante dal dataset PERSIANN-CCS), per un totale di 150 *features*. Lo scenario 2 implica una classificazione eseguita utilizzando un set di dati di *training* bilanciato, basato su un metodo di *oversampling* casuale (applicato alla classe di minoranza), al fine di produrre lo stesso numero di campioni di addestramento per ciascuna classe. Lo scenario 3 implica una classificazione basata sui dati di *training* "originali" e su un processo di *recursive feature elimination* (RFE) (basato su RF), al fine di ridurre il numero di *features* utilizzate come input (minore del numero di partenza, pari a 150). Lo scenario 4 si basa sia sul set di dati di training bilanciato sia sul processo di RFE (basato su RF).

L'intero set di dati di riferimento (Tabella 5) è stato utilizzato nel processo di classificazione, ma i 2992 campioni sono stati sottoposti a due tipi di suddivisione: in un primo caso (caso A) il 25% dei dati di riferimento è stato utilizzato come "dati di addestramento" (748 campioni) e i restanti dati del 75% sono stati utilizzati come "dati di validazione" (2244 campioni) (Johnson, 2013, Johnson et al., 2013); al contrario del primo, nel secondo caso (caso B) il 75% dei dati di riferimento è stato utilizzato come *training data* e il restante 25% è stato utilizzato come *validation data*.

Dopo la suddivisione dei dati di riferimento, tutte le variabili sono state centrate e riscalate per una migliore coerenza, prima della classificazione.

L'ottimizzazione dei parametri è stata eseguita utilizzando un metodo di *k-fold cross-validation* ($k=10$), mediante il pacchetto R CARET (Kuhn et al., 2016) per ciascuno dei 6 algoritmi di classificazione. Il parametro *tune length* è stato impostato su 10 per valutare 10 valori per ciascun parametro. Quest'ultimo processo ha permesso la costruzione del modello basandosi sui parametri più performanti. Pertanto, alla fine sono state condotte 48 classificazioni (6 algoritmi per 4 scenari per 2 tipologie (25%-75% e 75%-25%) di partizionamento in *training* e *validation* dei dati di riferimento). I parametri migliori sono stati quindi utilizzati per creare un modello. Ogni modello creato è stato quindi applicato al set di dati di *validation*, precedentemente definito e indipendente dai dati di *training*.

2.7. Valutazione delle prestazioni delle classificazioni

Sulla base della matrice degli errori di classificazione, che è stata derivata dal set di dati di *validation*, sono state calcolate diverse misure statistiche comuni (Foody, 2002) al fine di stimare le prestazioni di classificazione di ciascun modello addestrato e quindi applicato. Le misure statistiche includono l'accuratezza complessiva (OA), l'accuratezza del produttore (PA) e l'accuratezza dell'utente (UA). Per la valutazione dell'OA, è stato considerato un livello di confidenza del 95% attraverso il normale metodo di approssimazione (Brown et al., 2001) insieme a una correzione della continuità. È stata anche calcolata la statistica non ponderata di *Kappa* (Galton, 1892; Smeeton, 1985; Siegel, 1956). Inoltre, la significatività statistica è stata valutata mediante il *p-value*, secondo il test di McNemar con una correzione della continuità (Siegel, 1956).

3 Risultati: stima delle aree irrigate

Tabella 8 - OA e statistica kappa non ponderata, valutate per scenario ed algoritmo, nell'ambito della suddivisione delle verità in campo di tipo A (25% addestramento; 75% Validazione).

Scenario	Pre-processing	Accuracy measure	RF	SVM	DT	Boosted DT	ANN	k-NN
1	None	OA (%)	86.3%	84.5%	78.5%	86.0%	81.2%	75.8%
		Kappa	0.725	0.698	0.596	0.719	0.639	0.535
2	Balanced training data	OA (%)	87.8%	82.7%	77.2%	86.2%	78.7%	64.2%
		Kappa	0.766	0.669	0.595	0.730	0.604	0.440
3	Feature selection	OA (%)	86.7%	87.8%	78.1%	86.4%	81.7%	80.2%
		Kappa	0.740	0.770	0.572	0.730	0.665	0.655
4	Balanced training data + feature selection	OA (%)	87.5%	84.3%	77.5%	86.6%	80.0%	71.5%
		Kappa	0.763	0.721	0.596	0.744	0.638	0.543

Nella Tabella 8 sono mostrati l'OA e la statistica Kappa non ponderata calcolata per ciascun modello e per ogni scenario. Come evidenziato in grassetto, la percentuale di OA e il valore Kappa più elevati sono ottenuti dal modello RF per lo scenario 1, lo scenario 2 e lo scenario 4. Solo per lo scenario 3, SVM si è dimostrato il modello con le statistiche di rendimento più elevate. Lo scenario 3 per il modello SVM (Tabella 8) è risultato il caso con le migliori prestazioni.

L'algoritmo di classificazione SVM nello scenario 3, come riportato in Tabella 8, è il prodotto di una *recursive features selection* che consiste nel partire da 150 variabili o *features* e per queste si cerca il numero e la selezione esatta che massimizza l'accuratezza e i valori di kappa. Come evidenziato in Fig. 11, sono state selezionate 41 *features*, corrispondenti a un valore di precisione di 0,8997 e un valore di kappa di 0,8017.

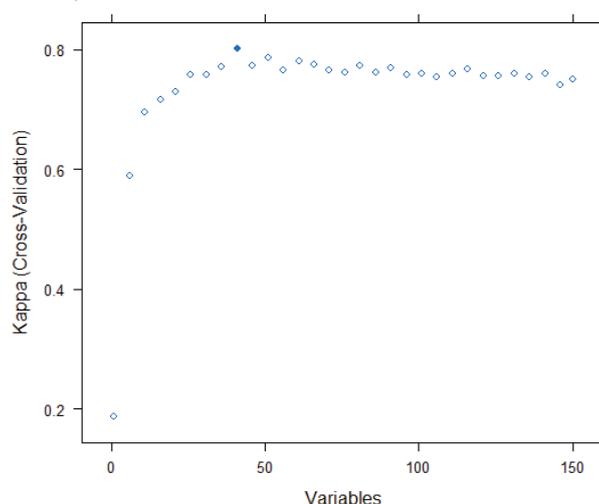


Figura 11 – Massimizzazione di Kappa (C-V) per numero e selezione esatta di feature (algoritmo con le statistiche di rendimento più elevate (SVM) nell'ambito della suddivisione delle verità in campo A e per lo scenario 3 (feature selection).

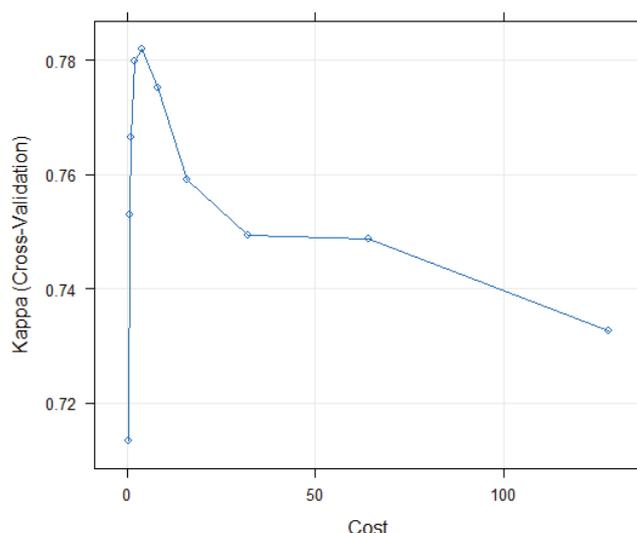


Figura 12 – Parametro di costo e relativi valori Kappa restituiti per numero e selezione esatta di feature (algoritmo con le statistiche di rendimento più elevate (SVM) nell’ambito della suddivisione delle verità in campo A e per lo scenario 3 (feature selection)).

Tra tutte le 41 *features* selezionate si sottolinea come le serie NDVI siano risultate più importanti delle *features* precipitazioni, poiché queste ultime non incluse tra le 41 selezionate. Una volta terminata la messa a punto dei parametri, è stato finalmente possibile applicare il classificatore e calcolare le statistiche già mostrate nella Tabella 8. Le stesse elaborazioni sono state eseguite suddividendo i dati di riferimento in diverse partizioni: 75% dei dati di addestramento (2244 campioni) e 25% dei dati di validazione (748 campioni), come precedentemente menzionato.

Tabella 9 - OA e statistica kappa non ponderata, valutate per scenario ed algoritmo, nell’ambito della suddivisione delle verità in campo di tipo b (75% addestramento; 25% Validazione).

Scenario	Pre-processing	Accuracy measure	RF	SVM	DT	D	ANN	k-NN
1	None	Overall accuracy (%)	90.5%	86.9%	81.3%	89.8%	83.2%	80.5%
		Kappa	0.814	0.744	0.630	0.802	0.675	0.637
2	Balanced training data	Overall accuracy (%)	90.4%	87.2%	76.2%	90.6%	76.7%	70.5%
		Kappa	0.814	0.759	0.593	0.821	0.580	0.525
3	Feature selection	Overall accuracy (%)	90.5%	88.0%	81.3%	90.8%	83.7%	81.3%
		Kappa	0.880	0.766	0.630	0.821	0.691	0.653
4	Balanced training data + feature selection	Overall accuracy (%)	90.6%	88.2%	76.2%	90.1%	81.4%	71.4%
		Kappa	0.820	0.777	0.595	0.809	0.653	0.540

Diversamente dalla prima suddivisione dei campioni (Tabella 8), questo caso (Tabella 9) mostra i valori di prestazione più elevati, in termini di valore OA e Kappa, nel modello RF per Scenario 1 e Scenario 4 e nel modello *Boosted DT* per

Scenario 2 e Scenario 3. Lo scenario 3 per il modello SVM è risultato il caso con le migliori prestazioni (Tabella 9) è risultato il caso con le migliori prestazioni. Proprio come la prima suddivisione dei campioni (A), in questo caso (B) lo scenario migliore è risultato quello che implicava la selezione della *features*. In questo caso, sono state selezionate 126 delle 150 *features*, tra cui anche in questo caso (B) come nel precedente (A) compaiono le sole *features* legate ai dati di NDVI.

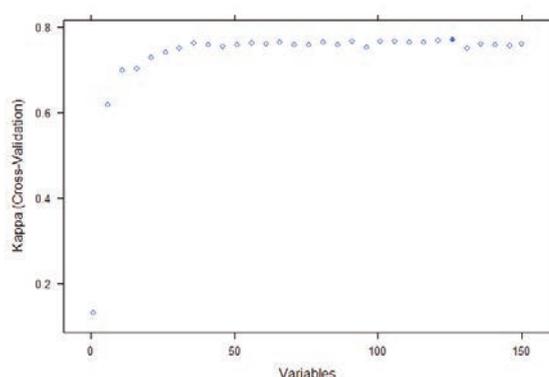


Figura 13 – Massimizzazione di Kappa (C-V) per numero e selezione esatta di feature (algoritmo con le statistiche di rendimento più elevate (Boosted DT) nell’ambito della suddivisione delle verità in campo B e per lo scenario 3 (feature selection).

Dopo la fase di selezione delle caratteristiche, anche in questo caso è stata effettuata la messa a punto dei parametri del modello, al fine di scegliere attraverso un metodo di *k-fold cross validation*, i parametri che massimizzavano il valore kappa. I valori finali utilizzati per il modello sono risultate trials = 90, model = tree e winnow = FALSE (Figura 14).

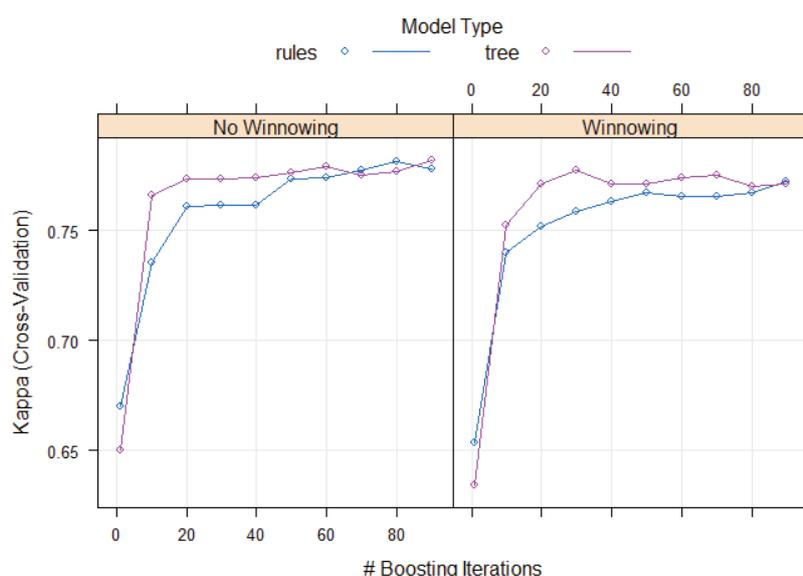


Figura 14 – Tuning dei parametri in funzione dei valori Kappa restituiti per numero e selezione esatta di feature (algoritmo con le statistiche di rendimento più elevate (Boosted DT) nell’ambito della suddivisione delle verità in campo B e per lo scenario 3 (feature selection).

In figura 15 sono mostrati i risultati della classificazione, in formato raster, per ciascun scenario in cui le prestazioni erano ottimali e nel primo caso (A) di suddivisione dei dati.

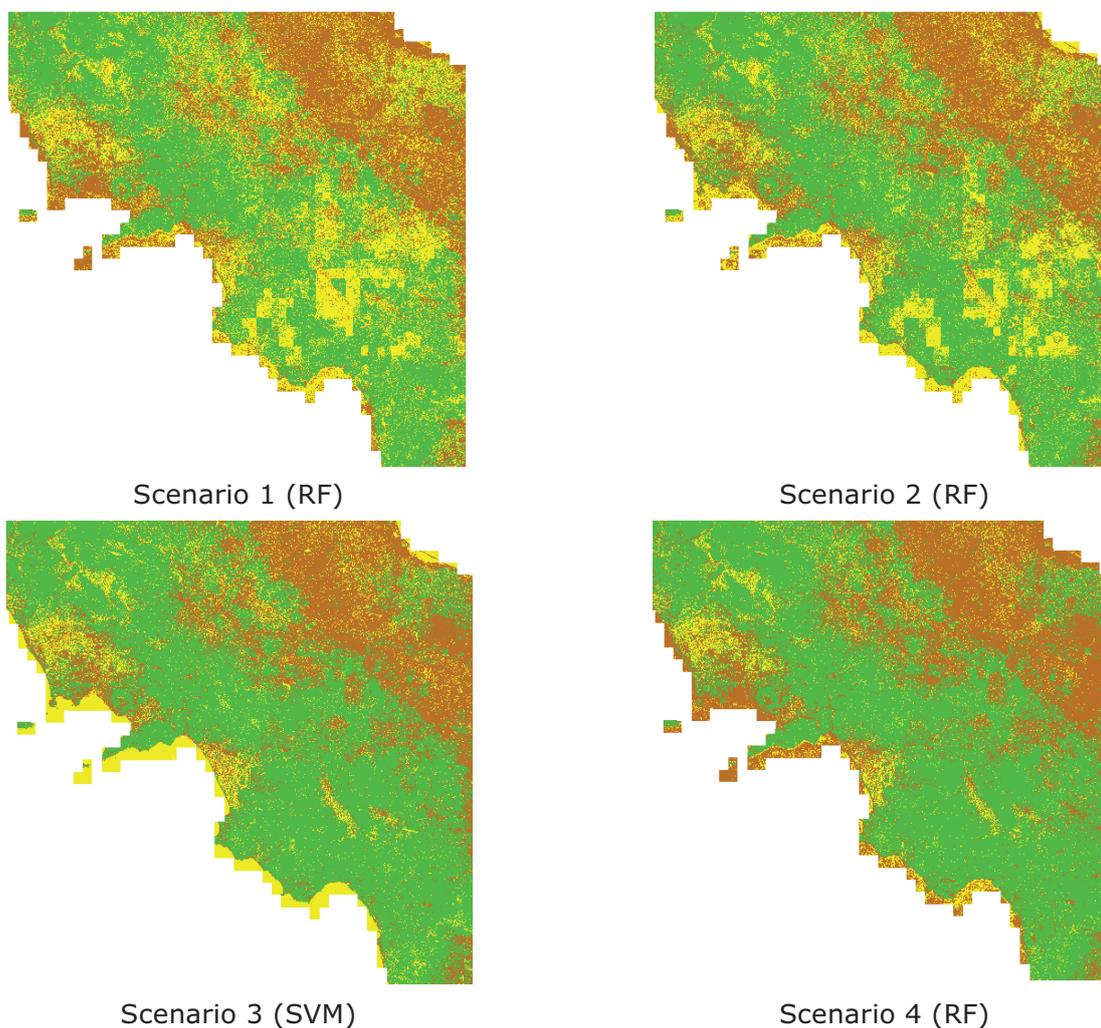


Figura 15 – Risultati della classificazione per ciascun scenario in cui le prestazioni erano ottimali e nel primo caso (A) di suddivisione dei dati.

È facile osservare nelle classificazioni Scenario 1 e Scenario 2 un effetto pixel che non è presente nello Scenario 3 e Scenario 4. La differenza tra le precedenti 2 classificazioni e l'ultima è che nello Scenario 3 e Scenario 4 è stata applicata una selezione delle *features* e ha escluso tutte le caratteristiche delle precipitazioni, dimostrando che una selezione delle caratteristiche è fondamentale per una buona classificazione.

4. Discussione e conclusioni

I risultati raggiunti in questo studio confermano che i dati satellitari, combinati con dati meteorologici, modellati e in situ, è una tecnologia matura pronta per essere trasferita ad applicazioni operative e da utilizzare come strumento utile per i gestori delle acque. In particolare, il processo di confronto e validazione ha dimostrato la capacità delle serie temporali dei dati ottici di stimare le mappe delle aree irrigate con un'alta precisione tematica. Per la mappatura delle aree

irrigate, in questo lavoro sono stati testati diversi algoritmi di classificazione supervisionata di *machine learning* al fine di analizzare l'impatto in termini di accuratezza complessiva. Ulteriori linee di ricerca saranno focalizzate in futuro introducendo ulteriori informazioni - come l'indice di umidità del suolo - derivate su bande VIS-NIR e SWIR con Optical TRapezoid Model, OPTRAM (Sadeghi et al., 2017). La procedura descritta in questo studio è attualmente utilizzata nella regione Campania per aggiornare ogni anno l'effettiva coerenza delle aree irrigate e i corrispondenti volumi di acqua, in linea con la condizionalità per la conformità della direttiva quadro sulle acque dell'UE.

Bibliografia

Claverie, M., Ju, J., Masek, J. G., Dungan, J. L., Vermote, E. F., Roger, J.-C., Skakun, S. V., & Justice, C. (2018). The Harmonized Landsat and Sentinel-2 surface reflectance data set. *Remote Sensing of Environment*, 219, 145-161.

F. Gao, J.G. Masek, R.E. Wolfe. Automated registration and orthorectification package for Landsat and Landsat-like data processing. *J. Appl. Remote. Sens.*, 3 (2009).

Harmonized Landsat Sentinel-2 (HLS) Product User's Guide Product Version 1.4. (https://hls.gsfc.nasa.gov/wp-content/uploads/2019/01/HLS.v1.4.UserGuide_draft_ver3.1.pdf).

Tucker C.J. Red and photographic infrared linear combinations for monitoring vegetation *Remote Sens. Environ.*, 8 (2) (1979), pp. 127-150.

Z. Zhu, S. Wang, C.E. Woodcock. Improvement and expansion of the Fmask algorithm: cloud, cloud shadow, and snow detection for Landsats 4-7, 8, and Sentinel 2 images.

R Core Team (2013). R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. URL <http://www.R-project.org/>.

P.H.C. Eilers A perfect smoother *Anal. Chem.*, 75 (no. 14) (2003), pp. 3631-3636

Matteo Mattiuzzi, Verbesselt, J., Stevens F., Mosher S., Hengl, T., Klisch, A., Evans B. and Lobo A. 2013. MODIS: MODIS acquisition and processing package. R package version 1.1.5/ <http://R-Forge.R-project.org/projects/modis/>. Ultimo accesso: 8 ottobre 2019.

GDAL/OGR contributors (2019). GDAL/OGR Geospatial Data Abstraction software Library. Open Source Geospatial Foundation.

Wright, M. N. 2017. "Ranger: A Fast Implementation of Random Forests." R package version 0.8.0. <https://cran.r-project.org/web/packages/ranger/index.html>.

Karatzoglou, A., A. Smola, and K. Hornik. 2016. "Kernlab: Kernel-Based Machine Learning Lab." R package version 0.9-25.<https://cran.r-project.org/web/packages/kernlab/index.html>.

Therneau, T., B. Atkinson, and B. Ripley. 2017. "Rpart: Recursive Partitioning and Regression Trees." R package version 4.1-11.<https://cran.r-project.org/web/packages/rpart/index.html>.

Kuhn, M., S. Weston, N. Coulter, M. Culp, and R. Quinlan. 2015. "C50: C5.0 Decision Trees and Rule-Based Models." R package version 0.8.0.<https://cran.r-project.org/web/packages/C50/index.html>.

Ripley, B., and W. Venables. 2016. "nnet: Feed-Forward Neural Networks and Multinomial Log-Linear Models." R package version 7.3-12.<https://cran.r-project.org/web/packages/nnet/index.html>.

Kuhn, M., J. Wing, S. Weston, A. Williams, C. Keefer, A. Engelhardt, T. Cooper, et al. 2016. "Caret: Classification and Regression Training." R package version 6.0-73.<https://cran.r-project.org/web/packages/caret/index.html>.

Johnson, B. 2013. "High Resolution Urban Land Cover Classification Using a Competitive Multi-Scale Object-Based Approach." *Remote Sensing Letters* 4 (2): 131–140. doi:10.1080/2150704X.2012.705440.

Johnson, B., and Z. Xie. 2013. "Classifying a High Resolution Image of an Urban Area Using Super-Object Information." *ISPRS Journal of Photogrammetry and Remote Sensing* 83: 40–49. doi:10.1016/j.isprsjprs.2013.05.008.

Foody, Giles M. Status of land cover classification accuracy assessment. *Remote sensing of environment*, 2002, 80.1: 185-201.

Brown, Lawrence D.; Cai, T. Tony; Dasgupta, Anirban. Interval estimation for a binomial proportion. *Statistical science*, 2001, 101-117.

Pontius, Robert; Millones, Marco (2011). "Death to Kappa: birth of quantity disagreement and allocation disagreement for accuracy assessment". *International Journal of Remote Sensing*. 32 (15): 4407–4429. doi:10.1080/01431161.2011.552923.

Galton, F. (1892). *Finger Prints* Macmillan, London.

Smeeton, N.C. (1985). "Early History of the Kappa Statistic". *Biometrics*. 41 (3): 795. JSTOR 2531300.

Siegel, Sidney. *Non parametric statistics for the behavioral sciences*. 1956.

Sadeghi, M., Babaeian, E., Tuller, M., Jones, S. B. 2017. The optical trapezoid model: A novel approach to remote sensing of soil moisture applied to Sentinel-2 and Landsat-8 observations. *Remote sensing of environment*, 198, 52-68.

