

QUANTIFICAZIONE DELL'UMIDITA' SUPERFICIALE DEL SUOLO IN AREE AGRICOLE SOGGETTE AD ELEVATA VULNERABILITA' CLIMATICA MEDIANTE DATI SENTINEL-1: IL CASO STUDIO DELLA REGIONE MARCHE (ITALIA)

B. Brunelli ^{a,b}

^a Università la Sapienza, Dipartimento di Ingegneria Civile Edile e Ambientale, via Eudossiana, 18, 00184 Roma RO, Italia, benedetta.brunelli@uniroma1.it

^b Università di Modena e Reggio Emilia (UNIMORE), Dipartimento di Ingegneria "Enzo Ferrari", via P. Vivarelli, 10, 41125 Modena MO, Italia, benedetta.brunelli@unimore.it

Parole chiave: Umidità superficiale del suolo, Sentinel-1, Sentinel-2, Google Earth Engine, Modello multitemporale Tu Wien

Keywords: Superficial soil moisture, Sentinel-1, Sentinel-2, Google Earth Engine, Tu Wien change detection model

Abstract

La diminuzione dell'umidità del suolo nella regione Mediterranea, registrata a partire dagli anni '50 e prevista per i prossimi decenni, minaccia il rendimento delle colture e la salute degli ecosistemi. Le tecniche di telerilevamento radar, sfruttando la correlazione tra l'acqua liquida e le proprietà dielettriche del suolo, sono divenute uno strumento chiave per la salvaguardia delle risorse idriche e lo sviluppo di un'agricoltura sostenibile. In questo studio, è stato sviluppato un flusso di lavoro in Google Earth Engine per quantificare l'umidità superficiale del suolo nelle aree agricole della regione Marche (Italia) attraverso dati radar ad apertura sintetica (SAR). In primo luogo, tali aree sono state identificate tramite dati ottici Sentinel-2 e dati radar Sentinel-1, studiando l'uso delle bande di decomposizione (entropia e α) per migliorare l'accuratezza della classificazione. I risultati mostrano che quest'ultime migliorano l'indice kappa ottenuto tramite dati radar del 4% ($K=0,818$), superando la precisione ottica nelle aree urbane e di acqua. Tuttavia, non consentono di raggiungere un'accuratezza pari a quella delle bande ottiche ($K=0,927$). I migliori risultati sono stati ottenuti con l'integrazione di bande ottiche, radar e della decomposizione ($K=0,949$). Successivamente, due modelli per l'inversione dell'umidità del suolo (Water Cloud Model e Tu Wien) sono stati implementati sulle aree coltivate, utilizzando parametri di calibrazione derivati da letteratura, e validati tramite misurazioni *in situ* dell'International Soil Moisture Network (ISMN). Il Water Cloud Model ha ottenuto un RMSD=12,3, mentre il modello multitemporale Tu Wien un RMSD=9,4.

Surface soil moisture is a key hydrologic state variable that greatly influences the global environment and human society. Its significant decrease in the Mediterranean region, registered since the 1950s, and expected to continue in the next century, threatens soil health and crops. Microwave remote sensing techniques are becoming a key tool for the implementation of climate-smart agriculture, as a means for surface soil moisture retrieval that exploits the correlation between liquid water and the dielectric properties of soil. In this study, a workflow in Google Earth Engine was developed to estimate surface soil moisture in the agricultural fields of the Marche region (Italy) through Synthetic Aperture Radar data. Firstly, agricultural areas were extracted with both Sentinel-2 optical and Sentinel-1 radar satellites, investigating the use of Dual-Polarimetric Entropy-Alpha decomposition's bands to improve the accuracy of radar data classification. The results show that Entropy and Alpha bands improve the kappa index obtained from the radar data only by 4% ($K=0.818$), exceeding optical accuracy in urban and water areas. However, they still did not allow to reach the overall optical accuracy ($K=0.927$). The best classification results are reached with the total dataset ($K=0.949$). Subsequently, Water Cloud and Tu Wien models were implemented on the crop areas using calibration parameters derived from literature, to test if an acceptable accuracy is reached without in situ observation. While the first model's accuracy was inadequate (RMSD=12.3), the extraction of surface soil moisture using Tu Wien change detection method was found to have acceptable accuracy (RMSD=9.4).

Introduzione

L'umidità superficiale del suolo, Surface Soil Moisture (SSM), influenza in maniera determinante gli scambi di calore e acqua tra la superficie terrestre e l'atmosfera, la frequenza e l'intensità di fenomeni siccitosi (Long et al., 2019), la previsione delle ondate di calore (Fischer et al., 2003) e la perdita di suolo dovuta all'erosione idrica (Todisco et al., 2015). Nei terreni agricoli condiziona il rendimento dei raccolti, controlla il deflusso idrico e la diversità negli ecosistemi (Robinson et al., 2008). Il cambiamento climatico sta modificando la variabilità dell'umidità del suolo e i suoi feedback con precipitazioni e temperatura; in particolare, è stata registrata una diminuzione significativa a partire dagli anni '50 nella regione del Mediterraneo (Kurnik et al., 2015; EEA, 2017). Entro la fine di questo secolo, si prevede un ulteriore calo del 20% (Mariotti et al., 2008), a causa della tendenza all'aumento delle temperature, con conseguenti tassi di evapotraspirazione più elevati, e dei

cambiamenti nella distribuzione e nell'intensità delle precipitazioni (EEA, 2017). Il monitoraggio ad alta risoluzione temporale e spaziale di questo parametro risulta quindi essenziale per salvaguardare il suolo e le risorse idriche, sviluppando sistemi colturali sostenibili, e determinando positivamente l'adattabilità ai nuovi scenari climatici (Lewis, 2019). Questo tipo di monitoraggio trova applicazione nella programmazione dell'irrigazione, allo scopo di ridurre lo stress delle piante e migliorare la resa delle colture (Pradhan et al., 2018), e può incoraggiare, nelle aree in cui è ambientalmente sostenibile, la diversificazione degli orientamenti produttivi (Zucaro et al., 2009).

Le misurazioni di umidità *in situ* forniscono dati puntuali che non sono sufficienti a caratterizzarne l'ampia variabilità spaziale e temporale (Panciera & Monerris, 2013). D'altra parte, le tecniche di telerilevamento nelle bande delle microonde ne consentono la stima su ampia scala ed in maniera continuativa, sia con radiometri passivi (Mohanty et al., 2017) che con sensori attivi,

ossia radar (Hornacek et al., 2012, Bauer-Marshallinger et al., 2019). Queste misurazioni sfruttano la correlazione tra l'acqua liquida e le proprietà dielettriche del suolo, che influenzano l'interazione tra la radiazione elettromagnetica e il target (Woodhouse, 2017).

Molti satelliti passivi, come l'AMSR (Advanced Microwave Scanning Radiometer) e SMOS (Soil Moisture and Ocean Salinity) (Fang et al., 2019), forniscono da decenni dati radiometrici che non risultano tuttavia adatti per il monitoraggio agricolo a causa della loro bassa risoluzione. D'altra parte, la strumentazione radar ad apertura sintetica (SAR) fornisce dati a risoluzione più elevata, misurando il coefficiente di retrodiffusione, σ^0 , definito come il rapporto tra l'intensità del segnale incidente e quello ricevuto (Pulvirenti et al., 2018; Mayer, 2019), il quale è sensibile alle variazioni della costante dielettrica e, quindi, al contenuto di acqua del suolo. Tuttavia, l'effetto della rugosità superficiale e della vegetazione, sovrapposti al contributo delle proprietà dielettriche, rendono il processo di inversione complesso da parametrizzare (Bindlish et al., 2002). I numerosi modelli implementati a tale scopo possono essere suddivisi in due approcci principali: algoritmi snapshot e algoritmi multi-temporali. I modelli snapshot sono solitamente raggruppati in teorici (Fung & Chen, 1992; Hajnsek et al., 2003); empirici (Oh et al., 1992; Zribi & Dechambre, 2003), che comprendono anche l'addestramento di reti neurali artificiali (Ge et al., 2018); e semi-empirici (Panciera & Moneris, 2013). Tra quest'ultimi, il Water Cloud Model (WCM) utilizza parametri di calibrazione per discriminare il contributo della vegetazione da quello del suolo, dal quale stima l'umidità ipotizzandone una correlazione lineare con la costante dielettrica (Baghdadi et al., 2006). D'altra parte, gli approcci multi-temporali si avvalgono di molteplici acquisizioni per ridurre al minimo l'effetto della vegetazione e della rugosità, e sono generalmente utilizzati per la produzione di mappe di umidità del suolo a vasta scala (Bhogapurapu et al., 2022; Bauer-Marshallinger et al., 2018). Tra questi, il modello multi-temporale Tu Wien, originariamente sviluppato per i dati ASCAT, è stato modificato in base alle caratteristiche dei dati SAR di Sentinel-1 da Bauer-Marshallinger et al. (2018), impiegando l'alta risoluzione temporale delle serie temporali acquisite dalla costellazione europea. Tramite il Tu Wien vengono ottenute giornalmente delle Copernicus Global Land Service delle mappe di umidità con griglia regolare ad 1km. Ad eccezione di questo dato, ancora poco risoluto per essere impiegato a scopi agricoli, non sono ad oggi disponibili mappe di umidità ad ampia scala, uniformi dal punto di vista dell'accuratezza e del tempo di ritorno.

Per quanto riguarda la penisola italiana, alcuni lavori hanno studiato l'applicazione di modelli e le variazioni di umidità in aree particolarmente vulnerabili a siccità e desertificazione. Ad esempio, in Sardegna Filion et al., 2016 ha stimato l'umidità in suoli nudi tramite dati Envisat ASAR, RADARSAT-2 e LANDSAT; più recentemente, Montaldo et al. (2021) ha testato il modello semi-empirico di Dubois e il modello fisico di Fung su dati Sentinel-1 in aree coperte da vegetazione.

Lo sviluppo di una procedura di quantificazione dell'umidità in aree agricole a scala nazionale, ad alta risoluzione e ad intervalli temporali regolari, risulta quindi un tema aperto, d'interesse applicativo oltre che scientifico.

A tale scopo, in questo studio si propone un flusso di lavoro standardizzato nella piattaforma di cloud computing Google Earth Engine (GEE) per individuare le aree agricole e quantificarne le variazioni di umidità a 20m di risoluzione. La metodologia è stata testata nella regione Marche, valutata come altamente vulnerabile alle variazioni climatiche, soprattutto per quanto riguarda la produttività agricola (Shukla et al., 2019), e inclusa nell'Atlante Nazionale delle aree a rischio desertificazione dal 2007 (Costantini et al., 2007).

In primo luogo, le aree agricole sono individuate tramite classificazione supervisionata Random Forest, utilizzando dati ottici (Sentinel-2), radar (Sentinel-1) e i parametri di entropia e α , derivanti dalla decomposizione polarimetrica delle immagini S-1. Successivamente, la stima dell'SSM è stata realizzata tramite il modello semi-empirico WCM e il modello multi-temporale Tu Wien, entrambi calibrati utilizzando parametri derivanti da letteratura. La validazione dei modelli è stata realizzata tramite dati in situ acquisiti nell'ambito dell'International Soil Moisture Network (ISMN) dalla rete di sensori "HYDROL-NET_PERUGIA".

Gli obiettivi del lavoro sono:

- indagare l'utilizzo delle bande della decomposizione polarimetrica, entropia e α , per migliorare la performance della classificazione radar della copertura del suolo (Banque et al., 2015), considerando che questa raggiunge solitamente un'accuratezza inferiore rispetto a quella ottenibile con i dati ottici (Steinhausen et al., 2018, Carrasco et al., 2019);
- implementare in GEE i modelli Tu Wien e Water Cloud Model (WCM) e confrontarne le stime e l'accuratezza in relazione alle misurazioni *in situ*.

1. Materiali e metodi

1.1 Area di studio

L'area di studio comprende la regione delle Marche, estesa per $9,694,51 \text{ km}^2$ nell'Italia centro-settentrionale e affacciata sul Mar Adriatico (Fig.1a). Il fiume Foglia e il fiume Tronto delimitano indicativamente i confini settentrionali e meridionali della regione, mentre l'Appennino e il Mare Adriatico ne segnano i limiti occidentali e orientali (Fig.1b). Il territorio regionale è caratterizzato da una morfologia collinare che degrada verso il mare, in cui la costa rappresenta l'unica zona pianeggiante. I fiumi marchigiani attraversano la regione da ovest a est, producendo solchi vallivi che gradualmente si allargano in prossimità della foce, formando una caratteristica struttura a pettine. Nonostante la rapida espansione delle aree urbanizzate o occupate da infrastrutture, soprattutto nella zona costiera (Appiotti et al., 2014), la regione Marche rimane in gran parte rurale (Istat, 2013), poiché la Superficie Totale Agricola (TFA) e la Superficie Agricola Utilizzata (SAU) coprono il 76,5% del territorio e le superfici agricole sono ampiamente distribuite su tutto il territorio regionale (Istat, 2013). Quasi l'80% della SAU è coltivata a seminativi, poco meno di 375mila ettari (Istat, 2013), e il cereale più coltivato è il grano duro.

1.2 Dataset

Il dataset comprende serie temporale di immagini Sentinel-1(S1) e Sentinel-2 (S2) dal 2016 al 2020. Tutti i dati sono georeferenziati nel sistema di riferimento cartografico predefinito di GEE, ossia WGS84/Pseudo-Mercator (EPSG: 3857). La missione Sentinel-1 comprende una costellazione di due satelliti in orbita polare, entrambi dotati di uno strumento SAR a banda C e doppia polarizzazione, con un periodo di rivisitazione di 12 giorni (Torres et al., 2012). Sono stati utilizzati i dati S1A e S1B, acquisiti in modalità Interferometric Wide Swath (IW), quindi con uno swath di 250 km, risoluzione spaziale di $5 \times 20 \text{ m}$ e un angolo di incidenza, θ_i , che varia tra $29,1^\circ$ e $46,0^\circ$.

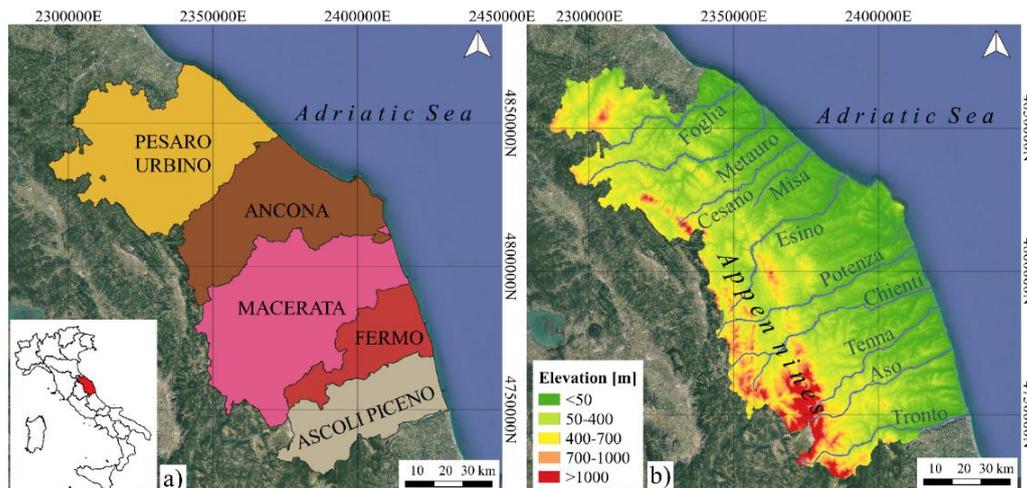


Figura 1. Area di studio. a) la regione Marche e le sue provincie b) DTM e principali corsi d'acqua (Reference system: WGS84/Pseudo-Mercator, EPSG: 3857)

Sono stati combinati due livelli di processamento distinti: le immagini Ground Range Detected (GRD), già implementate in GEE, sono state utilizzate per identificare il coefficiente di retrodiffusione; quelle Single Look Complex (SLC), scaricate dall'Alaska Satellite Facility (<https://asf.alaska.edu/>), sono state utilizzate per calcolare i parametri di entropia e α attraverso la decomposizione polarimetrica, in quanto mantengono la necessaria informazione di fase interferometrica. Orbite ascendenti (path 44 e 177) e discendenti (path 22 e 95) sono state processate separatamente.

Sentinel-2 è una missione ottica composta da due satelliti gemelli in posti in un'orbita quasi-polare, che trasportano uno strumento multispettrale (MSI), i quali acquisiscono passivamente in 13 bande con una risoluzione spaziale di 60m (banda dell'aerosol), 10m (bande nel visibile) e 20m (bande nell'infrarosso).

1.3 Procedura

La Figura 2 mostra l'intera procedura applicata. Ciascuna scena S1 e S2 è stata pre-processata (applicando il Refined Lee Filter per lo speckle e un modello di correzione radiometrica e geometrica) e utilizzata per estrarre le aree agricole della regione Marche attraverso una classificazione supervisionata della Random Forest. Successivamente, Tu Wien e il Water Cloud Model sono stati implementati nella piattaforma di cloud computing GEE e validati utilizzando misurazioni *in situ* effettuate da due stazioni ISMN (International Soil Moisture Network) in Umbria, nell'agosto 2015. Infine, le stime sono state applicate ad un'area agricola di 125 ettari, dove è stata analizzata la relazione tra le diverse coperture del suolo agricolo, l'umidità del suolo e le precipitazioni.

1.3.1 Decomposizione polarimetrica

La tecnica matematica della decomposizione polarimetrica si avvale della matrice di covarianza, indicata come $\langle C \rangle$, che esprime la polarizzazione di target naturali confrontando la intensità e fase dell'onda incidente con quella dell'onda retrodiffusa, in ciascun canale polarimetrico. Tale matrice viene calcolata in una "finestra" di pixel in dati SAR pienamente polarimetrici. $\langle C \rangle$ viene quindi decomposta tramite il metodo degli autovettori e autovalori, allo scopo di individuare matrici più semplici che esprimono la polarizzazione di elementi canonici (sfere, diedri, volumi), consentendo una più semplice

interpretazione fisica del target (Haldar et al., 2019; Harfenmeister et al., 2021). Per una descrizione dettagliata del processo di decomposizione si rimanda a Ouarzeddine et al. (2009). In questo lavoro, è stata impiegata la tecnica della decomposizione ad autovettori e autovalori adattata, da Cloud and Pottier (1996), a dati acquisiti in doppia polarizzazione.

L'analisi delle informazioni fisiche fornite dalla decomposizione può essere effettuata tramite tre parametri principali:

- l'entropia, H , che esprime il grado di disordine o casualità del meccanismo di retrodiffusione. $H=1$ indica la presenza di tre meccanismi di retrodiffusione (superficiale, volumetrico e diedrale) nella "finestra" considerata; d'altra parte, $H=0$ indica la presenza di un solo meccanismo, quindi di un target omogeneo;
- l'anisotropia, A , ossia la differenza normalizzata tra il secondo e il terzo autovettore, che esprime l'importanza del secondo meccanismo di retrodiffusione rispetto al terzo. Il suo comportamento è complementare a quello dell'entropia;
- l'angolo α , che esprime il meccanismo di retrodiffusione medio. Per dati a piena polarizzazione $\alpha \rightarrow 0$ indicata retrodiffusione di superficie; $\alpha \rightarrow \frac{\pi}{4}$ è associato a retrodiffusione volumetrica e $\alpha \rightarrow \frac{\pi}{2}$ indica retrodiffusione superficiale.

H , A e α sono stati calcolati in ciascuna scena SLC e i risultati sono stati caricati in GEE in formato geoTIFF.

1.3.2 Estrazione delle aree agricole

Le classificazioni di uso /copertura del suolo sono state effettuate attraverso l'algoritmo supervisionato Random Forest (Criminisi et al., 2012) in GEE con 500 "alberi", testando diversi set di dati. Sono stati considerati anche il Normalized Difference Vegetation Index (NDVI) e il Normalized Difference Build-up Index (NDBI). Le classi di uso del suolo considerate sono: foresta, suolo nudo, acqua, campi agricoli, aree urbane, vegetazione spontanea e neve. I dati di training sono stati aggiunte manualmente come poligoni sulla base della mappa ufficiale della copertura del suolo creata dalla regione Marche (2007). Tali dati rappresentano il 6,48% dei pixel totali, mentre quelli di validazione, estratti casualmente dai poligoni selezionati, sono l'1,62%.

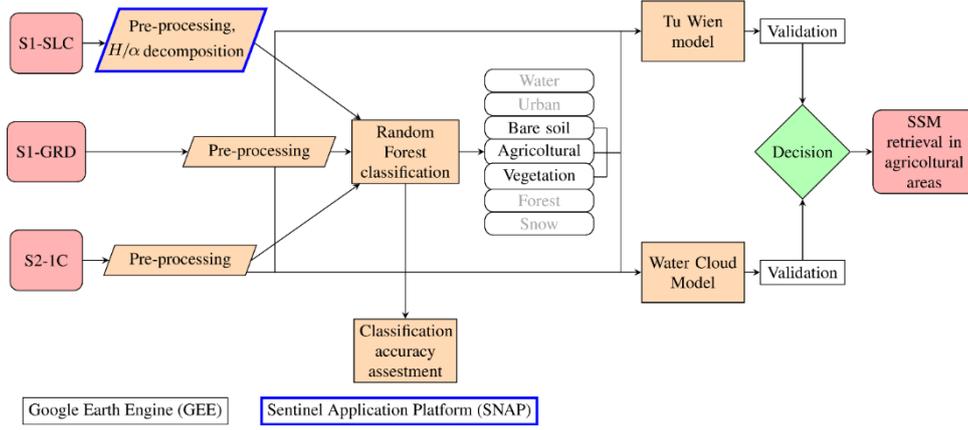


Figura 2. Flusso di lavoro

1.3.4. Quantificazione dell'umidità superficiale del suolo

I modelli Tu Wien e Water Cloud sono stati implementati in GEE e applicati sulle aree agricole estratte tramite la classificazione della copertura del suolo.

Il modello multi-temporale Tu Wien si basa su due presupposti: i) la relazione tra il coefficiente di retrodiffusione, σ^0 , e il contenuto di umidità superficiale del suolo è lineare; ii) dato che la rugosità del suolo e la vegetazione cambiano gradualmente e lentamente nel tempo, si presume che qualsiasi variazione brusca di σ^0 , se considerata entro un intervallo di tempo appropriato, abbia origine da un cambiamento nell'umidità del suolo (Panciera & Monerris, 2013).

Per tenere conto della rugosità e della vegetazione, il valore di retrodiffusione minimo registrato nell'intervallo temporale per ciascun pixel, $\sigma_{dry}^0(\theta_{ref})$, che rappresenta la retrodiffusione in condizioni di terreno asciutto, viene sottratto dal valore di retrodiffusione effettivamente registrato $\sigma^0(\theta_{ref})$. θ_{ref} indica la normalizzazione ad un angolo d'incidenza medio. Pertanto, le variazioni relative dell'umidità del suolo $m_{r,t}$ vengono calcolate dividendo il risultato per la sensibilità, che è la differenza tra il valore massimo di retrodiffusione per ciascun pixel, $\sigma_{wet}^0(\theta_{ref})$, e $\sigma_{dry}^0(\theta_{ref})$ (eq. 1):

$$m_{r,t} = \frac{\sigma^0(\theta_{ref,t}) - \sigma_{dry}^0(\theta_{ref})}{\sigma_{wet}^0(\theta_{ref}) - \sigma_{dry}^0(\theta_{ref})} [\%] \quad (1)$$

Per rilevare la quantità di umidità volumetrica del suolo vengono quindi introdotti due parametri:

- il punto di avvizzimento (*WP*), impostato al valore del 9% di umidità volumetrica, assumendo che corrisponda al minimo valore del coefficiente di retrodiffusione rilevato durante l'intervallo di tempo, ossia $\sigma_{dry}^0(\theta_{ref})$;
- il punto di saturazione (*SAT*), assumendo che corrisponda al valore massimo di retrodiffusione registrato nell'intervallo di tempo, $\sigma_{wet}^0(\theta_{ref})$. Il SAT è fissato al 30% di umidità, poiché σ^0 risulta insensibile ad aumenti oltre il 30-35% (Gao et al., 2017).

Quindi, l'umidità volumetrica del suolo viene calcolata con l'equazione 2:

$$m_{v,t} = m_{r,t} \cdot (SAT - WP) + WP [m^3 m^{-3}] \quad (2)$$

Per quanto riguarda il modello semi-empirico Water Cloud, sviluppato da Attema e Ulaby (1978), il coefficiente di

retrodiffusione totale è definito come la combinazione di tre contributi (eq. 3):

$$\sigma^0 = \tau^2 \cdot \sigma_{soil}^0 \cdot \sigma_{veg}^0 [dB] \quad (3)$$

dove σ_{veg} (eq. 4) è il contributo della vegetazione, σ_{soil} (eq. 5) quello del suolo nudo, e τ^2 esprime l'attenuazione da parte dalla canopy (eq. 6) (Baghdadi et al., 2017).

$$\sigma_{veg} = A \cdot V \cdot \cos \cdot \theta \cdot (1 - \tau^2) [dB] \quad (4)$$

$$\sigma_{soil} = C + D \cdot m_v [dB] \quad (5)$$

$$\tau^2 = \exp(-2B \cdot V \cdot \sec\theta) [dB] \quad (6)$$

V è un descrittore della vegetazione, A e B sono parametri del modello dipendenti dalla vegetazione e dalla configurazione del sensore radar, C è principalmente legato alla rugosità superficiale e D esprime la sensibilità della configurazione del radar all'umidità del suolo (Shamambo et al., 2019). In questo studio, l'NDVI (eq. 17) è utilizzato come descrittore della vegetazione.

$$V = NDVI = \frac{Nir-Red}{Nir+Red} \quad (7)$$

Altri parametri di calibrazione sono derivati da letteratura (Tabella 1).

| A_{VV} | B_{VV} | C_{VV} | D_{VV} | V |
|-----------------------|----------|------------|----------|------|
| 0.0950 | 0.5513 | 37.237 | 2.39 | NDVI |
| Baghdadi et al., 2017 | | Esch, 2018 | | S2 |

Tabella 1. Parametri di calibrazione del Water Cloud Model

2. Risultati

2.1. Accuratezza della classificazione

Al fine di valutare il contributo delle bande di entropia e α , è stata effettuata un'analisi statistica preliminare (medie e deviazioni standard) per ciascuna classe di copertura del suolo (Fig.3).

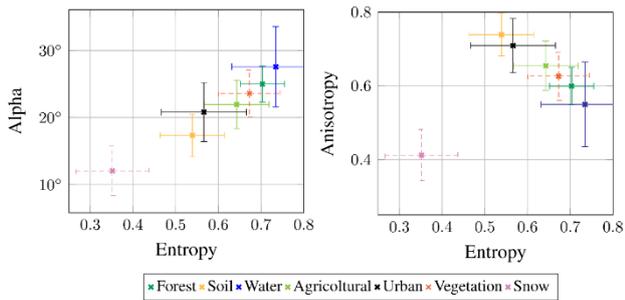


Figura 3. A destra, i valori medi di entropia e α per ciascuna classe di uso del suolo. A sinistra, i valori medi di entropia e anisotropia. Le linee orizzontali e verticali rappresentano le rispettive deviazioni standard.

Successivamente, l'accuratezza della classificazione per ciascun set di bande è stata valutata utilizzando indici kappa e matrici di confusione. Le bande ottiche consentono di ottenere un indice kappa medio di 0,927 mentre quelle radar di 0,783. Entropia e α portano l'indice kappa a 0,948 per i dati ottici e a 0,818 per i dati radar. La combinazione di bande ottiche e radar risulta in un valore kappa medio di 0,942, che aumenta leggermente aggiungendo le bande polarimetriche, ottenendo quindi un indice kappa di 0,949 per l'intero set di dati.

La valutazione dell'importanza di ciascuna banda è stata realizzata in GEE: le bande ottiche contribuiscono in media per il 24,8%, NDVI e NDBI per il 26,5%, e VV e VH per il 24,8%; infine entropia e α contribuiscono per il 23,7% alla classificazione finale. Da quest'analisi è risultato che

l'anisotropia non apporta un contributo significativo, per cui non è stata inclusa nel dataset.

Sebbene le bande derivanti dalla decomposizione contribuiscano in modo significativamente inferiore rispetto a qualsiasi altro set di dati, la Figura 5 mostra che possono migliorare notevolmente la classificazione radar, soprattutto nelle classi urbane, neve e acqua. L'accuratezza riportata è quella media calcolata su tutte le classificazioni (Carrasco et al., 2019).

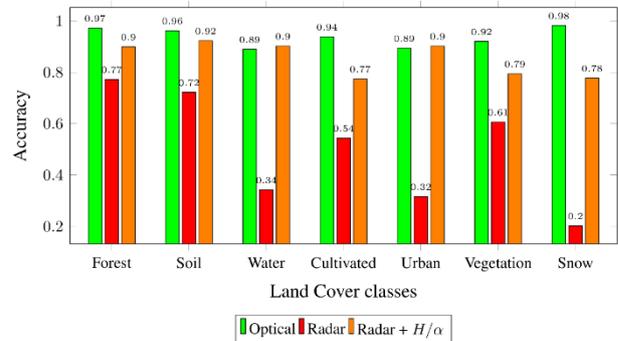


Figura 5. Precisione ottenuta dai tre set di dati in ciascuna classe di copertura del suolo

La Figura 6 mostra un confronto tra le mappe ottenute dai diversi set di dati, mentre la Figura 7 mostra un dettaglio della classificazione ottenuta con l'insieme delle bande disponibili.

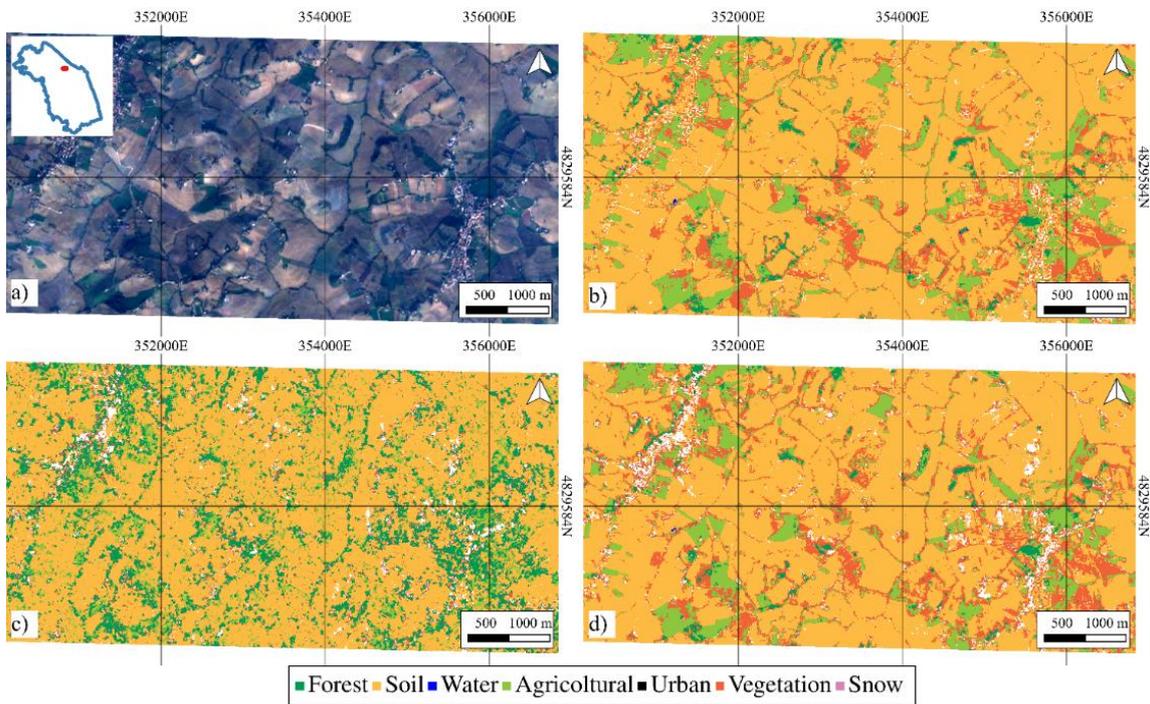


Figura 6. Confronto tra a) immagine Sentinel-2; b) classificazione del set di dati ottici; c) classificazione dei dati radar; d) classificazione totale del set totale di dati.

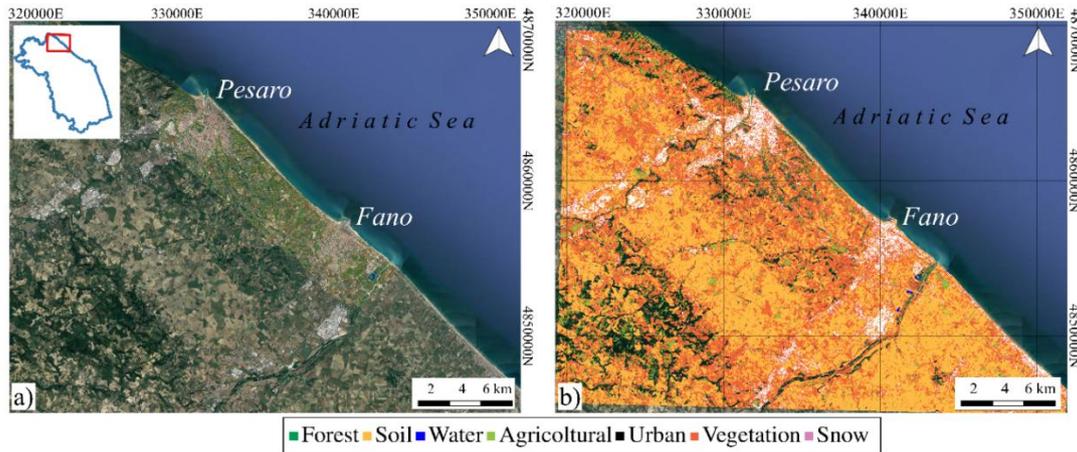


Figura 7. Confronto tra a) immagine di Google Earth; b) classificazione finale della copertura del suolo ottenuta dal set di bande totale, che ha mostrato l'accuratezza migliore. Città di Pesaro e Fano (PU), settembre 2020. Orbita ascendente

2.2. Validazione dei modelli

I valori di umidità superficiale del suolo sono stati stimati con una risoluzione spaziale di 20 metri. La validazione dei due modelli applicati è stata effettuata utilizzando misurazioni in situ acquisite dall'International Soil Moisture Network (ISMN) nella regione Umbria (Italia), in due stazioni, WEEF 1 e WEEF 2, nell'agosto 2015. Sono stati utilizzati tre parametri (RMDS, Bias e ubRMDS). Entrambe le stazioni, appartenenti alla rete HYDROL-NET-PERUGIA, si trovavano in terreni agricoli aridi e hanno misurato l'umidità del suolo a tre livelli di profondità utilizzando un sensore TRASE-BE della TDR-Soil Moisture Equipment Corp. Considerando che il radar in banda C non può penetrare nel terreno più in profondità, sono stati utilizzati i dati acquisiti a 5 cm. La tabella 2 mostra i risultati della convalida.

| | RMDS [%] | BIAS [%] | ubRMDS [%] |
|-------------|----------|----------|------------|
| Tu Wien | 9,409 | 0,193 | 9,407 |
| Water Cloud | 12,321 | -0,583 | 12,307 |

Tabella 2 Risultati della validazione dei modelli di inversione dell'umidità del suolo

La principale limitazione relativa all'applicazione dei modelli è la complessità nel discriminare l'effetto della costante dielettrica da quello della rugosità del terreno che, specialmente a risoluzioni spaziali elevate, limita l'accuratezza dei modelli. La bassa accuratezza del WCM è inoltre dovuta alla mancanza di dati di calibrazione specifici per il tipo di coltura e sensore presi in considerazione.

4. Conclusioni

In questo lavoro è stato dimostrato che l'utilizzo combinato di dati radar e ottici, data la loro complementarità, può migliorare in maniera significativa i risultati della classificazione. L'uso delle bande di entropia e α può essere utile per integrare le bande radar, superando l'accuratezza dell'ottico nelle aree urbane e negli specchi d'acqua, pur rimanendo inferiore alla classificazione ottica complessiva.

L'individuazione delle diverse tipologie di copertura di suolo è un aspetto preliminare per l'estrazione di informazioni geofisiche e biofisiche da dati SAR. In questo studio, i risultati della classificazione sono stati impiegati per isolare le aree agricole, sulle quali è stata quindi effettuata la stima dell'umidità del suolo. Allo scopo, due algoritmi sono stati implementati in GEE e validati tramite misurazioni *in situ*. Il modello Tu Wien ha dimostrato un'accuratezza più elevata rispetto al WCM, con un RMDS pari al 9,4%.

Utilizzando l'approccio multi-temporale, la procedura proposta in questo lavoro potrà essere ulteriormente sviluppata e testata in altre aree, data la necessità di monitorare il parametro dell'umidità del suolo in maniera omogenea, ad alta risoluzione spaziale e ad intervalli temporali regolari. Tale monitoraggio risulta prezioso per lo sviluppo di pratiche agricole intelligenti, come la pianificazione dell'irrigazione, e il monitoraggio della siccità.

Conflitti di interessi: L'autore dichiara di non avere conflitti di interesse da riportare

Nota: Il lavoro presentato è la traduzione in italiano dell'articolo: Brunelli, B., De Giglio, M., Magnani, E., Dubbini, M., 2023. Surface soil moisture estimate from Sentinel-1 and Sentinel-2 data in agricultural fields in areas of high vulnerability to climate variations: the marche region (Italy) case study. *Environment, Development and Sustainability*, 1–23.

Bibliografia

- Appiotti, F., Krželj, M., Russo, A., Ferretti, M., Bastianini, M., & Marincioni, F. (2014). A multidisciplinary study on the effects of climate change in the northern adriatic sea and the marche region (central italy). *Regional environmental change*, 14(5), 2007–2024. <https://doi.org/10.1007/s10113-013-0451-5>
<https://doi.org/10.1007/s10113-013-0451-5>
- Arzeni, A. (2003). Il territorio rurale e le politiche agricole nelle marche. Osservazioni Analisi. Osservatorio Agroalimentare delle Marche.
- Attema, E., & Ulaby, F. T. (1978). Vegetation modeled as a water cloud. *Radio science*, 13(2), 357–364. <https://doi.org/10.1029/RS013i002p00357>
- Baghdadi, N., Holah, N., & Zribi, M., (2006). Soil moisture estimation using multi-incidence and multi-polarization ASAR data. *International Journal of Remote Sensing*, 1907–1920. <https://doi.org/10.1080/01431160500239032>
- Baghdadi, N., El Hajj, M., Zribi, M., & Bousbih, S. (2017). Calibration of the water cloud model at c-band for winter crop fields and grasslands. *Remote Sensing*, 9(9), 969. <https://doi.org/10.3390/rs9090969>
- Balenzano, A., Mattia, F., Satalino, G., & Davidson, M. W. (2010). Dense temporal series of C-and L-band SAR data for soil moisture retrieval over agricultural crops. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 4(2), 439-450. <https://doi.org/10.1109/JSTARS.2010.2052916>.
- Banque, X., Lopez-Sanchez, J. M., Monells, D., Ballester, D., Duro, J., & Koudogbo, F. (2015). Polarimetry-based land cover classification with sentinel-1 data. *Proc. of POLINSAR*, 729, 1–5.
- Bauer-Marschallinger, B., Freeman, V., Cao, S., Paulik, C., Schaufler, S., Stachl, T., Modanesi, S., Massari, C., Ciabatta, L., Brocca, L., & Wagner, W. (2019). Toward global soil moisture monitoring with Sentinel-1: Harnessing assets and overcoming obstacles. *IEEE Transactions on Geoscience and Remote Sensing*, 57(1), 520–539. <https://doi.org/10.1109/TGRS.2018.2858004>
434
- Bhogapurapu, N., Dey, S., Homayouni, S., Bhattacharya, A. & Rao, Y. (2022). Field-scale soil moisture estimation using sentinel-1 GRD SAR data. *Advances in Space Research*. <https://doi.org/https://doi.org/10.1016/j.asr.2022.03.019>
- Bindlish, R., & Barros, A. P. (2002). Subpixel variability of remotely sensed soil moisture: An inter-comparison study of SAR and ESTAR. *IEEE Transactions on Geoscience and Remote Sensing*, 40(2), 326-337. DOI: 10.1109/36.992792
- Borrelli, P., Paustian, K., Panagos, P., Jones, A., Schütt, B., & Lugato, E. (2016). Effect of good agricultural and environmental conditions on erosion and soil organic carbon balance: a national case study. *Land use policy*, 50, 408-421. <http://dx.doi.org/10.1016/j.landusepol.2015.09.033>
- Carrasco, L., O’Neil, A. W., Morton, R. D. & Rowland, C. S. (2019). Evaluating combinations of temporally aggregated Sentinel-1, Sentinel-2 and Landsat 8 for land cover mapping with Google Earth Engine. *Remote Sensing*, 11 (3), 288. <https://doi.org/10.3390/rs11030288>
- Cloude, S. R. & Pottier, E. (1996). A review of target decomposition theorems in radar polarimetry. *IEEE transactions on geoscience and remote sensing*, 34(2), 498-518. DOI: 10.1109/36.485127
- Costantini, E. A., Urbano, F., Bonati, G., & Nino, P. (2007). *Atlante nazionale delle aree a rischio di desertificazione*. DOI: 10.13140/2.1.5124.0645
- Criminisi, A., Shotton, J., & Konukoglu, E. (2012). Decision forests: A unified framework for classification, regression, density estimation, manifold learning and semi-supervised learning. *Foundations and trends® in computer graphics and vision*, 7(2–3), 81-227. <http://dx.doi.org/10.1561/06000000035>
- EEA. (2017). European Environmental Agency. Climate change, impacts and vulnerability in Europe 2016. An indicator-based report.
- Esch, S. (2018). Determination of soil moisture and vegetation parameters from spaceborne c-band sar on agricultural areas. Universität zu Köln.
- Fang, B., Lakshmi, V., Jackson, T. J., Bindlish, R., & Colliander, A. (2019). Passive/active microwave soil moisture change disaggregation using SMAPVEX12 data. *Journal of hydrology*, 574, 1085-1098. <https://doi.org/10.1016/j.jhydrol.2019.04.082>
- FAO. Climate-Smart Agriculture. Available online: <https://www.fao.org/climate-smart-agriculture/on-the-ground/en/> (accessed on 21 March 2022).
- Filion, R., Bernier, M., Paniconi, C., Chokmani, K., Melis, M., Soddu, A., ... & Lafortune, F. X. (2016). Remote sensing for mapping soil moisture and drainage potential in semi-arid regions: Applications to the Campidano plain of Sardinia, Italy. *Science of the Total environment*, 543, 862-876. <https://doi.org/10.1016/j.scitotenv.2015.07.068>
- Fischer, E. M., Seneviratne, S. I., Vidale, P. L., Lüthi, D., & Schär, C. (2007). Soil moisture–atmosphere interactions during the 2003 European summer heat wave. *Journal of Climate*, 20(20), 5081-5099. DOI: <https://doi.org/10.1175/JCLI4288.1>
- Fung, A. K., Li, Z., & Chen, K. S. (1992). Backscattering from a randomly rough dielectric surface. *IEEE Transactions on Geoscience and remote sensing*, 30(2), 356-369. DOI: 10.1109/36.134085
- Gao, Q., Zribi, M., Escorihuela, M. J., & Baghdadi, N. (2017). Synergetic use of sentinel-1 and sentinel-2 data for soil moisture mapping at 100 m resolution. *Sensors*, 17(9), 1966. <https://doi.org/10.3390/s17091966>
- Hajnsek, I., Pottier, E. & Cloude, S. R. (2003). Inversion of surface parameters from polarimetric SAR. *IEEE Transactions on Geoscience and Remote Sensing*, 41 (4), 727–744. DOI: 10.1109/TGRS.2003.810702

- Hornacek, M., Wagner, W., Sabel, D., Truong, H. L., Snoeij, P., Hahmann, T., ... & Doubková, M. (2012). Potential for high resolution systematic global surface soil moisture retrieval via change detection using Sentinel-1. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 5(4), 1303-1311. DOI: 10.1109/JSTARS.2012.2190136.
- Istat. (2013). VI censimento generale dell'agricoltura. Istat
- Kurnik, B., Kajfež-Bogataj, L., & Horion, S. (2015). An assessment of actual evapotranspiration and soil water deficit in agricultural regions in Europe. *International Journal of Climatology*, 35(9), 2451-2471. <https://doi.org/10.1002/joc.4154>
- Lewis, P. (2019). Climate-Smart Agriculture in action: from concepts to investments. Dedicated Training for Staff of the Islamic Development Bank. Cairo, Egypt. Food and Agriculture Organization of the United Nations (FAO)
- Long, D., Bai, L., Yan, L., Zhang, C., Yang, W., Lei, H., ... & Shi, C. (2019). Generation of spatially complete and daily continuous surface soil moisture of high spatial resolution. *Remote Sensing of Environment*, 233, 111364. <https://doi.org/10.1016/j.rse.2019.111364>
- Mariotti, A., Zeng, N., Yoon, J. H., Artale, V., Navarra, A., Alpert, P., & Li, L. Z. (2008). Mediterranean water cycle changes: transition to drier 21st century conditions in observations and CMIP3 simulations. *Environmental Research Letters*, 3(4), 044001. <https://doi.org/10.1098/rsta.2010.0204>
- Mohanty, B. P., Cosh, M. H., Lakshmi, V., & Montzka, C. (2017). Soil moisture remote sensing: State-of-the-science. *Vadose Zone Journal*, 16(1), 1-9. <https://doi.org/10.2136/vzj2016.10.0105>
- Montaldo, N., Fois, L., & Corona, R. (2021). Soil Moisture Estimates in a Grass Field Using Sentinel-1 Radar Data and an Assimilation Approach. *Remote Sensing*, 13(16), 3293. <https://doi.org/10.3390/rs13163293>
- Oh, Y., Sarabandi, & K., Ulaby, F. T., et al., 1992. An empirical model and an inversion technique for radar scattering from bare soil surfaces. *IEEE transactions on Geoscience and Remote Sensing*, 370-381. DOI: 10.1109/36.134086
- Ouarzeddine, M., Souissi, B., & Belhadj-Aissa, A. (2006). Target detection and characterization using h/alpha decomposition and polarimetric signatures. In 2006 2nd International Conference on Information & Communication Technologies (Vol. 1, pp. 395-400). IEEE Xplore. DOI: 10.1109/ICTTA.2006.1684402
- Panciera, R., & Moneris, A. (2013). Basis of an Australian radar soil moisture algorithm theoretical baseline document (ATDB) Monash University
- Pradhan, S. N., Anjum, M., & Jena, P. (2018). Estimation of soil moisture content by remote sensing methods: A review. *Journal of Pharmacognosy and Phytochemistry*, 7, 1786-1792.
- Pulvirenti, L., Squicciarino, G., Cenci, L., Boni, G., Pierdicca, N., Chini, M., ... & Campanella, P. (2018). A surface soil moisture mapping service at national (Italian) scale based on Sentinel-1 data. *Environmental Modelling & Software*, 102, 13-28. <https://doi.org/10.1016/j.envsoft.2017.12.022>
- Robinson, D.A., Campbell, C.S., Hopmans, J.W., Hornbuckle, B.K., Jones, S.B., Knight, R., Ogden, F., Selker, J. & Wendroth, O. (2008), Soil Moisture Measurement for Ecological and Hydrological Watershed-Scale Observatories: A Review. *Vadose Zone Journal*, 7: 358-389. <https://doi.org/10.2136/vzj2007.0143>
- Sehler, R., Li, J., Reager, J., & Ye, H. (2019). Investigating relationship between soil moisture and precipitation globally using remote sensing observations. *Journal of Contemporary Water Research & Education*, 168(1), 106-118. <https://doi.org/https://doi.org/10.1111/j.1936-704X.2019.03324.x>
- Shamambo, D. C., Bonan, B., Calvet, J.- C., Albergel, C., & Hahn, S. (2019). Interpretation of ASCAT radar scatterometer observations over land: A case study over Southwestern France. *Remote Sensing*, 11(23), 2842-458. <https://doi.org/10.3390/rs11232842>
- Shukla, P., Skea, J., Calvo Buendia, E., Masson-Delmotte, V., Pörtner, H., Roberts, D., Zhai, P., Slade, R., Connors, S., ... & Van Diemen, R. (2019). IPCC, 2019: Climate Change and Land: an IPCC special report on climate change, desertification, land degradation, sustainable land management, food security, and greenhouse gas fluxes in terrestrial ecosystems
- Steinhausen, M. J., Wagner, P. D., Narasimhan, B. & Waske, B. (2018). Combining Sentinel-1 and Sentinel-2 data for improved land use and land cover mapping of monsoon regions. *International journal of applied earth observation and geoinformation*, 73, 595-604. <https://doi.org/10.1016/j.jag.2018.08.011>
- Todisco, F., Brocca, L., Termiti, L. F., & Wagner, W. (2015). Use of satellite and modeled soil moisture data for predicting event soil loss at plot scale. *Hydrology and Earth System Sciences*, 19(9), 3845-3856. <https://doi.org/10.5194/hess-19-3845-2015>
- Torres, R., Snoeij, P., Geudtner, D., Bibby, D., Davidson, M., Attema, E., ... & Rostan, F. (2012). GMES Sentinel-1 mission. *Remote sensing of environment*, 120, 9-24. <https://doi.org/10.1016/j.rse.2011.05.028>
- Wagner, W., Sabel, D., Doubkova, M., Bartsch, A., & Pathe, C. (2009). The potential of sentinel-1 for monitoring soil moisture with a high spatial resolution at global scale. *Symposium of Earth Observation and Water Cycle Science*, 3, 60.
- Woodhouse, I. H. (2017). *Introduction to microwave remote sensing*. CRC press
- Zribi, M., & Dechambre, M. (2003). A new empirical model to retrieve soil moisture and roughness from C-band radar data. *Remote Sensing of Environment*, 84(1), 42-52. [https://doi.org/10.1016/S0034-4257\(02\)00069-X](https://doi.org/10.1016/S0034-4257(02)00069-X)
- Zucaro, R., Arzeni, A., Capone, S., Tiberi, M., Boaro, I., Massaccesi, G., Pontrandolfi, A., Tascone, F. L., ... &

Serino, G. (2009). Rapporto sullo stato dell'irrigazione nelle Marche. Rapporto irrigazione.