



Estimación espacial de la humedad superficial del suelo mediante integración de datos satelitales y variables geoambientales en una cuenca tropical andina

Spatial estimation of surface soil moisture through integration of satellite data and geoenvironmental variables in a tropical Andean basin

Doris Helena Serrano Amaya ¹✉

¹Facultad de Ciencias Básicas, Departamento de Geografía y Medio Ambiente, Universidad de Córdoba (Colombia).



Vol. 54 (1 y 2) de 2024 | pp: 31 - 39 | ISSN 0562-5351 E-ISSN 2665-6558 | REC.: 25/02/2026- ACEP.: 24/03/2026

RESUMEN

La humedad del suelo constituye una variable de gran relevancia en campos como la producción agrícola, el monitoreo de condiciones de sequía, la planificación del riego y la modelación climática. Si bien los sensores satelitales permiten obtener información a escala global, su resolución espacial resulta insuficiente para abordar problemáticas de carácter local. En este contexto, la presente investigación propuso un modelo estadístico multivariado capaz de vincular las mediciones de humedad superficial del suelo obtenidas en campo en la cuenca del río Quindío, Colombia con factores del entorno como la cobertura vegetal y las propiedades físicas del suelo. Los resultados indicaron que el índice de vegetación normalizado (NDVI), la temperatura del suelo y la fracción de arena constituyeron los predictores con mayor capacidad explicativa. Al integrar estos factores con imágenes SMAP_L2 de distintas resoluciones espaciales (1, 3, 9 y 36 km), se lograron estimaciones con mayor resolución que las disponibles únicamente a partir de los productos satelitales. Los coeficientes de regresión se obtuvieron mediante el método de mínimos cuadrados parciales (PLS), y el análisis de varianza confirmó la significancia estadística de todos los modelos ajustados ($p = 0.0$). El modelo construido con datos SMAP de 1 km alcanzó el mayor coeficiente de determinación ($R^2 = 73\%$), seguido por el de 3 km ($R^2 = 65\%$). Estos hallazgos respaldan la viabilidad de la técnica propuesta para estimar la humedad superficial del suelo a escala local, incorporando su variabilidad espacial y temporal.

Palabras clave: Humedad del suelo, asimilación de datos, SMAP, variabilidad espacial, regresión PLS.

ABSTRACT

Soil moisture is a key variable in agricultural production, drought monitoring, irrigation planning, and climate modeling. Although satellite sensors provide global-scale information, their spatial resolution is often insufficient for local-scale analysis. In this study, a multivariate statistical model was developed to relate field-measured surface soil moisture in the Quindío River basin (Colombia) with environmental factors such as vegetation cover and soil physical properties. Results showed that the Normalized Difference Vegetation Index (NDVI), soil temperature, and sand fraction were the most explanatory predictors. By integrating these factors with SMAP_L2 satellite imagery at different spatial resolutions (1, 3, 9, and 36 km), predictions with higher spatial resolution than those available from satellite products alone were obtained. Regression coefficients were estimated using the Partial Least Squares (PLS) method, and analysis of variance confirmed statistical significance for all fitted models ($p = 0.0$). The model built with 1 km SMAP data achieved the highest coefficient of determination ($R^2 = 73\%$), followed by the 3 km model ($R^2 = 65\%$). These findings support the viability of the proposed technique for estimating surface soil moisture at the local scale, capturing its spatial and temporal variability.

Keywords: Soil moisture, data assimilation, SMAP, spatial variability, PLS regression.

INTRODUCCIÓN

La humedad del suelo (HS) representa un componente esencial del ciclo hidrológico, toda vez que regula los flujos de energía entre la superficie terrestre y la atmósfera (Babaeian et al., 2019). Su comportamiento incide de manera directa en una amplia gama de procesos hidrológicos y agronómicos: la generación de escorrentía superficial, la evapotranspiración, el establecimiento y desarrollo de cultivos, las necesidades de irrigación, así como la anticipación de eventos extremos como inundaciones y sequías. De igual forma, la HS desempeña un papel central en procesos biogeoquímicos vinculados al movimiento de solutos en el suelo y, por ende, a la calidad de los recursos hídricos (Brocca et al., 2017; Wagner et al., 2007; Zhang y Zhou, 2016).

Para la adecuada gestión del agua a escalas locales y regionales, resulta indispensable contar con observaciones detalladas que reflejen la variabilidad espacial de la HS (Lakshmi, 2013). No obstante, su caracterización plantea importantes desafíos, dada su marcada heterogeneidad espacial, la cual responde a gradientes de precipitación, tipo de suelo, cobertura vegetal y atributos topográficos como la pendiente, la curvatura, el aspecto y la elevación (Famiglietti et al., 1999; Yu et al., 2001; Guo et al., 2020).

La teledetección satelital se ha consolidado como una herramienta poderosa para el monitoreo continuo de la HS a escala global. En particular, el satélite SMAP (Soil Moisture Active Passive), puesto en órbita en 2015 por la NASA, ofrece estimaciones de la HS integrando mediciones de temperatura de brillo en banda L (sensor pasivo) con datos de retrodispersión de radar (sensor activo) (Mohanty et al., 2017; Petropoulos et al., 2015). Sin embargo, las resoluciones espaciales propias de estos productos

resultan insuficientes para estudios locales, lo que ha impulsado el desarrollo de técnicas de mejoramiento o downscaling.

En este marco, la asimilación de datos emerge como una estrategia eficaz para integrar información proveniente de distintas fuentes y mejorar la resolución espacial de las estimaciones (Chan et al., 2016). Dentro de los métodos estadísticos aplicables a este propósito, la regresión por mínimos cuadrados parciales (PLS) destaca por su capacidad de manejar conjuntos de predictores con alta colinealidad, reduciendo su dimensionalidad mediante la extracción de componentes ortogonales. Esta característica confiere al PLS una notable robustez frente a la incertidumbre en las mediciones (Wold, 1974; Leone et al., 2012).

El presente estudio tuvo como objetivo construir un modelo estadístico que relacione la variabilidad de la HS superficial con factores ambientales relevantes y con diferentes resoluciones espaciales de datos satelitales. Con tal fin, se emplearon imágenes SMAP_L2 de 1, 3, 9 y 36 km de resolución, en combinación con promedios de HS medidos en campo en nueve unidades de muestreo durante siete períodos. El modelo fue desarrollado mediante el método PLS con el algoritmo NIPALS (Nonlinear Iterative Partial Least Squares), con el objetivo de estimar los coeficientes de regresión no estandarizados y generar predicciones de la HS a escala local.

MATERIALES Y MÉTODOS

Área de estudio.

El área de estudio comprende la cuenca hidrográfica del río Quindío, localizada en la vertiente occidental de la cordillera Central de Colombia, entre las coordenadas 4° 20' 55" N - 75° 48' 04" W y 4° 42' 57" N - 75° 23' 0" W. La cuenca abarca una extensión de 688,85 km², con cotas altitudinales que oscilan entre 1.079

y 4.794 m s. n. m. Su territorio comprende unidades de paisaje diversas: montaña, piedemonte, lomerío y valle (IGAC, 2013). Desde el punto de vista socioeconómico, la cuenca sustenta importantes actividades agropecuarias—entre ellas el cultivo de café, plátano, cítricos y yuca—, además de la ganadería lechera, las plantaciones forestales y el turismo de naturaleza (García-Reinoso et al., 2011). El régimen climático presenta dos períodos húmedos definidos (marzo-mayo y octubre-diciembre) y dos estaciones más secas en los trimestres intermedios. Las temperaturas medias fluctúan entre 17,9 y 22,1 °C, con los valores más bajos en los meses de octubre y noviembre (IGAC, 2013).

Unidades de muestreo.

Se definieron nueve unidades de muestreo a partir de criterios fisiográficos que aseguraran representatividad de las condiciones de cobertura, pendiente, curvatura superficial y textura del suelo en la cuenca. Su delimitación se realizó mediante la técnica de geometría de contorno convexo (Barber et al., 1996), y se calcularon sus centroides geométricos y superficies, las cuales variaron entre 1.038 m² (U6) y 13.572,98 m² (U10).

Las unidades U1 a U6 se ubicaron en el paisaje de montaña, con pendientes superiores al 12%, bajo coberturas de bosque natural, plantaciones, pastos y cultivos semipermanentes, sobre suelos derivados de materiales volcánicos, sedimentarios y depósitos aluviales. Las unidades U7 y U9 se localizaron en el piedemonte y lomerío, en relieves de abanicos disectados y colinas con pendientes del 12 al 25%, con predominio de pastos y cultivos sobre suelos formados a partir de anfíbolitas, esquistos y cenizas volcánicas. La unidad U10, en el valle de inundación, se caracterizó por pendientes suaves (3-7%), cobertura de guaduales y suelos de origen aluvial.

Medición de la humedad del suelo en campo.

Se recolectaron un total de 2.211 muestras de suelo a una profundidad de 0-5 cm en las nueve unidades de muestreo, distribuidas en siete períodos de evaluación. La humedad volumétrica (θ) se determinó a partir de análisis gravimétrico y medición de la densidad aparente del suelo (ρ), siguiendo la metodología descrita por Gabriels y Lobo (2006).

Los valores de humedad volumétrica fueron promediados por período de evaluación y por unidad de muestreo mediante el promedio heroniano, que pondera la media aritmética y la media geométrica, siendo esta última menos susceptible a valores atípicos (Sykora, 2009). Este procedimiento permitió obtener 63 promedios heronianos representativos de las condiciones de humedad en cada unidad.

Datos satelitales de humedad del suelo (SMAP).

Se obtuvieron imágenes de los productos SMAP_L2 en cuatro resoluciones espaciales—1, 3, 9 y 36 km— correspondientes a las fechas de cada período de evaluación, a través del portal Earthdata Search de la NASA. Para cada centroide de unidad de muestreo, se extrajeron los valores de humedad del suelo satelital (HSs), que posteriormente se incorporaron al proceso de modelación estadística.

Variables ambientales asociadas a la variabilidad de la humedad del suelo.

Con el propósito de caracterizar los factores que condicionan la dinámica y heterogeneidad de la HS, se incluyeron las siguientes covariables:

Índices espectrales (Sentinel-2): A partir de imágenes del sensor Sentinel-2 se calcularon el Índice de Vegetación Normalizado (NDVI), el Índice de Vegetación Mejorado (EVI) y el

Índice de Diferencia Normalizada de Agua (NDWI), los cuales reflejan la densidad y salud de la cubierta vegetal, así como el estado hídrico de la superficie.

Precipitación (Pp): Factor que regula el aporte de agua al suelo y la dinámica de la vegetación. Los datos correspondieron a registros diarios de estaciones climáticas ubicadas en la cuenca.

Temperatura del suelo (Ts): Variable que influye en el estado físico del agua almacenada en el suelo y en la intensidad de la evapotranspiración, medida en °C mediante sensores instalados a 0-5 cm de profundidad.

Topografía: La elevación (DEM), la pendiente y la curvatura del terreno fueron derivadas del Modelo Digital de Terreno (MDT) ALOS PALSAR de 12,5 m de resolución. Estas variables condicionan la redistribución del agua sobre el paisaje.

Fracción de arena (A): Determinada mediante el método del hidrómetro de Bouyoucos en 43 muestras de suelo recolectadas en campo. La textura del suelo controla la velocidad de infiltración y la capacidad de retención hídrica.

Análisis estadístico

En primer lugar, se evaluó la asociación lineal entre la humedad del suelo en campo (HSc) y los valores satelitales (HSs) mediante el coeficiente de correlación de Pearson. Para establecer las relaciones entre las variables ambientales y la HSc, se empleó el análisis de correlación parcial, que permite cuantificar el grado de asociación lineal entre dos variables controlando el efecto de las demás. La selección de predictores se basó en la minimización de la colinealidad entre variables, evaluada mediante los coeficientes de correlación parcial.

El modelo estadístico fue construido mediante la regresión por mínimos cuadrados parciales (PLS), implementada con el algoritmo NIPALS. Este método estandariza las variables a media cero y desviación estándar unitaria, extrae

componentes latentes no correlacionados entre sí y posibilita la estimación de coeficientes de regresión robustos frente a la multicolinealidad. La partición de los datos asignó el 80% al conjunto de entrenamiento y el 20% restante a la validación del modelo. La capacidad predictiva del modelo ajustado se cuantificó mediante el coeficiente de determinación de predicción (R^2_{pred}), calculado como:

$$R^2_{pred} = 1 - [\sum(y_i - \hat{y}_{pred,i})^2] / [\sum(y_i - \bar{y})^2]$$

Donde y_i son los valores observados, $\hat{y}_{pred,i}$ los valores predichos sobre el conjunto de validación, \bar{y} la media de los valores observados y n el número de observaciones. Los resultados se evaluaron gráficamente mediante diagramas de dispersión de valores observados frente a predichos.

RESULTADOS

Correlaciones entre la humedad del suelo en campo y satelital

El análisis de correlación de Pearson entre la HSc y la HSs (Figura 2) mostró que las relaciones con los productos SMAP de 1, 3 y 36 km fueron estadísticamente significativas ($p < 0,05$). La correlación más elevada, de signo negativo, se obtuvo con la imagen de 1 km de resolución ($r = -0,5386$), mientras que la resolución de 9 km presentó la correlación más débil ($r = 0,2188$). Los comportamientos similares observados entre las resoluciones de 1 y 3 km sugieren que ambos productos capturan patrones espaciales afines en la cuenca.

Correlaciones parciales con variables ambientales

El análisis de correlación parcial (Figura 3) reveló que las variables NDVI, NDWI, temperatura del suelo (Ts), elevación (DEM), curvatura (Ct) y fracción de arena (A)

presentaron correlaciones estadísticamente significativas con la HSc ($p < 0,05$). Se identificó alta colinealidad entre NDVI y EVI, así como entre Ts y DEM, por lo que cualquiera de los pares podría actuar como predictor equivalente. A continuación, se resumen las interpretaciones de los factores con mayor relevancia:

NDVI: La correlación negativa encontrada entre este índice y la HSc indica que las coberturas con mayor densidad foliar —como bosques y cultivos densos (U1 a U6)— favorecen tasas más elevadas de evapotranspiración, lo que reduce la humedad disponible en la superficie del suelo.

EVI: Presentó una correlación positiva baja y no significativa con la HSc. Su menor sensibilidad en condiciones de cobertura vegetal moderada limita su utilidad como predictor en la cuenca estudiada (Huete et al., 2002).

NDWI: La correlación positiva con la HSc refleja la capacidad de este índice para detectar contenido de agua superficial y en la vegetación. Su desempeño fue particularmente notable en unidades con alta retención hídrica (U2, U9), aunque disminuye en suelos arenosos de alta permeabilidad.

Precipitación: No mostró correlación significativa con la HSc, lo que podría atribuirse a la rápida infiltración en suelos arenosos y a la redistribución vertical del agua en el perfil del suelo, factores que atenúan el efecto inmediato de la lluvia sobre la humedad superficial (Famiglietti et al., 1998).

Temperatura del suelo (Ts): La relación negativa con la HS es coherente con el aumento de la evaporación superficial a mayores temperaturas. Las unidades en altitudes más bajas y cálidas (U7, U9) presentaron menor humedad superficial respecto a las unidades ubicadas en zonas más elevadas (U1, U2).

DEM: La correlación negativa con la HS en zonas altas refleja la mayor exposición al viento y la mayor escorrentía superficial que caracteriza estas áreas, los cuales aceleran la pérdida de agua del horizonte superficial.

Pendiente: No se encontró una relación significativa entre este factor y la HSc, lo que sugiere que la influencia de otros elementos, como la cobertura vegetal o la estructura del suelo, puede neutralizar el efecto de la inclinación del terreno sobre la retención hídrica.

Curvatura del terreno: Las zonas cóncavas (U6, U8) tendieron a acumular mayor humedad superficial, mientras que las convexas (U5) mostraron valores inferiores, en concordancia con la dinámica gravitacional del agua.

Fracción de arena (A): Presentó la correlación negativa más alta con la HSc ($r = -0,5594$). En suelos con alto contenido de arena (U1, U9, U10), la baja capacidad de retención hídrica favorece la infiltración rápida hacia capas más profundas, reduciendo la humedad superficial disponible.

Modelos de regresión y predicción de la humedad del suelo.

A partir del análisis de correlación parcial, se seleccionaron el NDVI, la temperatura del suelo (Ts) y la fracción de arena (A) como variables predictoras para modelar la HSc en función de cada resolución espacial de SMAP. Las ecuaciones de regresión ajustadas con el método PLS fueron las siguientes:

$$HS_{p1} = 0,5596 - 0,0701 \cdot NDVI + 0,00113 \cdot Ts - 0,00184 \cdot A - 0,1961 \cdot SMAP1$$

$$HS_{p3} = 0,5368 - 0,0927 \cdot NDVI + 0,00254 \cdot Ts - 0,00217 \cdot A - 0,03972 \cdot SMAP3$$

$$HS_{p9} = 0,1558 - 0,0973 \cdot NDVI + 0,00385 \cdot Ts - 0,00212 \cdot A + 1,9929 \cdot SMAP9$$

$$HS_{p36} = 0,3825 - 0,0743 \cdot NDVI + 0,00319 \cdot Ts - 0,00225 \cdot A + 0,7389 \cdot SMAP36$$

Todos los modelos resultaron estadísticamente significativos ($p = 0,0$). El modelo construido con datos SMAP a 1 km de resolución alcanzó el mayor R^2 (72,75%), seguido por el de 3 km ($R^2 = 65,31\%$). El modelo basado en la resolución de 36 km ($R^2 = 52,44\%$) superó en ajuste al de 9 km ($R^2 = 40,24\%$), lo que sugiere que la integración espacial a mayor escala puede capturar patrones regionales que compensan la pérdida de detalle en el tamaño de píxel.

Los gráficos de dispersión evidencian que el modelo a 1 km presentó la distribución de puntos más cercana a la línea 1:1, lo que confirma su mayor precisión en la captura de la variabilidad espacial local. A medida que disminuye la resolución, la dispersión se incrementa y la capacidad predictiva se reduce, con excepción del modelo de 36 km, cuyo comportamiento más regular puede estar asociado al suavizado de la heterogeneidad espacial.

DISCUSIÓN

Los resultados de esta investigación demuestran que la integración de datos satelitales SMAP_L2 con variables ambientales derivadas de imágenes de mediana resolución y mediciones in situ permite estimar con mayor precisión la humedad superficial del suelo a escala local. El enfoque de asimilación de datos basado en regresión PLS produjo predicciones estadísticamente robustas, superando en resolución espacial a la ofrecida por los productos satelitales originales (R^2 referencia = 54%).

Entre las variables ambientales evaluadas, la fracción de arena del suelo emergió como el predictor de mayor peso, con una correlación negativa fuerte ($r = -0,5594$) con la HS superficial. Este comportamiento es consistente con la literatura especializada,

que señala que los suelos arenosos presentan una capacidad de retención hídrica reducida y tasas de infiltración más elevadas, lo que disminuye la humedad disponible en el horizonte superficial (Rawls et al., 2003). La incidencia de este factor fue particularmente notable en las unidades con suelos de textura gruesa (U1, U9, U10), que exhibieron los menores contenidos de HS. Este hallazgo tiene implicaciones directas para la gestión del riego, ya que los suelos arenosos requieren intervenciones más frecuentes para evitar el estrés hídrico de los cultivos.

La temperatura del suelo también mostró una asociación negativa significativa con la HS superficial, lo que refleja el efecto de la evaporación directa sobre el contenido hídrico de la capa superficial. Las unidades situadas en altitudes menores y con temperaturas más elevadas (U7, U9) registraron humedades superficiales menores, en tanto que las ubicadas en zonas más frías y altas (U1, U2) mostraron mayor retención de agua. Este patrón es coherente con los procesos de evapotranspiración reportados para regiones de montaña tropical (Seneviratne et al., 2011). El NDVI contribuyó al modelo con una correlación negativa, reflejando que las coberturas con mayor densidad vegetal generan mayores tasas de evapotranspiración y, por ende, reducen la humedad superficial (Jackson, 1997). Este comportamiento fue particularmente pronunciado en las unidades con vegetación más densa (U3-U6). Aunque el EVI es a menudo considerado superior al NDVI en condiciones de alta biomasa (Huete et al., 2002), su baja correlación con la HSc en este estudio sugiere que la variabilidad de la cobertura vegetal en la cuenca no es suficientemente intensa para diferenciarlo como predictor independiente.

La ausencia de correlaciones significativas para la precipitación, la pendiente y el EVI puede explicarse por la escala temporal

y espacial de análisis. A nivel local y en períodos cortos, la rápida infiltración en suelos arenosos y la redistribución del agua en el perfil del suelo atenúan el efecto inmediato de la lluvia sobre la humedad superficial, tal como han documentado estudios previos en cuencas con similar variabilidad pedológica (Famiglietti et al., 1998).

La resolución espacial de los datos SMAP tuvo una influencia determinante en el desempeño de los modelos. El modelo a 1 km demostró ser el más preciso para capturar la variabilidad local del paisaje, en tanto que la precisión disminuyó progresivamente con resoluciones más gruesas. El comportamiento atípico del modelo a 36 km —con mejor ajuste que el de 9 km— podría asociarse a la capacidad de las observaciones de menor resolución para representar patrones regionales de HS que resultan difusos a resoluciones intermedias (Crow et al., 2012).

Los resultados son consistentes con trabajos previos de Alemohammad et al. (2017) y Abbaszadeh et al. (2019), quienes documentaron el potencial de técnicas de downscaling estadístico para mejorar la resolución espacial de los productos SMAP. Más recientemente, Nativel et al. (2022) y Tao et al. (2024) han ampliado este enfoque mediante la integración de sensores ópticos y de radar con datos de campo, obteniendo mejoras adicionales en la precisión predictiva en entornos con alta variabilidad climática y de uso del suelo. Desde una perspectiva práctica, los modelos desarrollados ofrecen una herramienta útil para optimizar el manejo del riego en sistemas agrícolas de la región andina, especialmente en suelos arenosos o en condiciones térmicas desfavorables. Las limitaciones del estudio incluyen la dependencia de los productos SMAP disponibles y la ausencia de variables como la conductividad hidráulica, la materia orgánica del suelo y la actividad

biológica, cuya incorporación podría mejorar la representación de la dinámica hídrica superficial en trabajos futuros. La aplicación de técnicas de aprendizaje automático, como redes neuronales o modelos de ensamble, representa una vía prometedora para extender y fortalecer el enfoque propuesto en zonas con mayor diversidad climática.

CONCLUSIONES

La investigación desarrolló una metodología robusta para la estimación espacial de la humedad superficial del suelo a escala local en la cuenca del río Quindío, sustentada en la integración de datos satelitales SMAP_L2 con variables ambientales obtenidas en campo y mediante teledetección de mediana resolución. Los modelos de regresión PLS ajustados en las cuatro resoluciones espaciales demostraron capacidad estadística significativa para capturar la variabilidad de la HS, logrando predicciones con una resolución superior a la de los productos satelitales de origen.

Los principales factores predictores identificados fueron la fracción de arena, la temperatura del suelo y el NDVI, los cuales reflejan la interacción entre las propiedades físicas del suelo, las condiciones térmicas locales y la dinámica de la cubierta vegetal. El modelo basado en la resolución de 1 km de SMAP presentó el mayor coeficiente de determinación ($R^2 = 72,75\%$), lo que confirma la ventaja de emplear datos de alta resolución para estudios locales en paisajes heterogéneos.

Los hallazgos tienen implicaciones aplicadas para la gestión sostenible del agua en sistemas agrícolas y naturales: el conocimiento detallado de la distribución espacial de la HS permite orientar decisiones de riego, gestión del suelo y conservación de recursos hídricos. La metodología propuesta es transferible a

otras cuencas con características similares y ofrece una base sólida para futuras investigaciones que incorporen técnicas de aprendizaje automático o conjuntos de datos de mayor densidad temporal.

REFERENCIAS

Abbaszadeh, P., Moradkhani, H., & Zhan, X. (2019). Downscaling SMAP radiometer soil moisture over the CONUS using an ensemble learning method. *Water Resources Research*, 55(1), 324-344. <https://doi.org/10.1029/2018WR023354>

Alemohammad, S. H., Kolassa, J., Prigent, C., Aires, F., & Gentile, P. (2017). Statistical downscaling of remotely-sensed soil moisture. En *IEEE International Geoscience and Remote Sensing Symposium (IGARSS)* (pp. 2511-2514). IEEE.

Babaeian, E., Sadeghi, M., Jones, S. B., Montzka, C., Vereecken, H., & Tuller, M. (2019). Ground, proximal, and satellite remote sensing of soil moisture. *Reviews of Geophysics*, 57(2), 530-616. <https://doi.org/10.1029/2018RG000618>

Barber, C. B., Dobkin, D. P., & Huhdanpaa, H. (1996). The quickhull algorithm for convex hulls. *ACM Transactions on Mathematical Software*, 22(4), 469-483. <https://doi.org/10.1145/235815.235821>

Brocca, L., Ciabatta, L., Massari, C., Camici, S., & Tarpanelli, A. (2017). Soil moisture for hydrological applications: Open questions and new opportunities. *Water*, 9(2), 140. <https://doi.org/10.3390/w9020140>

Chan, S. K., Bindlish, R., O'Neill, P. E., Njoku, E., Jackson, T., Colliander, A., & Yueh, S. (2016). Assessment of the SMAP passive soil moisture product. *IEEE Transactions on Geoscience and Remote Sensing*, 54(8), 4994- 5007.

Crow, W. T., Berg, A. A., Cosh, M. H., Loew, A., Mohanty, B. P., Panciera, R., & Walker, J. P. (2012). Upscaling sparse ground-based soil moisture observations for the validation of coarse-resolution satellite soil moisture products. *Reviews of Geophysics*, 50(2). <https://doi.org/10.1029/2011RG000372>

Famiglietti, J. S., Devereaux, J., Laymon, C., Tsegaye, T., Houser, P., Jackson, T., Graham, T., Rodell, M., & Van Oevelen, P. (1999). Ground-based investigation of soil moisture variability within remote sensing footprints during the SGP97 hydrology experiment. *Water Resources Research*, 35(6), 1839-1851.

Famiglietti, J. S., Rudnicki, J. W., & Rodell, M. (1998). Variability in surface moisture content along a hillslope transect: Rattlesnake Hill, Texas. *Journal of Hydrology*, 210(1-4), 259-281.

Gabriels, D., & Lobo, D. (2006). Métodos para determinar granulometría y densidad aparente del suelo. *Venesuelos*, 14(1), 37-48.

García-Reinoso, P. L., Monsalve-Durango, E. A., & Lozano-Sandoval, G. (2011). Análisis espacial y temporal del índice de escasez de agua en la cuenca del río Quindío. *Revista de Investigaciones Universidad del Quindío*, 22(1), 70-82.

Guo, X., Fu, Q., Hang, Y., Lu, H., Gao, F., & Si, J. (2020). Spatial variability of soil moisture in relation to land use types and topographic features on hillslopes in the black soil area of northeast China. *Sustainability*, 12(9), 3552. <https://doi.org/10.3390/su12093552>

Huete, A., Didan, K., Miura, T., Rodriguez, E. P., Gao, X., & Ferreira, L. G. (2002). Overview of the radiometric and biophysical performance of the MODIS vegetation indices. *Remote Sensing of Environment*, 83(1-2), 195- 213.

- IGAC - Instituto Geográfico Agustín Codazzi. (2013). Estudio semidetallado de suelos, Departamento del Quindío. Escala 1:25 000. Informe técnico.
- Jackson, T. J. (1997). Soil moisture estimation using special satellite microwave/imager satellite data over a grassland region. *Water Resources Research*, 33(6), 1475-1484.
- Lakshmi, V. (2013). Remote sensing of soil moisture. *ISRN Soil Science*, 2013, Article ID 424178. <https://doi.org/10.1155/2013/424178>
- Leone, A., Viscarra-Rossel, R., Amenta, P., & Buondonno, A. (2012). Prediction of soil properties with PLSR and vis-NIR spectroscopy: Application to Mediterranean soils from Southern Italy. *Current Analytical Chemistry*, 8(2), 283-299.
- 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>
- Nativel, S., Ayari, E., Rodriguez-Fernandez, N., Baghdadi, N., Madelon, R., Albergel, C., & Zribi, M. (2022). Hybrid methodology using Sentinel-1/Sentinel-2 for soil moisture estimation. *Remote Sensing*, 14(10), 2434. <https://doi.org/10.3390/rs14102434>
- Petropoulos, G. P., Ireland, G., & Barrett, B. (2015). Surface soil moisture retrievals from remote sensing: Current status, products and future trends. *Physics and Chemistry of the Earth*, 83-84, 36-56.
- Rawls, W. J., Pachepsky, Y. A., Ritchie, J. C., Sobecki, T. M., & Bloodworth, H. (2003). Effect of soil organic carbon on soil water retention. *Geoderma*, 116(1-2), 61-76.
- Seneviratne, S. I., Corti, T., Davin, E. L., Hirschi, M., Jaeger, E. B., Lehner, I., Orlowsky, B., & Teuling, A. J. (2010). Investigating soil moisture–climate interactions in a changing climate: A review. *Earth-Science Reviews*, 99(3-4), 125-161. <https://doi.org/10.1016/j.earscirev.2010.02.004>
- Sykora, S. (2009). Mathematical means and averages: Generalized Heronian means. *Stan's Library*. <https://doi.org/10.3247/SL3Math09.002>
- Tao, S., Zhang, X., Chen, J., Zhang, Z., Kang, X., Qi, W., & Gao, Y. (2024). Generating surface soil moisture at 30 m resolution in grape-growing areas based on stacked ensemble learning. *International Journal of Remote Sensing*, 45(16), 5385-5424.
- Wagner, W., Blöschl, G., Pampaloni, P., Calvet, J. C., Bizzarri, B., Wigneron, J. P., & Kerr, Y. (2007). Operational readiness of microwave remote sensing of soil moisture for hydrologic applications. *Nordic Hydrology*, 38(1), 1-20.
- Wold, H. (1974). Causal flows with latent variables: Partings of the ways in the light of NIPALS modelling. *European Economic Review*, 5(1), 67-86.
- Yu, Z., Carlson, T., Barron, E., & Schwartz, F. (2001). On evaluating the spatial temporal variation of soil moisture in the Susquehanna river basin. *Water Resources Research*, 37(5), 1313-1326.
- Zhang, D., & Zhou, G. (2016). Estimation of soil moisture from optical and thermal remote sensing: A review. *Sensors*, 16(8), 1308. <https://doi.org/10.3390/s16081308>