

ESTIMACIÓN DE LA HUMEDAD DEL SUELO A NIVELES DE CAPACIDAD DE CAMPO Y PUNTO DE MARCHITEZ MEDIANTE MODELOS PREDICTIVOS A ESCALA REGIONAL

Pedro Pérez Cutillas

Departamento de Geografía. Universidad de Murcia. Centro de Edafología y Biología Aplicada del Segura,
Consejo Superior de Investigaciones Científicas (CEBAS-CSIC)
pedrope@um.es, perezcutillas@cebas.csic.es

Gonzalo G. Barberá

Centro de Edafología y Biología Aplicada del Segura, Consejo Superior de Investigaciones Científicas (CEBAS-CSIC)
gbarbera@cebas.csic.es

Carmelo Conesa García

Departamento de Geografía. Universidad de Murcia
cconesa@um.es

RESUMEN

La estimación de valores edáficos mediante el empleo de técnicas de modelización espacial, basada en procesos y variables ambientales, puede ser una solución válida para solventar la escasez de datos relativos a la información de las propiedades del suelo en estudios aplicados a grandes áreas de trabajo. Para este trabajo se han empleado valores del potencial de succión a niveles de Capacidad de Campo (pF 2,5) y Punto de Marchitez (pF 4,2) obtenidos a partir de datos de 307 perfiles (Proyecto LUCDEME) distribuidos en la Región de Murcia (más de 10000 km²), con el fin de proporcionar una estimación del contenido de humedad del suelo a los niveles de pF mencionados mediante 21 variables ambientales utilizadas como predictores. Los resultados aportados muestran claras diferencias en las variables que componen cada uno de los modelos, lo que sugiere que los procesos que determinan los valores de pF 2,5 y pF 4,2 en el suelo pueden ser distintos. Entre las variables más

Fecha de recepción: mayo 2013.

Fecha de aceptación: febrero 2014.

influyentes destacan las asociadas al relieve (i.e. modelo digital de elevaciones, curvaturas), la acumulación de flujo vinculada a las redes de drenaje, y los valores obtenidos mediante técnicas de teledetección, como el NDVI.

Palabras clave: propiedades del suelo, potencial hídrico, modelización, SIG, variables ambientales, teledetección.

ABSTRACT

Estimating soil values by using spatial modeling techniques based on processes and environmental variables can resolve the scarcity of data concerning from soil properties in studies applied to large areas. In this paper we have used values of soil water potential, on levels for Field Capacity (*pF* 2.5) and Wilting Point (*pF* 4.2), obtained from 307 profiles (LUCDEME Project) distributed in the region de Murcia (over 10000 km²), for the purpose of provide an estimate of the moisture content of soil *pF* mentioned levels by 21 environmental variables used as predictors. The supplied results show distinct differences in the variables that compose each of the models, which suggest that the processes that determine the values of *pF* 2.5 and *pF* 4.2 in soil can be different. Among the most influential variables include those associated with topography (digital elevation model, curvatures), flow accumulation linked to drainage networks, and values obtained by remote sensing techniques, such as NDVI.

Keywords: soil properties, water potential, modeling, GIS, environmental variables, remote sensing.

I. INTRODUCCIÓN

El contenido de la humedad del suelo es un factor esencial en la dinámica de los flujos hídricos de las regiones semiáridas (Dunkerley, 2002). Por lo general, se produce una disminución de la capacidad de infiltración de los suelos a medida que la humedad se incrementa (Manfreda et al., 2010), situación que se agrava en episodios tormentosos, cuando los volúmenes de precipitación en superficie superan la capacidad de infiltración del suelo llegando al estado de saturación, proceso que se conoce como ‘Infiltration excess overland flow’ (Herwitz, 1986; Garcia-Estringana et al., 2010). Escorrentía y humedad del suelo se presentan como elementos dependientes en los procesos hidrológicos, siendo ésta última un factor de considerable influencia en la economía hídrica de las plantas (Bucci et al., 2009), entendida como el balance de flujos entre suelo, planta y atmosfera. La vegetación natural, y en menor medida los cultivos (Loussert, 1992; Agustí, 2003), dependen del balance entre el agua que la planta absorbe del suelo y la que pierde por transpiración. Un exceso de transpiración respecto a la absorción genera un balance hídrico negativo con consecuencias negativas para el crecimiento y la producción en los cultivos. Por lo tanto, resulta interesante conocer cómo puede influir la dinámica del agua subsuperficial en la vegetación mediante el estudio de las propiedades hídricas del suelo.

Conocer las relaciones existentes entre potencial matricial (ψ) y el contenido de agua en el suelo (θ) resulta especialmente útil para describir las propiedades hidrodinámicas del

suelo. El contenido hídrico se halla normalmente regulado por la capacidad de cada suelo para la retención de agua a una determinada presión negativa, de modo que la disponibilidad del agua vendrá determinada por la relación de estos procesos, junto a la humedad precedente en los sistemas hidrológicos en estudio (Malik et al., 1987). La curva característica de retención de humedad expresa la relación entre el contenido de agua (θ ; $\text{m}^3 \text{m}^{-3}$) y el potencial matricial del suelo (ψ , Pa). Esta correspondencia proporciona información sobre características importantes como la capacidad máxima de almacenamiento de agua en el suelo, la capacidad de campo y el punto de marchitamiento. Tales procesos actúan de manera asimétrica por el efecto de histéresis en el estado de capilaridad del agua en el suelo, lo cual origina un comportamiento diferencial entre las fases de absorción de y de desorción producidas en los poros (Richards, 1931), y con ello distintos comportamientos de tensión y deformación dependiendo del grado de saturación en que se encuentra el suelo (Wheeler et al., 2003). La curva de retención de humedad del suelo se ha parametrizado de diversos modos, siendo la formulación de Van Genuchten (1980) la más popular.

La medición de estas propiedades hídricas, tanto en campo como en laboratorio, es compleja en tiempo y recursos, además de demandar un gran número de muestras debido a la variabilidad espacial del suelo (Klute, 1986). Y a pesar que numerosos estudios reconocen la utilidad de los modelos de regresión predictivos para obtener funciones hidráulicas del suelo a partir de propiedades de éste en grandes extensiones (Wosten y Van Genuchten, 1988; Schuh y Cline, 1990; Twarakavi et al., 2010), son, en cambio, escasos los trabajos referidos al análisis y aplicación de técnicas que, basadas en el uso de modelos estadísticos, tratan de estimar las propiedades hidráulicas del suelo a escala regional mediante variables ambientales. Los procesos de cálculo, desarrollados en estos últimos, permiten obtener resultados con una distribución espacial acorde a las características ambientales del entorno analizado, al mismo nivel que otras técnicas de estimación directa generadas a través de métodos de interpolación como cokriging (McBratney et al., 1981), o procesamientos de regresión ponderada geográficamente (GWR) (Wang et al., 2013). Es conocido que las propiedades hidráulicas en el suelo tienen una alta variabilidad espacial, y están condicionadas por la combinación de numerosos factores ambientales (Poggio et al., 2010; Bandara et al., 2013).

Estas técnicas que están basadas fundamentalmente en la dependencia espacial de las variables de estudio, está señalada para áreas no muy grandes y con muestreos bastante intensivos y regulares (Chen et al. 2000; Fox and Sabbagh 2002). En una estimación de carácter regional (entendida como un área extensa de miles de kilómetros cuadrados), con muestras ampliamente dispersas, la información proporcionada por la posible autocorrelación espacial entre muestras puede ser muy reducida (Burrough et al., 1997; Western et al., 2004). Como la densidad de medidas no es habitualmente muy alta a escala regional, se requiere el uso de otros métodos para predecir los valores de las variables del suelo de manera sencilla y asequible (Ließ et al., 2012). Una alternativa particularmente efectiva es la modelización de la relación entre la variable de interés en el suelo y las variables ambientales de las que se dispone de información espacialmente distribuida (Gessler et al., 1995; Brus y De Grujter, 1997; McKenzie y Ryan, 1999; Thompson et al., 2001; McBratney et al., 2003). La importancia de dicha relación en el proceso de elaboración de la cartografía digital de suelos ha sido ya reseñada por diversos autores mediante el uso de métodos estadísticos aplicados a la predicción espacial de las propiedades del suelo (Minasny et al., 2008; Dobos

and Hengl, 2009; Bou Kheir et al., 2010; Greve et al., 2012). El resultado son productos cartográficos con información continua obtenidos mediante modelos estadísticos de las propiedades del suelo en función de las variables ambientales que influyen en su formación y distribución espacial.

Desde otra perspectiva, la teledetección va a permitir una visión general de grandes superficies, proporcionando volúmenes masivos de datos cuantitativos georreferenciados, y valores espectrales que presentan buenas correlaciones con las coberturas de los usos del suelo, además de poseer una capacidad de actualización temporal muy dinámica (Ben-Dor, 2002). La evaluación, caracterización y determinación de las propiedades del suelo, mediante la utilización de datos procedentes de sensores remotos ha sido extensamente aplicada durante los últimos años (Scull et al., 2002; Rawls et al., 2004; Uno et al., 2005; Vrieling, 2006; Lagacherie et al., 2012; Poggio et al., 2013). La capacidad de la espectrometría en condiciones de laboratorio está demostrada para la predicción de importantes propiedades del suelo (Schulten y Schnitzer, 1997; Viscarra Rossel et al., 2006; Ben-Dor et al., 2009). Sin embargo, su aplicación directa a la superficie terrestre no está exenta de ciertas dificultades y limitaciones, lo que hace aconsejable, en este caso, enfocar su uso a la obtención de índices específicos relacionados con las variables ambientales

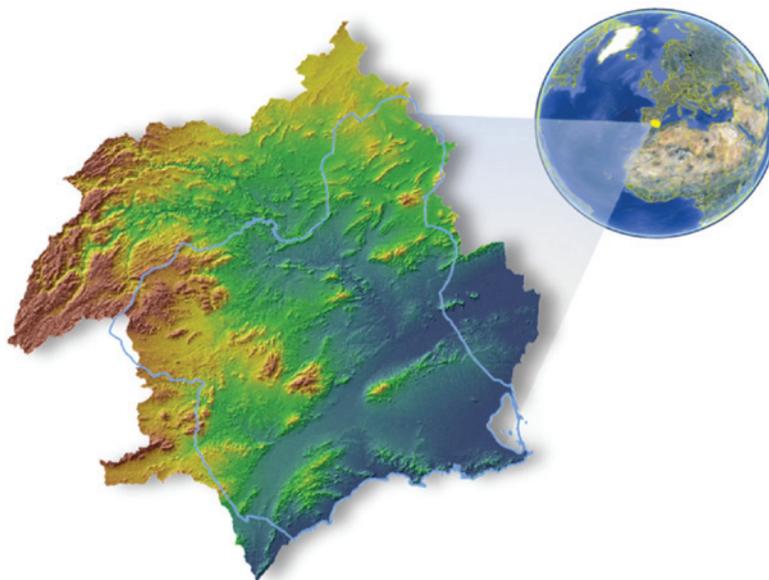
Los resultados de los trabajos mencionados han servido para plantear aquí procesos de modelización, mediante análisis de regresión con una serie de variables ambientales, necesarios para el cálculo de los valores de capacidad de campo y del punto de marchitamiento de la curva de retención de humedad del suelo.

II. **ÁREA DE ESTUDIO Y CONDICIONES AMBIENTALES**

Como área de estudio se ha elegido la Región de Murcia (11313 km², INE, 2013), encuadrada dentro de la cuenca del Río Segura (18208 km², CHS, 2013) en el Sureste de España (Fig. 1). En conjunto, se trata de una superficie bastante accidentada por la presencia de numerosas sierras, pertenecientes a las Cordilleras Béticas, que se alinean en dirección ENE-WSW con altitudes a menudo superiores a los 1.000 m. Entre ellas se intercalan una serie de valles, cubetas, llanuras y altiplanos, que en conjunto configuran una topografía contrastada y un territorio singular de gran variedad paisajística. La zona de estudio participa en su mayor parte de las características de un clima mediterráneo semiárido (Capel-Molina, 2000): precipitación media de la cuenca en torno a 375 mm/año, con valores medios anuales de 472 mm en cabecera y de 317 mm en zonas próximas a la desembocadura, gran irregularidad pluviométrica estacional e interanual, sequías prolongadas y lluvias a menudo torrenciales.

Toda esta región recibe una fuerte insolación anual, con un promedio de 2800 horas de sol al año, un máximo en julio (340 h) y un mínimo en diciembre (160 h), según datos del observatorio de Alcantarilla, próximo a la ciudad de Murcia (Alonso Sarria, 2007). Por el carácter accidentado del relieve regional, las variaciones locales en la radiación recibida son notables. Sólo en las tierras más llanas (llanura litoral, depresiones pre-litorales y altiplanicies) los contrastes disminuyen y la homogeneidad es mayor. Estimaciones basadas en modelos teóricos de terreno han dado valores medios de 5.023 kWh/m²/año, valores que superan los 5.500 e incluso los 6.000 en solana y descienden en la umbría, especialmente en las zonas de mayor altitud (Conesa García y Alonso Sarría, 2006).

Figura 1
ÁREA DE ESTUDIO, CUENCA DEL RÍO SEGURA, EN EL SE DE LA PENÍNSULA IBÉRICA.
EN CONTORNO, LÍMITE DE LA REGIÓN DE MURCIA



La desertificación y la pérdida de suelo por erosión se presentan como unas de las causas más importantes de la degradación del suelo en este territorio, ya que implica una pérdida de sus principales componentes físicos, químicos y biológicos (Boix-Fayos et al., 2005). Según datos del Inventario Nacional de Erosión de Suelos, elaborado por el Ministerio de Medio Ambiente (MMA, 2002-2012), la erosión media del suelo en la Cuenca del río Segura se sitúa en torno a la media española, $24,53 \text{ ton/ha}^{-1}\text{año}^{-1}$, equivalentes a un rebajamiento de casi 2 mm al año. En esta cuenca existe una gran diversidad de suelos originados por la acción de diferentes procesos asociados a la influencia de múltiples factores ambientales. Entre ellos destacan las condiciones climáticas, la litología y el relieve, que condicionan en gran medida la erosión y los procesos edáficos (Álvarez Rogel et al., 2001).

III. MATERIAL Y MÉTODOS

III.1. Datos analíticos del Proyecto LUCDEME

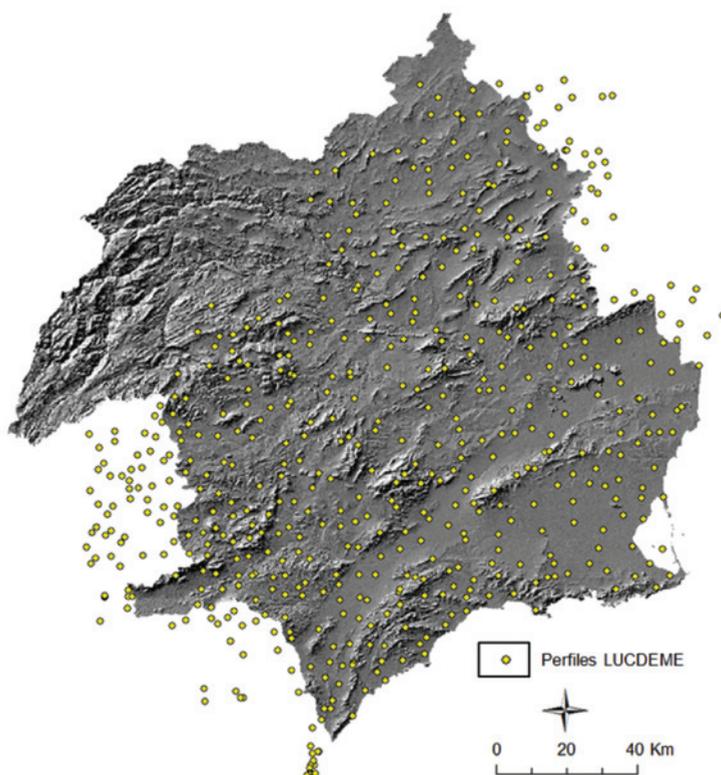
Toda la información empírica sobre el potencial de succión (pF) en el suelo ha sido obtenida a partir de datos del Proyecto de Lucha contra la Desertificación en el Mediterráneo (LUCDEME) (ICONA, 1986), elaborado a comienzos de los años ochenta y primeros de los noventa. La información utilizada en esta parte del trabajo se centra en los datos completos de una selección de perfiles edáficos, muestreados en el campo y analizados en el laboratorio. Las diferentes unidades taxonómicas del sistema FAO-UNESCO (1974), extraídas del

proyecto LUCDEME para la zona de estudio, están caracterizadas por 307 perfiles, muestreados ad-hoc, distribuidos por el territorio en los lugares donde mejor representadas se hallan dichas unidades. La información de los perfiles aparece clasificada por profundidades de los diferentes horizontes observados en campo, en función de sus propiedades físico-químicas anotadas en 1880 registros.

El empleo de variables ambientales para la estimación de los valores de contenido de humedad a escala regional aconseja filtrar estos muestreos a los niveles superiores del perfil para una mejor conexión con la descripción de la información ambiental. De las determinaciones analíticas de los perfiles se han suprimido los horizontes orgánicos (parte externa del suelo) y los horizontes más profundos (Fig. 2).

Figura 2

DISTRIBUCIÓN ESPACIAL DE LOS MUESTREOS DE CAMPO DEL PROYECTO LUCDEME PARA LAS DETERMINACIONES ANALÍTICAS DE LOS PERFILES



III.2. Variables ambientales empleadas en la modelización

En sentido estricto no se pueden denominar variables ambientales de obtención directa a todas las variables utilizadas en los procesos de modelización de este estudio. Algunas de

ellas son índices elaborados a partir de señales espectrales de sensores remotos que sólo se pueden relacionar indirectamente con las características del suelo. No obstante, mantenemos esta denominación para homogeneizar toda la información tratada en los análisis de SIG y tratamientos estadísticos. Estas variables se pueden estructurar en una serie de conjuntos de datos, que son descritos en los siguientes bloques de variables (entre paréntesis y en negrita figura el número de secuencia de cada variable):

III.2.1. Variables topográficas e hidrológicas

Estas variables se han obtenido a partir del Modelo Digital del Terreno (DTM) de la misión TERRA de la NASA, realizado con el sensor japonés ASTER (NASA – METI, 2013). A partir de este DTM (**1**) se ha obtenido: Pendientes (**2**), utilizando el método de cambio máximo en el valor de altitud respecto de los píxeles circundantes para cada píxel, con valores expresados en grados de inclinación (Burrough and McDonnell, 1998). La curvatura que se calcula de manera análoga al mapa de pendientes, pero mediante la segunda derivada, expresándose como la pendiente de la pendiente (Moore et al., 1991). La curvatura se puede descomponer (Zeverbergen and Thorne, 1987) en Curvatura del perfil (**3**), que se calcula a partir de la dirección de máxima pendiente, y curvatura perpendicular (**4**). Y la acumulación de flujo (**5**) que representa el número de píxeles de la cuenca vertiente a un píxel en particular (Tarboton et al., 1991). Indicar que la distribución de esta variable tiene una distribución fuertemente sesgada a la derecha por lo que para la modelización se ha utilizado su logaritmo.

III.2.2. Tipos de suelos y litología

La información edafológica y litológica procede de diferentes fuentes. Mapa de suelos del proyecto LUCDEME (E. 1:100.000) (**6**) con la distribución espacial de las unidades taxonómicas clasificadas según el Sistema FAO 1974, la mayoría de los polígonos del suelo no identifican una unidad taxonómica sino una asociación de dos o tres unidades. Además el mapa de suelos cartografía la Fase Salina (**7**), identificada como áreas cuya conductividad eléctrica > 2 mmhos/cm Mapa de litología (**8**) realizado a partir de los datos del Mapa Geológico Nacional 1:50.000 (MAGNA) del Instituto Geológico y Minero de España (IGME), cartografía geológica que ha sido reclasificada para obtener los valores litológicos, mediante interpretación de la leyenda de cada formación geológica que aparece en la memoria que acompaña a cada hoja del mapa

III.2.3. Variables climáticas

Las variables climáticas utilizadas son la capa de precipitación (mm) (**9**) y la de temperatura (°C) (**10**) para la zona de estudio, elaboradas por el Laboratorio de Biogeografía Informática (LBI, 2013) del Museo Nacional de Ciencias Naturales del CSIC y diversas variables relacionadas con la radiación solar.

La radiación solar recibida por un punto en un momento depende de la posición del sol respecto a la superficie receptora que a su vez está determinado por la latitud y el momento

del año. La cantidad de radiación solar que recibe una superficie es sólo una porción de lo que recibiría fuera de la atmósfera debido a la transmisividad de esta, influyendo solo la proporción de radiación solar capaz de atravesarla (Rich et al., 1994). El cálculo de la radiación se ha realizado para un año completo, obteniéndose tres capas de información: La radiación solar directa (**11**) (Fu and Rich, 2000), es decir, la radiación que la superficie recibe directamente del sol, (**12**) la radiación solar difusa (Fu and Rich, 2000), correspondiente a la radiación que alcanza un punto no directamente del sol sino de la proporción que ha sido dispersada por la atmósfera. Finalmente se incluyó una última capa que representa la duración de la radiación solar directa (**13**), indicada en horas de insolación directa para cada uno de los píxeles.

III.2.4. Variables complementarias obtenidas mediante Teledetección

Se han utilizado imágenes del satélite Landsat 5 para obtener información adicional, mediante el uso de dos fechas (14/02/2009 y 24/07/2009). Estas imágenes corresponden a dos periodos estacionales diferentes del mismo año, uno estival y otro invernal. De esta forma se minimiza el posible sesgo estacional. Para cada periodo se estimó el Índice de Vegetación de Diferencia Normalizada (NDVI) (**14 y 15**, datos para invierno y verano, respectivamente). Este índice permite determinar la cantidad, calidad y desarrollo de la vegetación de acuerdo con la medición de la intensidad de la radiación de las longitudes de onda de la zona Roja (R) e Infrarrojo Cercano (IRC) del espectro electromagnético que la vegetación emite o refleja (Townshend et al, 1985). Este índice aprovecha la diferencia de las características espectrales de estas dos bandas, donde las altas absorciones de pigmentos de clorofila en la banda Roja contrastan con la alta reflectividad de los materiales vegetales de la banda IRC.

$$NDVI = (IRC - R)/(IRC + R)$$

Donde *IRC* es el valor de los píxeles en la banda del Infrarrojo Cercano (0,75–0,90 μm) y *R* el valor de los píxeles en la banda Roja (0,63–0,69 μm).

También se han aplicado una serie de algoritmos sobre las imágenes seleccionadas para obtener indicadores mineralógicos (Sabins, 1981; Crosta et al., 2003), mediante combinación de las siguientes funciones estandarizadas «Clay Minerals» (minerales de arcilla, CMI) (**16 y 19**), «Ferrous Minerals» (minerales ferrosos, FMI) (**17 y 20**) y «Iron Oxide» (óxidos de hierro, IOI) (**18 y 21**). Para cada una de las funciones se han realizado los cálculos correspondientes a la estación de verano (Julio) e invierno (Febrero).

El primer índice (CMI) se deriva de la alta reflectancia de los minerales arcillosos al infrarrojo medio (IRM, 1,55 a 1,75 μm) y baja al infrarrojo térmico próximo (TP, 2,09 a 2,35 μm), mientras que una roca no alterada tiene una reflectancia relativamente uniforme en las dos longitudes de onda. El índice FMI se ha empleado para realzar áreas con alto contenido ferroso (Dury, 1987), aplicando el mismo principio que en el caso anterior, en concreto el cociente entre el intervalo de longitud de onda del infrarrojo medio (IRM, 1,55 a 1,75 μm), donde estos minerales ofrecen una gran reflectividad, y los del infrarrojo cercano (IRC, 0,75–0,90 μm), con elevados niveles de absorción. Los minerales con contenido en óxido de hierro tienen valores elevados de reflectancia correspondientes al intervalo de longitud de

ondas de la banda Roja ($R, 0,63-0,69 \mu\text{m}$) y valores más bajos de reflectancia en el intervalo de longitud de la banda Azul ($A, 0,45-0,515 \mu\text{m}$), mientras que una roca sin minerales de este tipo registra valores semejantes en las bandas roja y azul. Mediante el índice IOI que resulta del cociente de valores entre ambas bandas, pueden distinguirse rocas formadas por minerales con cierto contenido en hierro, posiblemente afectadas por procesos de alteración hidrotermal. En el cálculo de dichos índices se han empleado los siguientes algoritmos:

$$\text{Índice de Minerales Arcillosos (CMI)} = \text{IRM} / \text{TP}$$

$$\text{Índice de Minerales Férricos (FMI)} = \text{IRM} / \text{IRC}$$

$$\text{Índice de Óxido de Hierro (IOI)} = R / A$$

Donde A es el valor de los píxeles en la banda Azul ($0,45-0,515 \mu\text{m}$); R , el valor de los píxeles en la banda Roja ($0,63-0,69 \mu\text{m}$); IRC , el valor de los píxeles en la banda del Infrarrojo Cercano ($0,75-0,90 \mu\text{m}$); IRM , el valor de los píxeles en la banda del Infrarrojo Medio ($1,55-1,75 \mu\text{m}$); TP , el valor de los píxeles en la banda del Térmico Próximo ($2,09-2,35 \mu\text{m}$).

A continuación (Tabla 1) se exponen los valores resumen de cada una de las variables expuestas:

Tabla 1

DESCRIPCIÓN DE LA REPRESENTATIVIDAD DE LOS VALORES DE LAS VARIABLES AMBIENTALES RASTER Y SU ESTADÍSTICO DESCRIPTIVO CON EL CÁLCULO DEL RANGO, MEDIA Y DESVIACIÓN ESTÁNDAR

Id	Variable	Descripción valores mínimos	Descripción valores máximos	Rango	Media	Desv. Estándar
(1)	DTM	Altitud nivel mar	Altitud absoluta	0 - 2057	612	± 407
(2)	Slp	Superficies llanas	Relieve escarpado	0 - 79	7,5	$\pm 7,7$
(3)	CuP	Curvatura Cóncava	Curvatura Convexa	-1,6	0,008	$\pm 0,27$
(4)	CuPP	Curvatura Convexa	Curvatura Cóncava	-6	0,008	$\pm 0,41$
(5)	FAc	Baja Acumulación de flujo	Alta Acumulación de flujo	0 - 17	1,6	$\pm 1,8$
(9)	Pr	Precipitación mínima	Precipitación máxima	250 - 771	390	± 84
(10)	Tmp	Bajas temperaturas	Altas temperaturas	8,2 - 18,4	15,1	$\pm 2,07$
(11)	RaDir	Baja radiación directa	Alta radiación directa	0,001 - 2.258 *	1,36 *	$\pm 0,12$
(12)	RaDif	Baja radiación difusa	Alta radiación difusa	0,083 - 0,514 *	0,28 *	$\pm 0,01$
(13)	RaDur	Escasa duración de radiación	Elevada duración de radiación	40 - 4360	4,03	$\pm 0,27$
(14)	NDVIfeb	Suelos artificiales - agua	Abundante vegetación	-2	0,05	$\pm 0,19$
(15)	NDVIjul	Suelos artificiales - agua	Abundante vegetación	-2	0,03	$\pm 0,13$
(16)	CMIfeb	Baja alteración minerales CMI	Alta alteración minerales CMI	0 - 3,5	1,21	$\pm 0,97$
(17)	FMIfeb	Baja alteración minerales FMI	Alta alteración minerales FMI	0 - 3	0,83	$\pm 0,75$
(18)	IOIfeb	Baja alteración minerales IOI	Alta alteración minerales IOI	0 - 1,5	0,31	$\pm 0,28$
(19)	CMIjul	Baja alteración minerales CMI	Alta alteración minerales CMI	0 - 3,5	1,21	$\pm 0,92$
(20)	FMIjul	Baja alteración minerales FMI	Alta alteración minerales FMI	0 - 3	0,95	$\pm 0,76$
(21)	IOIjul	Baja alteración minerales IOI	Alta alteración minerales IOI	0 - 1,5	0,39	$\pm 0,34$

* RaDr y RaDi están escalados a 1/1000000 respecto a los valores originales. En la tabla están expresados en MWh/m^2 .

III.3. Modelos predictivos de estimación del contenido de humedad para los valores de capacidad de campo y punto de marchitez

Los procedimientos SIG se implementaron mediante ArcGIS v.10 (ESRI, 2013). A partir de las coordenadas de las muestras de la base de datos se obtuvieron los valores de las 21 variables ambientales para píxeles de 400 m de resolución. Debido a la naturaleza discreta de las variables del bloque SL en los modelos propuestos existe un coeficiente para el efecto de cada nivel de la clase, esto es para cada tipo desuelo o litología. Por razones matemáticas, los niveles de una variable discreta se introducen en un modelo de regresión como un conjunto de variables *dummy*. Así, se crean tantas variables nuevas como niveles tiene la clase, asignando el valor 1 a la variable que representa un nivel particular cuando la muestra en particular pertenece a ese nivel. Con ese sistema de decodificación y con la estructura de un modelo de regresión, es preciso que exista un nivel de 'referencia', no necesariamente explícito en la formulación del modelo, en tanto que los coeficientes para el resto de las variables *dummy* expresan el efecto respecto a esa clase de referencia.

Los valores de pF disponibles para cada punto fueron relacionados en una tabla con los correspondientes a las variables ambientales seleccionadas. Dicha tabla se utilizó como *input* para el lenguaje de análisis estadístico 'R' (R Core Team, 2013), con el que se construyeron modelos de regresión según el procedimiento descrito más adelante. Un modelo de regresión en el que los predictores son capas de SIG puede representarse fácilmente mediante álgebra de mapas ya que es una simple combinación lineal de dichas capas.

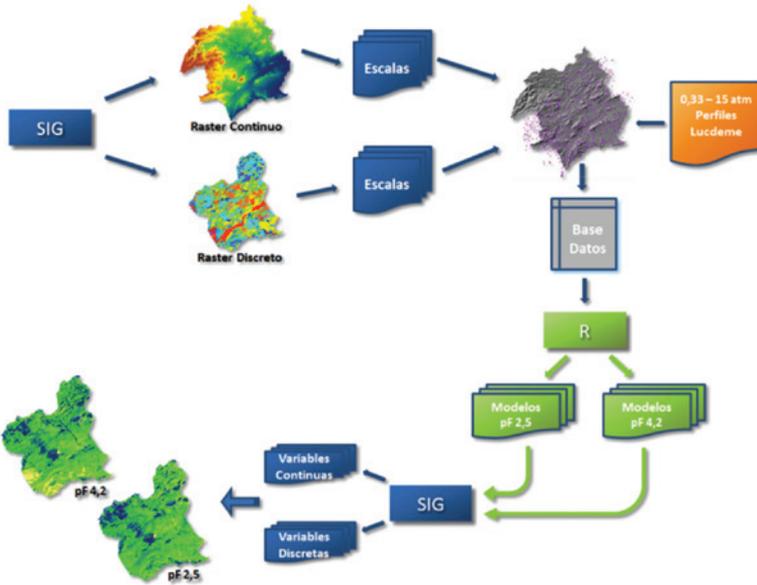
La resolución de píxel para los modelos fue de 400 m, por tratarse de una resolución espacial con cierto detalle y ser acorde con la modelización de estos valores a escala regional. Además, Pérez-Cutillas (2013) mostró que el uso de resoluciones inferiores no mejora de manera sustancial la capacidad predictiva de los modelos. Para uniformizar dicha resolución, se realizó el cambio de tamaño de los píxeles originales para todas las capas utilizadas como variables predictoras en los modelos de pF . Para las variables originalmente ráster se remuestreó por interpolación bilineal (Kidner et al., 1999), salvo en el caso de las variables climáticas de temperatura y precipitación, que se han introducido en los modelos en una sola resolución con su tamaño original de 850 m. En el caso de las capas vectoriales los polígonos fueron remuestreados a ráster con una resolución de 400 m, de tal forma que un píxel es siempre asignado al polígono que cubre mayor superficie dentro del mismo. En la Figura 3 se esquematiza el proceso completo. Los datos analíticos del potencial de succión corresponden a los 307 perfiles de muestreo del proyecto LUCDEME en la zona de estudio.

Para obtener el modelo de pF en función de las variables ambientales se aplicó la regresión lineal paso a paso hacia adelante (*forward stepwise*) utilizando el Criterio de Información de Akaike (AIC). El AIC fue desarrollado por Hirotugu Akaike (1974). El método ofrece una medida relativa de la pérdida de información cuando un determinado modelo es utilizado para describir la realidad, de modo que finalmente permite seleccionar el modelo que más se ajusta a los datos reales. Matemáticamente se puede demostrar que AIC mide la distancia entre el modelo ajustado y el modelo perfecto que representa exactamente la realidad, incluso aunque este modelo perfecto no nos sea nunca conocido. De esta forma, entre dos modelos ajustados a los mismos datos es preferible aquél cuyo valor de AIC es menor porque está más cercano al modelo perfecto o ideal. Hay

que señalar que un pequeño descenso en los valores calculados en el AIC representa una mejora importante en localidad del modelo. El AIC se expresa de la siguiente manera:

$$AIC = 2k - 2\ln(L)$$

Figura 3
PLANTEAMIENTO METODOLÓGICO DEL ANÁLISIS SIG Y ESTADÍSTICO PARA LA ESTIMACIÓN DEL POTENCIAL HÍDRICO A pF 2,5 Y pF 4,2



Donde k es el número de parámetros en el modelo, y L , el valor máximo de la función de verosimilitud para el modelo estimado. Aplicado a un proceso de selección de modelos paso a paso, de manera resumida, la mecánica es la siguiente. En primer lugar se ajustan modelos con una sola variable, seleccionando entre todos ellos el modelo con el AIC más bajo, y a partir de él se construye una batería de modelos de dos variables. De estas dos variables una es fija, que se seleccionó en el primer paso, mientras que la segunda proviene del subconjunto formado por el resto de las variables. Es decir, se construyen todos los modelos de 2 variables que incluyan como variable la seleccionada en el primer paso. De entre todos ellos se selecciona como mejor modelo aquél con AIC más bajo. Se sigue sucesivamente el proceso con 3, 4, etc. variables hasta que el AIC de un modelo con $n+1$ variables es superior al modelo con n variables. En este sentido el proceso de selección de variables es el clásico de paso a paso hacia delante (*forward stepwise*), pero el criterio para añadir variables está basado en AIC.

Como la respuesta frente a las variables cuantitativas puede ser no lineal, para todas ellas se utilizó en los modelos términos cuadráticos. Por ejemplo, para la precipitación no se incluyó en la construcción de los modelos sólo la variable *precipitación* sino también su cuadrática *precipitación*². De esta forma el modelo puede ajustar fácilmente diversas formas curvas.

IV. RESULTADOS Y DISCUSIÓN

IV.1. Modelización de los valores de pF mediante variables ambientales a escala regional

El mejor modelo predictivo para el contenido de agua en el suelo a valores de capacidad de campo (*pF* 2,5) generado por el procedimiento descrito y de acuerdo con los valores de AIC obtenidos para cada combinación de variables, se describe en la siguiente fórmula (los acrónimos de los modelos se describen en la Tabla 1):

$$\text{Modelo } pF\ 2,5 = [DTM + FAc^2 + RaDi + RaDr + RaDu^2 + FMI_{feb} + NDVI_{jul} + FSLu]$$

A continuación se muestra el mejor modelo obtenido para los valores del punto de marchitez (*pF* 4,2):

$$\text{Modelo } pF\ 4,2 = [DTM + DTM^2 + CuP + CuP^2 + FAc^2 + Tmp^2 + Pr^2 + RaDi + RaDr + NDVI_{jul} + LM + FSLu]$$

Los modelos obtenidos muestran unos coeficiente de determinación dispares, $R^2 = 0,15$ para el *pF* 2,5 y $R^2 = 0,31$ para el *pF* 4,2. Los coeficientes y sus errores estándar calculados para cada una de las variables cuantitativas se muestran en la Tabla 2, mientras que los coeficientes para los diferentes niveles de las variables discreta aparecen indicados en la Tabla 3.

Tabla 2
VARIABLES Y COEFICIENTES OBTENIDOS EN LA MODELIZACIÓN DE LOS *pF* 2,5 Y *pF* 4,2.

Variable	<i>pF</i> 2,5		<i>pF</i> 4,2	
	Estimate	Std. Error	Estimate	Std. Error
(Intercept)	2,96E+05	1,02E+05	1,08E+05	7,06E+04
DTM	3,69E+01	1,21E+01	4,45E+01	1,60E+01
DTM ²	---	---	-1,72E-02	6,24E-03
CuP	---	---	4,85E+04	1,74E+04
CuP ²	---	---	-2,40E+05	1,24E+05
FAc ²	8,06E+01	4,23E+01	6,96E+01	3,37E+01
Tmp ²	---	---	1,46E+02	7,53E+01
Pr ²	---	---	1,18E-01	3,94E-02
RaDi	-1,16E+06	4,14E+05	-6,26E+05	2,66E+05
RaDr	1,86E+04	9,82E+03	1,15E+04	7,84E+03
RaDu ²	1,10E+03	7,43E+02	---	---
FMI _{feb}	-3,21E+03	1,18E+03	---	---
NDVI _{jul}	1,37E+04	4,75E+03	1,22E+04	3,72E+03
SPLu	3,43E+03	1,40E+03	2,30E+03	1,09E+03

Tabla 3

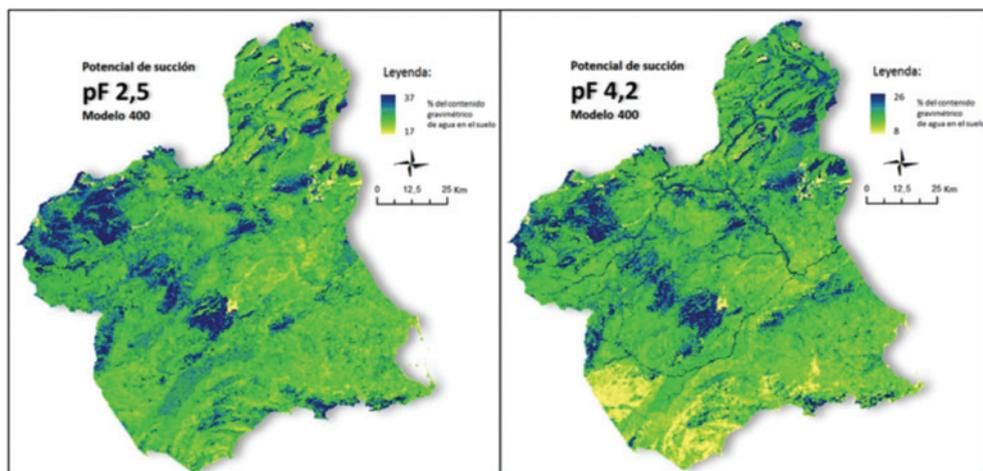
COEFICIENTES OBTENIDOS EN EL PROCESO DE MODELIZACIÓN DE LOS NIVELES DE pF 2,5 Y pF 4,2 PARA LAS DIFERENTES CATEGORÍAS DE LA VARIABLE DISCRETA 'LITOLOGÍAMAGNA' (LM). RELACIÓN DE CLASES Y CÓDIGOS POR MUESTRA: ARCILLAS = 12; ARENISCAS= 14; CALIZAS = 16; COLUVIOS = 17; CONGLOMERADO= 18; CUATERNARIO INDIFERENCIADO= 19; DOLOMIÁS= 20; MARGAS= 23; KEUPER= 25; METAMÓRFICO-SILÍCEO= 26

Variable	pF 4,2	
	Estimate	Std.Error
LM_12	-2,54E+03	2,09E+03
LM_14	-1,05E+03	2,89E+03
LM_16	-2,74E+03	1,80E+03
LM_17	-4,28E+03	1,75E+03
LM_18	-3,32E+03	1,97E+03
LM_19	-3,05E+03	1,48E+03
LM_20	2,21E+03	2,61E+03
LM_23	-1,10E+03	1,58E+03
LM_25	-1,13E+03	2,65E+03
LM_26	-7,42E+03	1,81E+03

La Figura 4 muestra la representación espacial para la estimación del contenido de agua en el suelo a valores de pF 2,5 y pF 4,2 con las variables y coeficientes obtenidos en el modelo.

Figura 4

CAPAS RASTER DE LA ESTIMACIÓN DEL POTENCIAL DE SUCCIÓN (pF 2,5 Y pF 4,2) PARA LA RESOLUCIÓN 400 M (PÍXEL) ELABORADA MEDIANTE VARIABLES AMBIENTALES. EXPRESADA EN % DEL CONTENIDO GRAVIMÉTRICO DE AGUA EN EL SUELO, EN TONOS OSCUROS LOS VALORES MÁS ALTOS Y EN TONOS CLARO LOS MÁS BAJOS



IV.2. Influencia y efecto de las variables ambientales en los modelos de pF

Para conocer cuál es el efecto que ejercen las distintas variables en los modelos de estimación de los valores de pF se puede obtener una visión de conjunto observando los coeficientes del modelo (Tablas 2 y 3). Los efectos analizados se basan en las repercusiones que producen las variables sobre los distintos modelos a partir de los coeficientes obtenidos en los procesos de modelización. Un signo positivo (+) en estos valores significa que el efecto de la variable aumenta el agua retenida por el suelo a determinado pF mientras que los signos (-) producen el efecto contrario. No obstante esta simple regla puede no ser válida para aquellas variables que entran en el modelo en forma cuadrática, ya que, por denotar curvatura que puede incluir máximos o mínimos que deben ser representadas gráficamente. Esta representación ayuda a comprender cuál es la respuesta, a cambios en las variables ambientales, del contenido de agua del suelo a una succión determinada.

Antes de analizar el efecto de las variables, merece reseñar las desigualdades encontradas entre los dos modelos. De hecho, resultan importantes las diferencias apreciadas respecto al número de variables que componen los modelos, en particular el modelo a pF 4,2, más complejo y con mayor predictivo que el modelo a pF 2,5. La mayor incertidumbre del modelo que describe la Capacidad de Campo puede deberse a la menor precisión que ofrecen los procesos de medida a menor tensión (Richards, 1947).

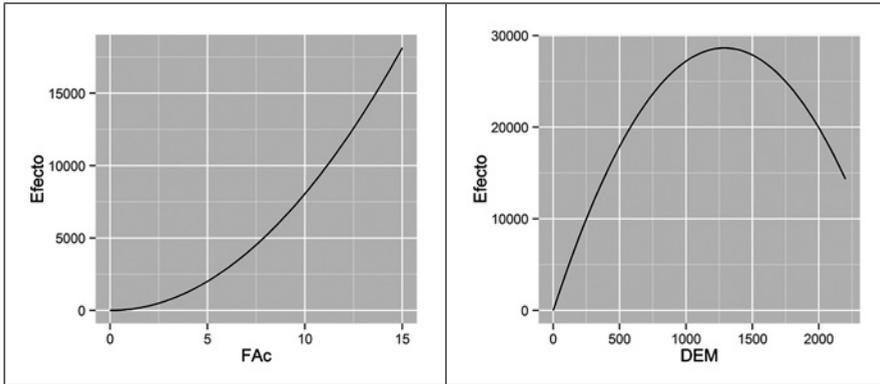
La discusión del efecto de las variables sobre los pF es enormemente interesante por las conclusiones que se pueden extraer de las distintas implicaciones que ejercen los patrones ecológicos en su distribución y variabilidad espacial. En la realización de este análisis se ha agrupado las variables en los bloques descritos en la metodología, adoptando igualmente un tratamiento diferente individualizado para la información del bloque SL, por su condición cualitativa. Las variables del bloque TG que aparecen en el modelo pF 2,5 son [DTM] y [FAc]. En el primer caso observamos cómo el aumento de la altitud aparece relacionado con un crecimiento de los valores de humedad del suelo a Capacidad de Campo. [FAc] se presenta con valores cuadráticos, con un incremento progresivo en los valores estimados de humedad del suelo a pF 2,5 en las áreas con altos valores de acumulación de flujo (Fig. 5). Para el modelo de pF 4,2 se repiten los efectos de manera similar para estas variables, con la diferencia de [DTM] se encuentra en el modelo en forma cuadrática, lo que da lugar a que altitudes superiores a 1300 m la tendencia creciente en la estimación del pF se invierta y disminuya (Fig.6). El modelo a pF 4,2 incluye la curvatura del perfil de máxima pendiente [CuP], haciéndolo de forma no lineal, con un aumento del contenido de humedad en las áreas de curvatura convexa y disminuyendo en las áreas cóncavas. Esta influencia en los modelos de los valores topográficos coinciden con los resultados obtenidos en otros trabajos (Poggio et al., 2010), según los cuales, los parámetros derivados del DTM demostraron su utilidad como información auxiliar en la predicción de los valores de capacidad de agua disponible en múltiples extensiones espaciales.

En el bloque C, solo las variables [Pr] y [Tmp] participan en el modelo pF 4,2. Su efecto es similar y actúan del mismo modo, aumentando el contenido de humedad a mayor temperatura y precipitación. Respecto a la radiación, [RaDi] y [RaDr] muestran un comportamiento similar en los dos modelos de pF : en el caso de la radiación difusa el efecto es decreciente conforme aumentan los valores radiación, mientras que para la radiación directa el efecto

se amplía. La variable [RaDu] solo aparece en el modelo pF 2,5, actuando con un efecto no lineal produciendo un incremento del contenido de humedad a pF 2,5 a medida que aumentan las horas de insolación.

Figuras 5 y 6

REPRESENTACIÓN DE LA ACUMULACIÓN DE FLUJO (FAC) EN EL MODELO DE ESTIMACIÓN DEL pF 2,5 (IZQUIERDA) Y DE LA ALTITUD (DEM) EN EL MODELO DE ESTIMACIÓN DEL pF 4,2 (DERECHA), EXPRESADOS POR EL EFECTO PRODUCIDO EN LA pF Y LOS VALORES PREDICTORES DEL MODELO



Finalmente, el bloque RS solo aparece presente con $[IOI_{feb}]$ para el modelo de pF 2,5 y $[NDVI_{jul}]$ para los dos modelos de pF . Respecto al índice mineralógico, los efectos se traducen en un descenso de los valores de la pF 2,5 conforme aumentan los niveles de alteración mineralógica para los elementos detectados en estos niveles del espectro electromagnético. Para $[NDVI_{jul}]$, los efectos son similares para los dos modelos, observándose un aumento de los niveles estimados de pF a medida que aumentan los valores del índice de vegetación (Figuras 7 y 8). Esta información resulta bastante consistente, generando poco sesgo en el tipo de ecosistema asociado a la actividad vegetal, que es lo que realmente representa dicha variable, mostrando una conexión entre desarrollo vegetativo y capacidad de agua disponible en el suelo (Todoroff et al., 2010).

La interpretación de las variables cualitativas y sus efectos en los pF se muestran en la figura 9. La fase salina de los datos LUCDEME [SPLu], se presenta como una variable cualitativa que contiene una información booleana, en la que la asignación del valor 1 o 0 a la porción delimitada por cada polígono expresa la presencia o ausencia de salinidad. Por su parte, siguiendo los criterios metodológicos expresados anteriormente, los efectos de las categorías de la variable Litología [LM] han sido evaluados con referencia a la clase ‘Aluvial’. Las superficies en Fase Salina [SPLu] presentan un aumento de los valores para los dos modelos de pF , siendo la única variable cualitativa que afecta al pF 2,5. En el modelo pF 4,2 la variable [LM] actúa casi en la totalidad de sus categorías con un efecto negativo en el pF respecto al nivel de referencia ‘Aluvial’, en tanto que las clases ‘Coluvios’ y ‘Metamórfico – Silíceo’ alcanzan unos valores más extremos. Solo la categoría ‘Dolomías’, y de manera muy débil, muestra un efecto positivo.

Figuras 7 y 8
 REPRESENTACIÓN DEL ÍNDICE DE VEGETACIÓN ($NDVI_{Jul}$) EN LOS MODELOS DE ESTIMACIÓN DEL pF 2,5 (IZQUIERDA) Y DEL pF 4,2 (DERECHA), EN RELACIÓN CON EL EFECTO PRODUCIDO EN LA pF Y LOS VALORES PREDICTORES DEL MODELO

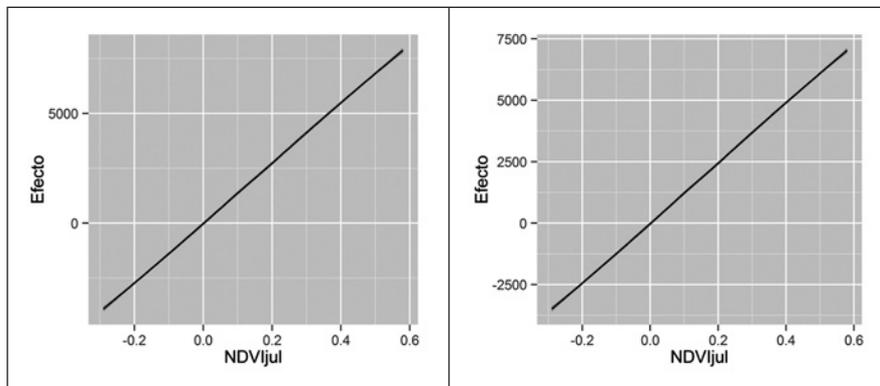
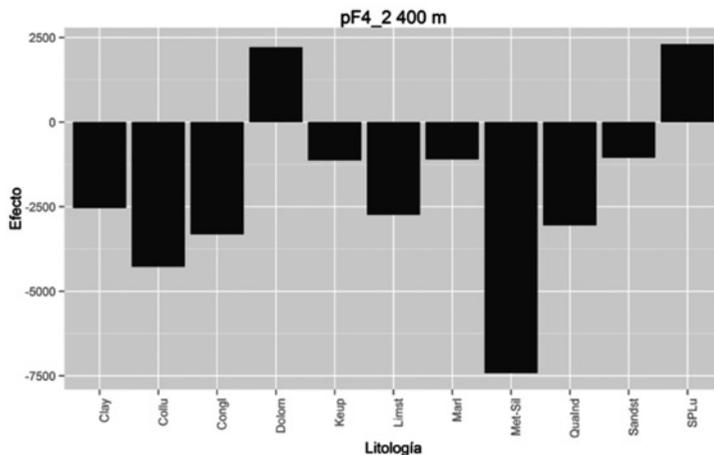


Figura 9
 HISTOGRAMA DE LOS VALORES DE RECLASIFICACIÓN DE LAS PRINCIPALES CLASES DE LA VARIABLE LITOLÓGICA (LM), EXPRESADOS POR EL EFECTO PRODUCIDO EN EL pF Y LOS VALORES PREDICTORES DEL MODELO



V. CONCLUSIONES

Los modelos de contenido de humedad del suelo a distintos pF difieren estructuralmente, sugiriendo que los procesos ambientales que determinan la capacidad de retención de humedad del suelo a distintos pF son, al menos parcialmente, diferentes en uno u otro caso. Estos resultados muestran una menor complejidad del modelo pF 2,5, respecto al modelo de pF 4,2.

Para el modelo de pF 4,2, las variables que están mejor representadas se encuentran en los bloques [TG] y [C]. Los efectos descritos por DTM, CuP y FAc a nivel del Punto de Marchitez están asociados a un incremento de los pF en zonas de elevada altitud (hasta los 1500 m), en superficies cóncavas y en áreas de drenaje de mayor entidad.

También es significativo el efecto del $NDVI_{jul}$, que participa en los dos modelos de pF , mostrando un aumento de los valores de pF en zonas de mayor vegetación, causado por la relación entre materia orgánica y vegetación con la capacidad de retención de humedad del suelo.

Por último, para nuestros resultados, se puede afirmar que la información aportada por teledetección ha permitido mejorar los modelos, por lo que el uso de datos obtenidos por sensores remotos puede ser recomendable en combinación con el resto de variables ambientales.

VI. REFERENCIAS BIBLIOGRÁFICAS

- AGUSTÍ, M. (2003). *Citricultura*. Madrid, Ediciones Mundi-Prensa.
- AKAIKE, H. (1974). «A new look at the statistical model identification». *IEEE Transactions on Automatic Control*, n°19: 716-723.
- ALONSO-SARRÍA, F. (2007). *Atlas Global de la Región de Murcia*. La Verdad- CMM S.A. Murcia. Disponible en: <http://www.atlasdemurcia.com/index.php/secciones/1/el-clima/3/>
- ÁLVAREZ ROGEL, J.; ORTIZ SILLA, R. y ALCARAZ ARIZA, F. (2001). «Edaphic characterization and soil ionic composition influencing plant zonation in a semiarid Mediterranean salt marsh». *Geoderma*, n°99: 81-98.
- BANDARA, R., WALKER, J.P. y RUDIGER, C. (2013). «Towards soil property retrieval from space: A one-dimensional twin-experiment». *Journal of Hydrology* 497: 198-207.
- BEN-DOR, E. (2002). «Quantitative remote sensing of soil properties». *Advances in Agronomy*, n°75, 173-243.
- BEN-DOR, E.; CHABRILLAT, S.; DEMATTÊ, J.A.M.; TAYLOR, G.R.; HILL, J.; WHITING, M.L. y SOMMER, S. (2009). «Using Imaging Spectroscopy to study soil properties». *Remote Sensing of Environment*, n°113: 38-55.
- BOIX-FAYOS, C.; MARTÍNEZ-MENA, M.; CALVO-CASES, A.; CASTILLO, V. y ALBALADEJO, J. (2005). «Concise review of interrill erosion studies in SE Spain (Alicante and Murcia): Erosion rates and progress of knowledge from the 1980's». *Land Degradation and Development*, n°16: 517-528.
- BRUS, D.J. y DE GRUIJTER, J.J. (1997). «Random sampling or geostatistical modelling. Choosing between design-based and model-based sampling strategies for soil». *Geoderma*, n°80, 1-59.
- BURROUGH, P.A.; VAN GAANS, P.F.M. y HOOTSMANS, R. (1997). «Continuous classification in soil survey: Spatial correlation, confusion and boundaries». *Geoderma*, n°77: 115-135.
- BURROUGH, P.A. y MCDONNELL, R.A. (1998). *Principles of geographical information systems*. Oxford University Press, Oxford.
- BUCCI, S.J., SCHOLZ, F.G., GOLDSTEIN, G., MEINZER, F.C. y ARCE, M.E. (2009). «Soil water availability and rooting depth as determinants of hydraulic architecture of Patagonian woody species». *Oecologia* 160 (4): 631-641.

- BOU KHEIR, R.; GREVE, M.H.; BØCHER, P.K.; GREVE, M.B.; LARSEN, R. y MCCLOY, K. (2010). «Predictive mapping of soil organic carbon in wet cultivated lands using classification-tree based models: The case study of Denmark». *Journal of Environmental Management*, nº 91, 1150-1160.
- CAPEL-MOLINA, J.J. (2000). *El clima de la Península Ibérica*. Ariel Geografía, Barcelona.
- CHEN, F.; KISSEL, D.E.; WEST, L.T. y ADKINS, W. (2000). «Field-scale mapping of surface soil organic carbon using remotely sensed imagery». *Soil Science Society of America Journal*, 64: 746-753.
- CONESA GARCÍA, C., y ALONSO SARRIA, F. (2006). *El Clima de la Región de Murcia*. En Conesa García, C. (Ed.), *El Medio Físico de la Región de Murcia*. Servicio de Publicaciones, Universidad de Murcia. Murcia, 3: 95-127.
- CONFEDERACIÓN HIDROGRÁFICA DEL SEGURA (CHS), Ministerio de Agricultura, Alimentación y Medio Ambiente. 2013. Disponible en: <http://www.chsegura.es/chs/cuenca/-resumendedatosbasicos/marcoadministrativo/>
- CROSTA, A.P.; DE SOUZA FILHO, C.R.; AZEVEDO, F. y BRODIE, C. (2003). «Targeting key alteration minerals in epithermal deposits in Patagonia, Argentina, using ASTER imagery and principal component analysis». *International Journal of Remote Sensing*, nº24 : 4233-4240.
- DOBOS, E. y HENGL, T. (2009). *Soil mapping applications*. In: T. Hengl and H.I. Reuter, editors, *Geomorphometry, concepts, software and applications*. Elsevier, New York, 461-479.
- DUNKERLEY, D.L. (2002). «Infiltration rates and soil moisture in a groved mulga community near Alice Springs, arid central Australia: Evidence for complex internal rainwater redistribution in a runoff-runon landscape». *Journal of Arid Environments* 51 (2):199-219.
- DURY, S.A. (1987). *Image Interpretation in Geology*. Chapman & Hall. London.
- ESRI 2013. ArcGIS Desktop: Release 10. Redlands, CA: Environmental Systems Research Institute.
- FAO (1974). *Soil Map of the World*. Vol I.
- FOX, G.A. y SABBAGH, G.J. (2002). «Estimation of soil organic matter from red and near-infrared remotely sensed data using soil line Euclidean techniques». *Soil Science Society of America Journal*, 66: 1922-1929.
- FU, P. y P. M. RICH. (2000). *The Solar Analyst 1.0 Manual*. Helios Environmental
- GARCIA-ESTRINGANA, P., ALONSO-BLAZQUEZ, N. y ALEGRE, J. (2010). «Water storage capacity, stemflow and water funneling in Mediterranean shrubs». *Journal of Hydrology* 389(3-4) : 363-372.
- GESSLER, P.E.; MOORE, I.D.; MCKENZIE, N.J. y RYAN, P.J. (1995). «Soil-landscape modelling and spatial prediction of soil attributes». *Int. J. Geographical Information Systems*, nº 4, 421-432.
- GREVE, M.H.; KHEIR, R.B.; GREVE, M.B. y BØCHER, P.K. (2012). «Quantifying the ability of environmental parameters to predict soil texture fractions using regression-tree model with GIS and LIDAR data: The case study of Denmark». *Ecol. Indic.* nº 18, 1-10.
- HERWITZ, S.R. (1986). «Infiltration-excess caused by stemflow in a cyclone prone tropical rainforest». *Earth Surface Processes & Landforms*, 11 (4): 401-412.
- ICONA. Proyecto LUCDEME (Lucha contra la Desertificación del Mediterráneo) (1986). *Mapa de suelos, escala 1:100.000*. ICONA - Ministerio de Agricultura, Pesca y Alimentación.

- INSTITUTO NACIONAL DE ESTADÍSTICA (INE). Ministerio de Economía y Competitividad. 2013. Disponible en: http://www.ine.es/inebmenu/mnu_entornofis.htm#1.
- KIDNER, D.; DOREY, M. y SMITH D.(1999). «What's the point? Interpolation and extrapolation with a regular grid DTM». *Proceedings of the 4th International Conference on GeoComputation*.
- KLUTE, A. (1986). *Water retention: Laboratory methods*, in A.Klute, ed. *Methods of Soil Analysis. Part 1: Physical and Mineralogical Methods*. Agronomy Monograph 9, ASA, Madison, WI, pp. 635-662.
- LAGACHERIE, P.; BAILLY, J.S.; MONESTIEZ, P. y GOMEZ, C. (2012). «Using scattered hyperspectral imagery data to map the soil properties of a region». *European Journal of Soil Science*, nº 63: 110-119.
- LBI, (2013). Laboratorio de Biogeografía Informática. Museo Nacional de Ciencias Naturales. CSIC. Disponible en: http://www.mncn.csic.es/Menu/Investigacin/Serviciodeapoyoalinvestigacin/LabBiogeografiaInformtica/seccion=1258&idioma=es_ES.do
- LIEß, M.; GLASER, B. y HUWE, B. (2012). «Uncertainty in the spatial prediction of soil texture Comparison of regression tree and Random Forest models». *Geoderma*, nº 170, 70- 79.
- LOUSSERT, R. (1992). *Los Agrios*. Madrid, Ediciones Mundi-Prensa.
- MALIK, R.S., BUTTER, B.S., ANALAUF, R. y RICHTER, J., (1987). «Water penetration into soils with different textures and initial soil contents». *Soil Science*, 144(6): 389-393.
- MANFREDA, S., SCANLON, T.M., CAYLOR, K.K. (2010). On the importance of accurate depiction of infiltration processes on modelled soil moisture and vegetation water stress. *Ecology* 3 (2): 155-165.
- MCBRATNEY, A.B.; WEBSTER, R. y BURGESS, T.M. (1981). «The design of optimal sampling schemes for local estimation and mapping of regionalized variables-I. Theory and method». *Computers and Geosciences*, nº 7: 331-334.
- MCBRATNEY, A.B.; MENDONÇA SANTOS, M.L. y MINASNY, B. (2003). On digital soil mapping. *Geoderma*, nº 117: 3-52.
- MCKENZIE, N.J. y RYAN, P.J. (1999). Spatial prediction of soil properties using environmental correlation. *Geoderma*, nº 89: 67-94.
- MINASNY, B., y MCBRATNEY, A.B. (2008). «Regression rules as a tool for predicting soil properties from infrared reflectance spectroscopy». *Chemom. Intell. Lab. Syst.*, nº 94: 72-74.
- MINISTERIO DE MEDIO AMBIENTE (MMA) (2002-2012). Inventario Nacional de Erosión de Suelos. Disponible en: <http://www.magrama.gob.es/es/biodiversidad/temas/inventariosnacionales/inventarionacional-de-erosion-de-suelos/>.
- MOORE, I.D.; GRAYSON, R.B. y LANDSON, A.R. (1991). «Digital Terrain Modelling: A Review of Hydrological, Geomorphological, and Biological Applications». *Hydrological Processes*, nº 5, 3-30.
- NASA – METI. (2013). ASTER GDEM. The Ministry of Economy, Trade and Industry of Japan (METI) and the National Aeronautics and Space Administration (NASA). Disponible en: <http://gdem.ersdac.jspacesystems.or.jp/>.
- PEREZ-CUTILLAS, P. Modelización de propiedades físicas del suelo a escala regional. Casos de estudio en el Sureste Ibérico. Tesis Doctoral. Universidad de Murcia. 2013. Disponible en: <http://hdl.handle.net/10201/37810>

- POGGIO, L., GIMONA, A., BROWN, I. y CASTELLAZZI, M. (2010). «Soil available water capacity interpolation and spatial uncertainty modelling at multiple geographical extents». *Geoderma* 160 (2): 175-188.
- POGGIO, L.; GIMONA, A. y BREWER, M.J. (2013). «Regional scale mapping of soil properties and their uncertainty with a large number of satellite-derived covariates». *Geoderma*, n° 209-210: 1-14.
- RAWLS, W.; COSH, M.; JACKSON, T. y NEMES, A. (2004). «Use of remotely sensed soil moisture to determine soil hydraulic properties». *International Geoscience and Remote Sensing Symposium (IGARSS)*, n° 4, 2791-2794.
- RICHARDS, L.A. (1947). Pressure membrane apparatus: construction and use. *Agric. Eng.*, 28: 451-454.
- SABINS JR, F.F. (1981). *Geological applications and training in remote sensing*. CORSE 81: the 1981 conference on remote sensing education, Lafayette, IN: 77-82.
- 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/>.
- RICH, P. M.; DUBAYAH, R.; HETRICK, W.A. y SAVING, S.C. (1994). «Using Viewshed Models to Calculate Intercepted Solar Radiation: Applications in Ecology». *American Society for Photogrammetry and Remote Sensing Technical Papers*, 524-529.
- SCHUH, W.M. y CLINE, R.L. (1990). «Effect of soil properties on unsaturated hydraulic conductivity pore interaction factors». *Soil Science Society of America Journal*. 54(6): 1509-1519.
- SCHULTEN, H.R. y SCHNITZER, M. (1997). «Chemical model structures for soil organic matter and soils». *Soil Science*, n° 162, 115-130.
- SCULL, P.; FRANKLIN, J.; CHADWICK, O.A. y MCARTHUR, D. (2002). «Predictive soil mapping: A review». *Progress in Physical Geography*, n° 27, 171-197.
- TARBOTON, D. G.; BRAS, R. L. y RODRIGUEZ-ITURBE, I. (1991). «On the Extraction of Channel Networks from Digital Elevation Data». *Hydrological Processes*, n° 5, 81-100.
- THOMPSON, J.A.; BELL, J.C. y BUTLER, C.A. (2001). «Digital elevation model resolution: Effects on terrain attribute calculation and quantitative soil-landscape modeling». *Geoderma*, n° 100: 67-89.
- TODOROFF, P., DE ROBILLARD, F. y LAURENT, J.-B. (2010). «Document Interconnection of a crop growth model with remote sensing data to estimate the total available water capacity of soils». *International Geoscience and Remote Sensing Symposium (IGARSS)*. Article 5653790, Pages 1641-1644
- TOWNSHEND, J.R.G.; GOFF, T.E. y TUCKER, C.J. (1985). «Multitemporal dimensionality of images of Normalized Difference Vegetation Index at continental scales». *IEEE Transactions on Geoscience and Remote sensing*, n° 23: 888-895.
- TWARAKAVI, N.K.C., ŠIMUNEK, J. y SCHAAP, M.G. (2010). «Can texture-based classification optimally classify soils with respect to soil hydraulics?». *Water Resources Research* 46 (1), art. no. W01501
- UNO, Y., PRASHER, S.O., PATEL, R.M., STRACHAN, I.B. y PATTEY, E. (2005). «Development of field-scale soil organic matter content estimation models in Eastern Canada using airborne hyperspectral imagery». *Canadian Biosystems Engineering/Le génie des biosystèmes au Canada*, 47: 9-14.

- VAN GENUCHTEN, M.TH. (1980). «Closed-form equation for predicting the hydraulic conductivity of unsaturated soil». *Soil Sci. Soc. Am*, 44: 1147-1152.
- VISCARRA-ROSSEL, R.A.; WALVOORT, D.J.J.; MCBRATNEY, A.B.; JANIK, L.J. y SKJEMSTAD, J.O. (2006). «Visible, near infrared, mid infrared or combined diffuse reflectance spectroscopy for simultaneous assessment of various soil properties». *Geoderma*, nº131: 59-75.
- VRIELING, A. (2006). «Satellite remote sensing for water erosion assessment: A review». *Catena*, nº 65, 2-18.
- WANG, K., ZHANG, C., LI, W. (2013). «Predictive mapping of soil total nitrogen at a regional scale: A comparison between geographically weighted regression and cokriging». *Applied Geography*, 42: 73-85.
- WESTERN, A.W.; ZHOU, S.L.; GRAYSON, R.B.; MCMAHON, T.A.; BLÖSCHL, G. y WILSON, D.J. (2004). «Spatial correlation of soil moisture in small catchments and its relationship to dominant spatial hydrological processes». *Journal of Hydrology*, nº 286, 113-134.
- WHEELER, S.J., SHARMA, R.S., BUISSON, M.S.R. (2003). «Coupling of hydraulic hysteresis and stress-strain behaviour in unsaturated soils». *Geotechnique*, 53(1): 41-54.
- WOSTEN, J.H.M. y VAN GENUCHTEN, M.T. (1988). «Using texture and other soil properties to predict the unsaturated soil hydraulic functions». *Soil Science Society of America Journal*, 52 (6): 1762-1770.
- ZEVEBERGEN, L.W. y THORNE, C.R. (1987). «Quantitative Analysis of Land Surface Topography». *Earth Surface Processes and Landforms*, nº 12: 47-56.

