

DESARROLLO DE FUNCIONES DE EDAFO-TRANSFERENCIA PARA LA CARACTERIZACION HIDRAULICA DE ANDOSOLES

Pablo Borja¹, Bert De Bièvre¹, Pedro Cisneros¹

RESUMEN

El presente trabajo se llevó a cabo con el propósito de desarrollar ecuaciones que permitan estimar la CRHS y la K_s a partir de propiedades del suelo fáciles de obtener para Andosoles. Se obtuvieron Funciones de Edafo-Transferencia para estimar 6 puntos de la curva de retención de humedad del suelo, para estimar la K_s y para estimar los 4 parámetros del modelo de van Genuchten para los Andosoles del Ecuador. La base de datos que se utilizó consta de 87 muestras para el desarrollo de las FET y 13 para su validación. Para el desarrollo de las FET se emplearon modelos de regresión lineal múltiple (MRLM) y modelos de redes neuronales artificiales (MRNA). Se determinó que para la estimación de puntos individuales de la CRHS ambos métodos son igual de efectivos. En general con las FET desarrolladas en base a MRLM para puntos de la CRHS, se obtuvieron buenos resultados (valores de R^2 superiores a 0.6) y estimaron mejor la CRHS que las FET de Rawls et al. (1982), cuando se compararon utilizando las muestras para la validación. En la estimación de K_s las FET basadas en MRLM presentaron valores de R^2 entre 0.5 y 0.7. Adicionalmente se compararon con las FET de los programas Rosetta (Schaap et al., 2001) y RETC (van Genuchten et al., 1991). Esta comparación reveló un mejor desempeño por parte de las FET desarrolladas en este estudio.

1 INTRODUCCION

Los Andosoles son los suelos más comunes en el páramo, tienen una extraordinaria capacidad para retener agua y una baja densidad aparente (DA). Corresponden a la clasificación de la FAO WRB (ISSS Working group RB, 1998) y son equivalentes a los Andisoles de la Soil Taxonomy (Soil Survey Staff, 2006).

Los suelos del páramo, especialmente los Andosoles, se caracterizan por cumplir una función importantísima dentro del complejo proceso de regulación y almacenamiento del agua en este ecosistema. Los ríos que aquí se originan proveen de agua para diversos usos para la región andina de Ecuador, Colombia y Venezuela. Esta y otras funciones se deben en gran parte a las extraordinarias propiedades de su suelo.

En la actualidad existen algunas propuestas en el país que se enmarcan dentro del estudio de los ecosistemas de páramo cuyos objetivos principales son caracterizar el estado actual de la salud del páramo, diseñar estrategias de conservación de la biodiversidad de este ecosistema, encontrar mejores prácticas para el manejo del agua, realizar un aprovechamiento racional y sostenible de sus servicios ambientales, etc. Sin embargo, para que lo anterior se cumpla, es necesario conocer cada uno de sus elementos así como las relaciones que se dan entre ellos, siendo uno de los más trascendentes el elemento suelo.

¹ Programa para el Manejo del Agua y el Suelo (PROMAS) - Universidad de Cuenca, Av. 12 de Abril s/n. Cuenca-Ecuador.

Una importante herramienta que contribuye al conocimiento de las relaciones existentes entre las partes del sistema ecológico del páramo es el uso de *modelos* que simplifican los complejos procesos físicos, biológicos y químicos. Estos modelos requieren como información de entrada las propiedades hidráulicas del suelo, cuya obtención en la mayoría de los casos se ve limitada por los costos y el tiempo que estas implican o por lo complejo de los experimentos de campo y laboratorio requeridos. Buenas estimaciones en lugar de mediciones directas de las propiedades hidráulicas del suelo pueden ser suficientemente exactas para muchas aplicaciones.

Actualmente existen algunas técnicas para determinar las propiedades hidráulicas del suelo a partir de otras propiedades fácilmente disponibles. Estas técnicas son conocidas como Funciones de Edafo-Transferencia (FET).

Las propiedades hidráulicas del suelo son propiedades físicas que describen las relaciones entre el agua y el suelo. Las propiedades más importantes son la curva de retención de humedad del suelo (CRHS) y la conductividad hidráulica (K). La CRHS se conoce también como curva de pF y es característica para cada tipo de suelo.

Un primer paso, para desarrollar FET, es conocer mejor las relaciones entre las principales propiedades hidráulicas (K y curva de pF) con otras propiedades del suelo fáciles de obtener tales como: la textura, la densidad aparente y el contenido de materia orgánica. Las Funciones de Edafo-Transferencia son funciones matemáticas que predicen las propiedades hidráulicas a partir de información básica del suelo permitiendo un ahorro considerable de recursos

Por lo tanto el uso de Funciones de Edafo-Transferencia, basadas en parámetros más fácilmente obtenibles, tiene una gran utilidad para diversas aplicaciones y cualquier esfuerzo tendiente a su obtención se ve ampliamente justificado. Además, debido a que los Andosoles poseen características muy particulares, no se está en capacidad de afirmar que las FET generales actualmente disponibles proporcionen valores correctos de retención de humedad y K_s . Otra importante razón es que las áreas de páramo para las que no se dispone de información son grandes y obtener esta información de forma directa sería demasiado costoso.

1.1 OBJETIVOS GENERALES

Contribuir al conocimiento de las propiedades hidráulicas de los Andosoles y desarrollar Funciones de Edafo-Transferencia para estimar la curva de pF y la conductividad hidráulica saturada.

2 MATERIALES Y METODOS

2.1 Descripción de la zona de estudio

El páramo del Austro Ecuatoriano, como se denomina a la región sur de los Andes Ecuatorianos entre 2° 15' y 3° 30' de latitud sur y sobre los 3200 m s.n.m. (Dercon et al., 1998), es un ecosistema de humedales alpino neo-tropical situado entre el límite superior de los bosques y el límite inferior de las nieves perpetuas. La precipitación promedio está entre

1200 y 1600 mm año⁻¹ (Buytaert et al., 2005) y generalmente la lluvia es de baja intensidad (lloviznas). El promedio anual de temperatura está alrededor de 7 °C cuya variación día-noche es alta, el promedio máximo es 13.2 °C y el promedio mínimo 4.6 °C (Buytaert, 2004). Los páramos del norte del país se caracterizan por una vegetación similar a la de los páramos del Austro, sin embargo aquí pueden encontrarse los “páramos de frailejones” o los páramos secos como los de las faldas del volcán Chimborazo. Otra característica de los páramos del norte es el avanzado estado de degradación al que se han visto sometidos debido a la intensa actividad del hombre impulsada principalmente por la pobreza y el crecimiento demográfico. La altitud va desde los 3200 a los 4200 m s.n.m., y según datos citados por Alomía (2005) la temperatura está entre los 6 y 12 °C, con una precipitación promedio de 760 mm año⁻¹.

2.2 Grupo de datos

En cuanto a los datos usados para desarrollar las FET, la gran mayoría de la información provino de muestras tomadas en los páramos del Austro. Adicionalmente se contó con 22 muestras provenientes del páramo de Guangaje, al norte del país. En la Figura 1 se puede ver su localización, además se incluye la ubicación de las zonas de páramo y de los principales volcanes cuya ceniza probablemente tuvo influencia en la formación de los suelos.

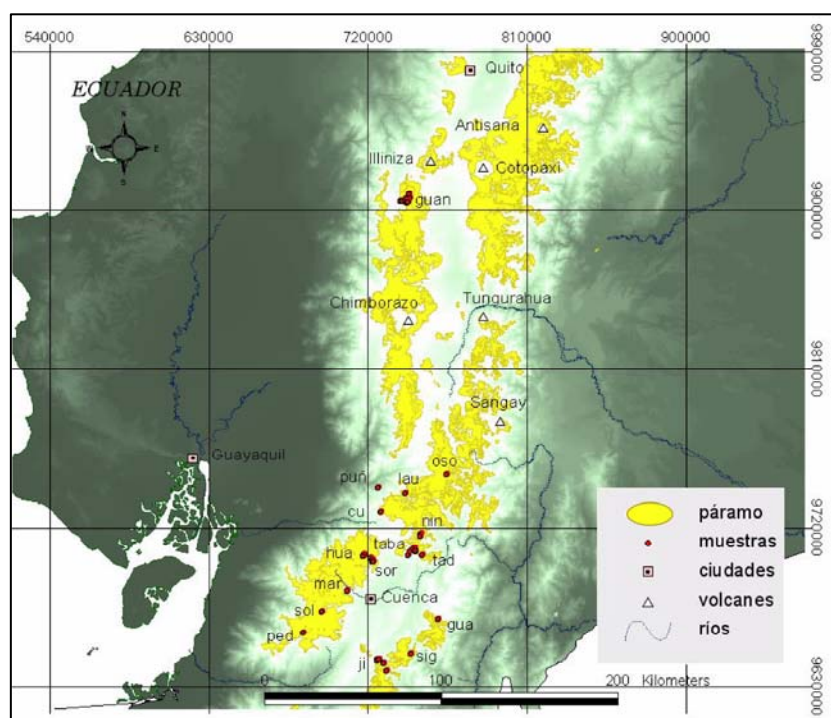


Figura 1. Ubicación de las zonas de muestreo en el páramo ecuatoriano.

2.3 Análisis previo de la información disponible

Todas las muestras corresponden a horizontes orgánicos muy oscuros *A* o cuyas características dominantes son las de un *A* y con propiedades *ándicas* claras en el caso de las muestras del Austro. Las muestras provenientes del norte del país corresponden en su mayoría a horizontes superficiales de los primeros 30 cm del perfil y con propiedades *vítricas*.

Los suelos son clasificados como Andosoles de acuerdo con la FAO WRB (ISSS Working Group RB, 1998).

En todos los casos la caracterización hidrofísica se la hizo a partir de muestras inalteradas de 100 cm³. En la Tabla 1 se describe la información principal que contiene cada uno de los 8 grupos de datos.

Tabla 1. Descripción de la información disponible.

Grupo de datos	Lugar de muestreo	Perfiles	Horizontes	pF
Borja	Puñay, Launa y Osogoche	3	3	0, 1.5, 1.8, 2, 2.4, 2.7, 3.5, 4.2
Borja y Garrido (2003)	Austro	14	38	0, 2, 2.3, 2.5, 2.6, 2.7, 3.5, 4.2
Buytaert (2000)	Jima	4	8	0, 1.5, 2, 2.4, 2.7, 4.2
Crespo (2006)	Lise, Joyagshi y Tablón	3	4	0, 1.5, 1.8, 2, 2.4, 2.7, 3.5, 4.2
Iñiguez (2003)	Huagrauma y Ningar	7	15	0, 2, 2.3, 2.5, 2.6, 2.7, 3.5, 4.2
Mejía (2004)	Guangaje	20	22	0, 1.5, 1.8, 2, 2.4, 2.7, 3.5, 4.2
Mogrovejo y Palacios (2005)	Marianza	2	3	0, 1.8, 2, 2.4, 2.7, 3.5, 4.2
Verdugo (2004)	Tabacay	7	7	0, 1.5, 1.8, 2, 2.3, 2.7, 3.5, 4.2
Total		60	100*	

* De este total se seleccionaron al azar 13 muestras para la validación

Los valores de θ correspondientes a pF en el rango de 0 – 2.7, fueron medidos utilizando el método *multistep-outflow* (van Dam et al., 1992) (aparato de presión por etapas múltiples) con muestras inalteradas de 100 cm³. Los contenidos de humedad (θ) para los valores de pF: 3.48 y 4.18 se midieron en un aparato de membranas para presiones altas utilizando muestras alteradas.

En cuanto a la K_s todos los datos provienen de mediciones de flujo con el permeámetro de carga constante y con muestras de 100 cm³.

Para la determinación de la conductividad hidráulica saturada (K_s) del suelo se empleó el permeámetro de carga constante.

El valor de la materia orgánica (MO) corresponde al obtenido con el método Walkley Black (Jackson, 1982). En cuanto a la textura, los términos: arena, limo y arcilla solamente hacen referencia al diámetro de las partículas según la clasificación de la USDA más no a su composición mineralógica. La densidad aparente fue calculada utilizando muestras inalteradas, secadas en el horno durante 24 hrs. a 105 °C.

Los datos medidos de θ fueron ajustados con el modelo de van Genuchten (MVG) (van Genuchten, 1980) en base a datos de flujo de salida a partir del experimento en el MULTISTEP y el aparato de membranas para presiones altas.

El ajuste de los parámetros para las 100 muestras se la hizo con el programa SHYPFIT 0.22 (Durner, 1995) a partir de los contenidos de humedad del suelo y sus respectivas presiones.

2.4 Desarrollo de Funciones de Edafo-Transferencia para estimar θ y K_s

Se consideraron dos tipos de FET: el primero consistió en desarrollar FET que estimen 6 puntos de la CRHS (θ correspondiente a pF: 0, 1.98, 2.35, 2.7, 3.48, y 4.18). El segundo consistió en desarrollar FET para estimar los 4 parámetros de la ecuación de van Genuchten: θ_r , θ_s , α y n , que permitan luego mediante dicha ecuación generar una curva con valores de θ para diferentes valores de pF. Se trabajó con una base de datos compuesta por 87 muestras. Para esto se emplearon dos métodos:

- a) Modelos de regresión lineal múltiple (MRLM).
- b) Modelos de redes neuronales artificiales (MRNA).

2.4.1 Modelos de regresión lineal múltiple (MRLM)

Constituye el método más usado en el desarrollo de FET. Son modelos que se usan para relacionar una variable dependiente Y (respuesta) con variables independientes X_1, X_2, \dots, X_k (predictoras), para plantear relaciones más complejas que la línea recta (Mendenhall y Sincich, 1995). Un ejemplo de MRLM para predecir Y sería:

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k + \varepsilon$$

Donde: Y = variable respuesta, X_1, X_2, \dots, X_k = variables predictoras, β_0 = intercepto, $\beta_1, \beta_2, \dots, \beta_k$ son los coeficientes de regresión y ε = error aleatorio.

Mediante modelos de regresión lineal múltiple se desarrollaron FET para cada uno de los 6 puntos de la CRHS y para los 4 parámetros del MVG. Para seleccionar las mejores variables predictoras a ser incluidas en el modelo y para revisar la estructura de los datos se consideraron tres técnicas estadísticas. Estas técnicas fueron comparadas con el fin emplear la que proporcione mejores resultados a efectos de este estudio (concretamente las dos primeras). La comparación se la hizo para el MRLM1, las variables de los demás modelos se establecieron de acuerdo con la técnica escogida. Estas técnicas son las siguientes:

- i) La técnica conocida como *regresión paso a paso* (stepwise regression) consiste en eliminar de forma sistemática las variables que tengan valores de Pr altos (probabilidad grande de aceptar la H_0) y se controla como afectan los cambios al modelo.
- ii) La segunda técnica se conoce como: Akaike information Criterion (AIC). Esta técnica consiste en escoger el “mejor modelo” de acuerdo al valor de AIC.
- iii) Otra técnica es el análisis de componentes principales (ACP), cuyo objetivo es reducir la dimensión de un conjunto de p variables a un conjunto m de menor número de variables para mejorar la interpretabilidad de los datos.

2.4.2 Modelos de redes neuronales artificiales (MRNA)

Los MRNA se refieren a sistemas computacionales que representan modelos matemáticos altamente simplificados de redes neuronales biológicas. Consta de muchos procesadores simples que trabajan en paralelo llamados neuronas organizados en capas y que están conectados por canales de comunicación. A través de estos canales fluye la información, desde las neuronas de entrada hasta las de salida, y es manipulada por los pesos. Mediante los

cambios en los pesos de las conexiones, la salida que produce la red se va acercando a la salida deseada. Estos cambios son controlados por reglas de entrenamiento que básicamente buscan minimizar el error de estimación.

Para el desarrollo de las FET se usó un modelo de redes neuronales artificiales de 3 capas de alimentación hacia adelante en donde la señal fluye desde las neuronas de entrada, avanza a través de las neuronas ocultas y eventualmente alcanza las neuronas de salida (Jain et al., 2004). La Figura 2 muestra la estructura del modelo conformado por: 1 capa de entrada, 1 capa oculta y 1 capa de salida. Se optó por un modelo con 4 neuronas en la capa oculta y este número fue determinado mediante varias corridas de prueba. El número de neuronas de la capa de entrada es igual al número de variables predictoras, mientras que la capa de salida en este caso siempre se mantuvo con una neurona (la variable respuesta) aunque es perfectamente posible incluir más. Un modelo de este tipo se utilizó para desarrollar las FET para cada uno de los 6 puntos de la CRHS y para cada uno de los 4 parámetros del MVG. Las variables predictoras incluidas en el modelo fueron las mismas que se usaron en el modelo de regresión lineal múltiple luego del proceso de selección.

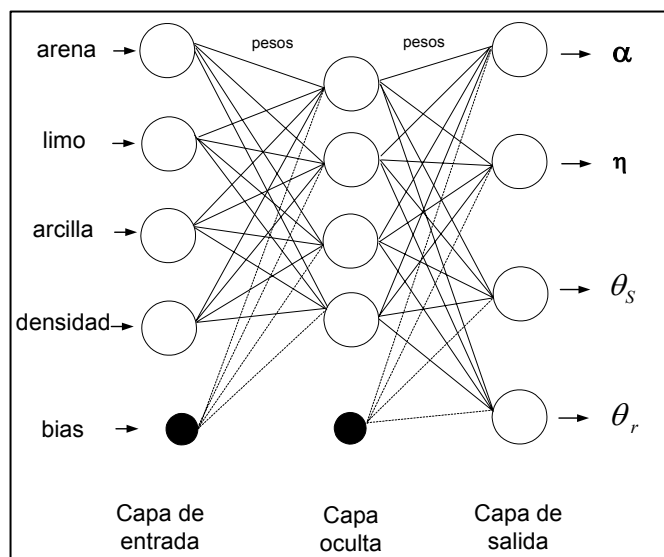


Figura 2. Ejemplo de un modelo de red neuronal artificial de 3 capas para estimar los parámetros del MVG

Para la estimación de K_s se utilizaron ambos modelos para desarrollar FET: el modelo de regresión lineal múltiple y el modelo de redes neuronales artificiales. La base de datos que se usó para este propósito estuvo formada por 72 muestras.

2.5 Evaluación y Validación de las FET

Para la evaluación de la exactitud de las FET en el caso de los MRLM se utilizaron los estadísticos R^2 y R^2_{aj} (coeficiente de determinación y coeficiente de determinación ajustado). Esta es una medida de la bondad de ajuste del modelo. Para evaluar la confiabilidad de las FET, obtenidas mediante MRLM y MRNA, se utilizó un grupo de datos independientes. Este grupo no fue usado para el desarrollo de las FET y estuvo compuesto por 13 muestras seleccionadas al azar.

El estadístico utilizado para esta evaluación fue el RMSE (raíz del error medio cuadrático) que calcula el error medio de predicción y cuyas unidades son las mismas que las de los datos analizados:

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{N}} \quad [4]$$

Donde: y_i = valor observado, \hat{y}_i = valor estimado y N = número de datos.

Adicionalmente las FET desarrolladas en esta investigación se compararon con otras FET ya existentes. El propósito fue establecer que tan bien predicen determinados puntos de la CRHS, para Andosoles, algunas de las FET más empleadas. Las más populares y de mayor uso son las de Rawls et al. (1982) y las disponibles en los programas Rosetta (Schaap et al., 2001) y RETC (van Genuchten et al., 1991). La comparación se hizo de forma cualitativa, representando las CRHS medidas y estimadas por medio de gráficos.

3 RESULTADOS Y DISCUSIÓN

3.1 Análisis previo de la información disponible

Se obtuvieron 100 curvas de retención de humedad del suelo cada una de ellas descrita por 6 puntos individuales (Figura 4). Estas curvas evidencian la elevada capacidad de retención de agua que presentan los Andosoles, especialmente los del Austro. La Figura 3 presenta el triángulo de texturas de la USDA con los grupos de muestras usados en este estudio, puede verse que la información cubre un amplio rango de clases texturales, que van desde la arcillosa hasta la arenosa – franca. Esto es muy importante para el desarrollo de las FET ya que se ha comprobado que estas son válidas solo dentro del rango de texturas que cubre la información utilizada (Tomasella et al., 2000).

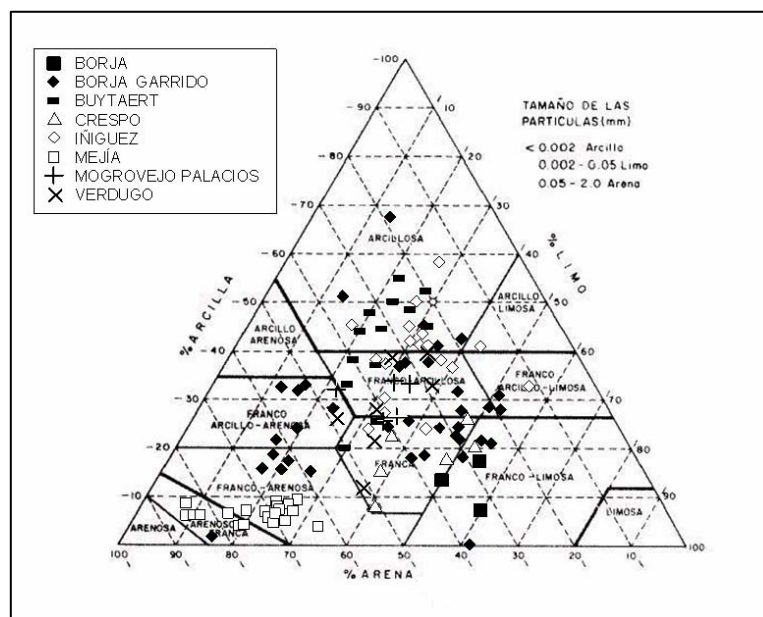


Figura 3. Triángulo de texturas de la USDA con los 8 grupos de muestras (Soil survey staff, 1975)

Las variables comunes a todos los grupos de datos que se seleccionaron para el desarrollo y validación de las FET fueron: arena, limo, arcilla, MO , densidad, K_s y los contenidos de humedad del suelo para los siguientes valores de pF: 0, 1.98, 2.35, 2.7, 3.48, y 4.18 (Figura 4). Una lista con estas variables puede verse en la Tabla 2.

Se usaron como variables predictoras: los contenidos de arena, limo y arcilla, la MO y la DA , y adicionalmente para ciertas FET: $\theta_{(pF-0)}$, $\theta_{(pF-3.48)}$ y $\theta_{(pF-4.18)}$. Las variables respuesta fueron: $\theta_{(pF-0)}$, $\theta_{(pF-1.98)}$, $\theta_{(pF-2.35)}$, $\theta_{(pF-2.7)}$, $\theta_{(pF-3.48)}$ y $\theta_{(pF-4.18)}$, K_s , θ_s , θ_r , α y n .




Figura 4. Curvas de retención de humedad para 6 puntos individuales, con los valores promedio para los Andosoles del norte y del Austro, N = 100

La Tabla 2 presenta para cada propiedad del suelo los valores mínimo, máximo, mediana, promedio y desviación estándar para el total de muestras disponibles; sin embargo hay que tener en cuenta que existen diferencias claras entre los Andosoles del Austro y los del norte del país (Figura 4).

Con el propósito de validar las FET desarrolladas en este estudio se utilizó un grupo de datos independiente conformado por 13 muestras. A partir de este grupo de datos se prosiguió con la respectiva validación de los modelos cuyas variables se seleccionaron de acuerdo a los criterios expuestos en la sección correspondiente.

3.2 Relaciones entre las principales propiedades del suelo

La Tabla 3 presenta el grado de relación lineal entre las principales propiedades del suelo expresado por el coeficiente de correlación.

Se encontró que una de las variables más importantes para explicar la capacidad de retención de agua de estos suelos es la DA . La DA es más importante en los rangos bajos de succión del suelo y esta disminuye conforme aumenta la succión ($>pF$) El contenido de MO tiene mayor importancia en los rangos altos de succión del suelo.

Tabla 2. Medidas de tendencia central y dispersión para el grupo total de muestras, N = 100.

Propiedades	Min.	Máx.	Mediana	Promedio	Desviación estándar
Arena (%)	12.00	86.00	37.50	44.29	19.77
Limo (%)	7.00	61.70	28.50	30.70	12.89
Arcilla (%)	0.00	68.60	25.00	24.97	14.68
MO (%)	0.10	27.80	12.15	11.61	5.51
Ph (H ₂ O)	3.00	6.30	4.90	4.99	0.54
Densidad aparente (g cm ⁻³)	0.11	1.29	0.52	0.61	0.32
K _s (cm h ⁻¹)	0.00	11.59	0.88	1.70	2.36
θ _(pF-0) (cm ³ cm ⁻³)	0.34	0.98	0.75	0.74	0.14
θ _(pF-1.98) (cm ³ cm ⁻³)	0.21	0.93	0.69	0.66	0.15
θ _(pF-2.35) (cm ³ cm ⁻³)	0.20	0.87	0.67	0.64	0.16
θ _(pF-2.7) (cm ³ cm ⁻³)	0.20	0.83	0.64	0.62	0.15
θ _(pF-3.48) (cm ³ cm ⁻³)	0.05	0.65	0.38	0.36	0.14
θ _(pF-4.18) (cm ³ cm ⁻³)	0.03	0.61	0.33	0.31	0.14

Tabla 3. Matriz de correlación (R) de las propiedades más importantes de los Andosoles, N = 87.

	aren a	lim o	arcill a	MO	pH (H ₂ O)	DA	K _s (g cm ⁻³)	θ _(pF-0) (cm ³ cm ⁻³)	θ _(pF-1.98) (cm ³ cm ⁻³)	θ _(pF-2.35) (cm ³ cm ⁻³)	θ _(pF-2.7) (cm ³ cm ⁻³)	θ _(pF-3.48) (cm ³ cm ⁻³)	
limo	-	0.67											
arcilla		0.77	0.04										
MO		0.61	0.48	0.40									
pH		0.58	0.14	-0.66	0.46								
DA		0.60	0.36	-0.49	0.58	0.58							
K _s		0.49	0.23	-0.48	0.32	0.49	0.52						
θ _(pF-0)		0.55	0.38	0.42	0.48	-0.57	-0.89	-0.63					
θ _(pF-1.98)		0.53	0.38	0.39	0.40	-0.54	-0.85	-0.63	0.95				
θ _(pF-2.35)		0.54	0.38	0.40	0.40	-0.54	-0.84	-0.60	0.92	0.98			
θ _(pF-2.7)		0.57	0.40	0.41	0.40	-0.55	-0.82	-0.60	0.90	0.97	0.99		
θ _(pF-3.48)		0.74	0.47	0.59	0.52	-0.58	-0.66	-0.58	0.67	0.67	0.66	0.68	
θ _(pF-4.18)		0.75	0.44	0.63	0.59	-0.57	-0.65	-0.56	0.63	0.59	0.60	0.62	0.93

Las diferencias entre las muestras del norte del país y las del Austro son muy claras. Esto es lógico ya que los Andosoles del norte son más jóvenes y con una textura gruesa (pertenecen a la zona de volcanismo moderno cuyos suelos continúan recibiendo el aporte de cenizas volcánicas), mientras que los del Austro son antiguos y por lo tanto su textura es más fina. El estudio de Buytaert (2004) presenta información detallada al respecto. Las variables para las cuales estas diferencias se muestran más notorias son: el contenido de partículas de 50 – 2000 μm , pH, DA y K_s .




Figura 5. Clusters formados a partir de los 2 primeros componentes, N = 87

Un análisis de clusters a partir de los dos primeros componentes obtenidos del análisis de componentes principales muestra dos regiones bien definidas. En la primera están agrupadas todas las muestras del norte del país y algunas otras cuyos valores de contenido de partículas gruesas y DA son altos. El primer componente es sensible a los cambios en los contenidos de partículas gruesas y la DA . El segundo componente es sensible a los cambios en los contenidos de las partículas clasificadas como limo y arcilla. El 80.63 % de la variabilidad se explica con los dos componentes y solo con el primer componente se explica el 60.9 % (Figura 5). En el sentido del componente 1, mientras más negativo es su valor, mayor es el contenido de partículas de 50 – 2000 μm y la DA , y menor será el contenido de MO . Para el componente 2, valores más negativos significan contenidos altos de limo y valores positivos significan aumento en el contenido de partículas más finas (arcilla). Las variables predictoras involucradas en el análisis de componentes principales fueron: MO , DA y los contenidos de arena (ar), limo (lim) y arcilla (Arc).

3.3 Selección de variables

Se compararon las técnicas para seleccionar las variables a ser incluidas en el MRLM1 (básicamente: el método de *regresión paso a paso* y el AIC), para el resto de modelos se usó únicamente la técnica escogida. El método de *regresión paso a paso* resultó sencillo de aplicar sin embargo hay que tener en cuenta que: (i) puede suceder que el modelo

seleccionado no sea el óptimo, (ii) algunas variables que se eliminan pueden estar correlacionadas con la variable respuesta.

Con el ACP hay que considerar ciertos aspectos: (i) al ser los componentes combinaciones lineales de las variables originales su interpretación en ocasiones no es muy sencilla, (ii) en el ACP no interviene la variable respuesta por lo que puede suceder que alguno de los componentes descartados sean importantes para su predicción, (iii) es más efectivo cuando se tiene un gran grupo de variables y que no estén correlacionadas a un nivel muy alto, (iv) el ACP es más útil para encontrar relaciones entre las variables.

El método de selección AIC resultó más fácil de aplicar e interpretar. Por lo tanto las variables que se incluyeron en cada modelo fueron escogidas de acuerdo con este criterio de selección. En trabajos con modelos de regresión lineal múltiple, Faraway (2002) recomienda el uso de métodos basados en criterios de selección como el AIC, ya que estos involucran una búsqueda más amplia y comparan los modelos de una mejor manera.

3.4 FET para estimar puntos individuales de la CRHS

Mediante MRLM se obtuvieron 16 funciones que predicen θ para los siguientes valores de pF: 0, 1.98, 2.35, 2.7, 3.48, y 4.18. Las variables incluidas en las ecuaciones fueron seleccionadas de acuerdo al AIC. Estas ecuaciones se muestran en la Tabla 4, en donde se incluye el código asignado a cada una de ellas y el coeficiente de determinación para el ajuste del modelo. Las siglas MRLM y MRNA significan modelo de regresión lineal múltiple y modelo de redes neuronales respectivamente. Las letras minúsculas al final: a, b, c, d, e, y f representan los valores de pF: 0, 1.98, 2.35, 2.7, 3.48, y 4.18 respectivamente.

Tabla 4. FET desarrolladas en esta tesis para estimar θ .

FET	Función	R ²
MRLM1a	$\theta_{(pF-0)} = 0.98458 + 0.001 \text{ lim} - 0.00239 \text{ MO} - 0.39079 \text{ DA}$	0.807
MRLM2a	$\theta_{(pF-0)} = 0.97984 - 0.38024 \text{ DA}$	0.798
MRLM1b	$\theta_{(pF-1.98)} = 0.95068 + 0.00177 \text{ lim} - 0.00576 \text{ MO} - 0.44808 \text{ DA}$	0.754
MRLM2b	$\theta_{(pF-1.98)} = -0.156909 - 0.002141 \text{ MO} + 1.129018 \theta_{(pF-0)}$	0.907
MRLM1c	$\theta_{(pF-2.35)} = 1.1120589 - 0.0020833 \text{ ar} - 0.0016178 \text{ Arc} - 0.0059779 \text{ MO} - 0.4363393 \text{ DA}$	0.734
MRLM2c	$\theta_{(pF-2.35)} = -0.0895098 - 0.0007843 \text{ ar} - 0.0029093 \text{ MO} + 1.069679 \theta_{(pF-0)}$	0.861
MRLM1d	$\theta_{(pF-2.7)} = 0.8576702 + 0.0022306 \text{ lim} - 0.0049716 \text{ MO} - 0.4070583 \text{ DA}$	0.707
MRLM2d	$\theta_{(pF-2.7)} = -0.0192182 - 0.0011658 \text{ ar} - 0.0028412 \text{ MO} + 0.9652626 \theta_{(pF-0)}$	0.831
MRLM1e	$\theta_{(pF-3.48)} = 0.2601549 + 0.0033606 \text{ lim} + 0.0039463 \text{ Arc} - 0.1512933 \text{ DA}$	0.636
MRLM2e	$\theta_{(pF-3.48)} = -0.1087494 + 0.0033977 \text{ lim} + 0.0041112 \text{ Arc} + 0.3612422 \theta_{(pF-0)}$	0.653
MRLM3e	$\theta_{(pF-3.48)} = 0.02887 + 0.07187 \theta_{(pF-0)} + 0.93244 \theta_{(pF-4.18)}$	0.906
MRLM4e	$\theta_{(pF-3.48)} = 0.06799 + 0.98129 \theta_{(pF-4.18)}$	0.903
MRLM1f	$\theta_{(pF-4.18)} = 0.15471 + 0.0026855 \text{ lim} + 0.0039253 \text{ Arc} + 0.0038006 \text{ MO} - 0.1140223 \text{ DA}$	0.652
MRLM2f	$\theta_{(pF-4.18)} = -0.1214053 + 0.0025213 \text{ lim} + 0.0039894 \text{ Arc} + 0.0044617 \text{ MO} + 0.2707795 \theta_{(pF-0)}$	0.663
MRLM3f	$\theta_{(pF-4.18)} = -0.1323094 + 0.0033118 \text{ lim} + 0.0044872 \text{ Arc} + 0.307816 \theta_{(pF-0)}$	0.643
MRLM4f	$\theta_{(pF-4.18)} = 0.009902 - 0.036955 \text{ DA} + 0.862956 \theta_{(pF-3.48)}$	0.907

Los modelos con el número 1 (p.e. MRLM1a) consideran como variables predictoras la *MO*, *DA* y los contenidos de arena, limo y arcilla, y de estas incluyen solo aquellas seleccionadas de acuerdo con el AIC.

Tabla 5. **Relaciones entre variables para los modelos de redes neuronales artificiales.**

FET	Relación	Pesos
MRNA1a	$\theta_{(pF-0)} = lim + MO + DA$	21
MRNA1b	$\theta_{(pF-1.98)} = lim + MO + DA$	21
MRNA2b	$\theta_{(pF-1.98)} = MO + \theta_{(pF-0)}$ $\theta_{(pF-2.35)} = ar + Arc + MO$	17
MRNA1c	$+ DA$ $\theta_{(pF-2.35)} = ar + MO + \theta_{(pF-0)}$	25
MRNA2c		21
MRNA1d	$\theta_{(pF-2.7)} = lim + MO + DA$ $\theta_{(pF-2.7)} = ar + MO + \theta_{(pF-0)}$	21
MRNA2d		21
MRNA1e	$\theta_{(pF-3.48)} = lim + Arc + DA$	21
MRNA2e	$\theta_{(pF-3.48)} = lim + Arc + \theta_{(pF-0)}$	21
MRNA3e	$\theta_{(pF-3.48)} = \theta_{(pF-0)} + \theta_{(pF-4.18)}$	17
MRNA4e	$\theta_{(pF-3.48)} = \theta_{(pF-4.18)}$ $\theta_{(pF-4.18)} = lim + Arc + MO$	13
MRNA1f	$+ DA$ $\theta_{(pF-4.18)} = lim + Arc + MO + \theta_{(pF-0)}$	25
MRNA2f	$\theta_{(pF-4.18)} = lim + Arc + \theta_{(pF-0)}$	25
MRNA3f	$\theta_{(pF-0)}$	21
MRNA4f	$\theta_{(pF-4.18)} = DA + \theta_{(pF-3.48)}$	17

Utilizando MRNA se generaron FET comparables a las obtenidas a partir de MRLM en cuanto a las variables predictoras incluidas en la función; la Tabla 5 presenta estos modelos y sus respectivas variables.

En la Tabla 6 se incluyen los resultados de la comparación de diferentes FET desarrolladas para predecir θ una vez que fueron validadas (confiabilidad), además en la primera parte de la tabla se tienen los valores del coeficiente de determinación, coeficiente de determinación ajustado y el AIC para el desarrollo de las FET (precisión).

Se observa que las FET obtenidas por ambos métodos dan valores similares de RMSE, aunque a partir de las FET para θ a pF-3.48 hay una tendencia por parte del MRNA a tener valores más bajos de RMSE, sin embargo esta diferencia no es significativa. La Figura 6 muestra una comparación entre los modelos de regresión lineal múltiple y de redes neuronales artificiales en la estimación de θ utilizando las funciones 1 y 4.

Esta similitud por parte de los dos métodos puede deberse a que el tamaño de la base de datos es relativamente pequeño y por lo tanto se pudo haber llegado a un límite en cuanto a la capacidad de predicción de los MRNA. Los resultados en general fueron buenos para ambos métodos. Al respecto Minasny et al. (1999) también encontraron que las FET obtenidas a partir de regresión lineal múltiple y redes neuronales artificiales dieron mejores predicciones para la estimación de puntos individuales de la CRHS. Los valores de RMSE para las FET de esta investigación son similares a los que presentan estos autores.

Observamos que las FET: MRLM2b y MRNA2b dieron buenos estimados de θ (RMSE = 0.049 y 0.059 $\text{cm}^3 \text{cm}^{-3}$ respectivamente) al incorporar $\theta_{(pF-0)}$ como variable predictora (Tabla 6). De acuerdo con el AIC = -525.07 la función 2b también aparece como la mejor.

Tabla 6. Comparación de la precisión y confiabilidad de las FET en la predicción de θ .

Desarrollo					Validación N = 13			
Función	N	R ²	R ² _{aj}	AIC	Función	RMSE	Función	RMSE
MRLM1a	87	0.807	0.801	483.04	MRLM1a	0.1076	MRNA1a	0.1083
MRLM2a	87	0.798	0.796	482.96	MRLM2a	0.1054	-	-
MRLM1b	87	0.754	0.745	438.35	MRLM1b	0.0964	MRNA1b	0.0872
MRLM2b	87	0.907	0.905	525.07	MRLM2b	0.0499	MRNA2b	0.0592
MRLM1c	87	0.734	0.721	426.72	MRLM1c	0.0939	MRNA1c	0.0922
MRLM2c	87	0.861	0.856	485.29	MRLM2c	0.0530	MRNA2c	0.0552
MRLM1d	86	0.707	0.696	422.53	MRLM1d	0.0968	MRNA1d	0.0909
MRLM2d	86	0.831	0.825	469.85	MRLM2d	0.0557	MRNA2d	0.0612
MRLM1e	78	0.636	0.621	372.51	MRLM1e	0.1219	MRNA1e	0.1082
MRLM2e	78	0.653	0.639	376.31	MRLM2e	0.1189	MRNA2e	0.1035
MRLM3e	77	0.906	0.903	472.85	MRLM3e	0.0604	MRNA3e	0.0571
MRLM4e	77	0.903	0.902	472.65	MRLM4e	0.0608	MRNA4e	0.0461
MRLM1f	85	0.652	0.635	417.72	MRLM1f	0.1183	MRNA1f	0.0823
MRLM2f	85	0.663	0.646	420.39	MRLM2f	0.1177	MRNA2f	0.1022
MRLM3f	85	0.643	0.630	-417.5	MRLM3f	0.1083	MRNA3f	0.0891
MRLM4f	77	0.907	0.904	478.72	MRLM4f	0.0588	MRNA4f	0.0681

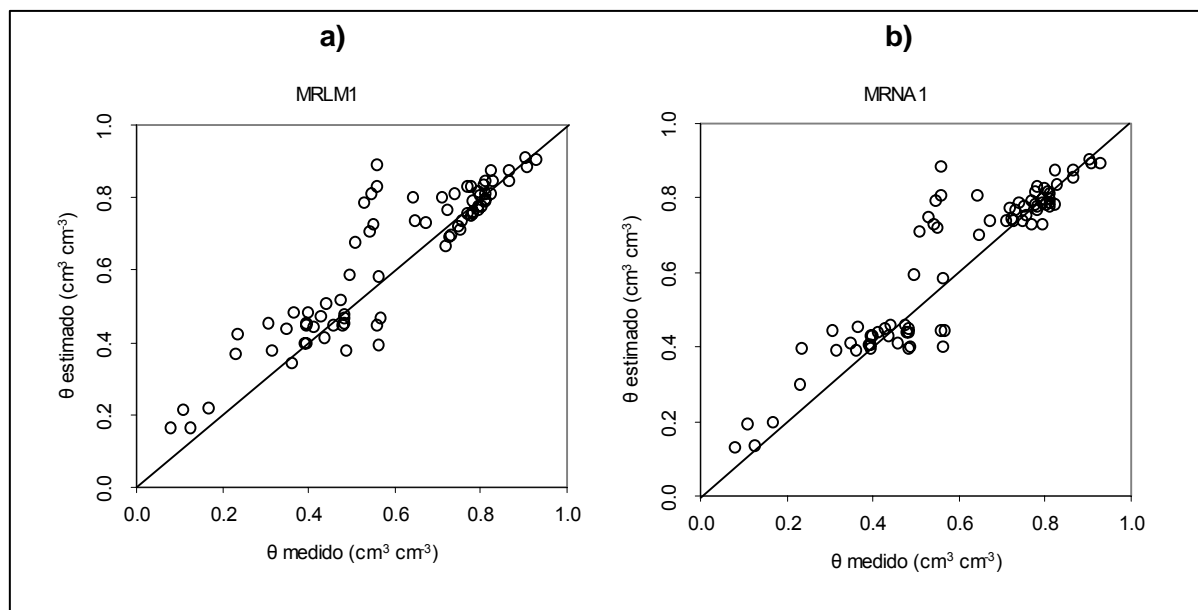


Figura 6. Comparación de θ medido y estimado en el grupo de datos de la validación usando: a) MRLM1 y b) MRNA1 (se incluyen θ para todos los valores de pF), N = 78

Cuando se incorporó $\theta_{(pF-0)}$ la DA ya no tuvo importancia en la función debido a que estas dos variables están estrechamente relacionadas como puede verse en la FET MRLM2a en donde únicamente con la DA como variable predictora se obtuvo un $R^2 = 0.798$ (Tabla 4). Este mismo comportamiento se pudo notar en el resto de FET que predicen θ hasta pF-2.7

Para los valores bajos de succión del suelo ($pF < 2.7$) el contenido de agua depende principalmente de la distribución del tamaño de poros, influenciada fuertemente por la estructura del suelo, DA y porosidad (Hartmann y Cornelis, 2004). Es claro que para θ en la zona húmeda de la CRHS, la estructura del suelo es una de las propiedades más importantes y la DA es un indicador indirecto de esta propiedad. A succiones altas del suelo ($pF > 2.7$) la importancia de la DA no es tan notoria.

El contenido de partículas de 50 – 2000 μm (arena) aparece en las FET solo en la predicción de θ hasta pF-2.7. Para los valores más altos de succión del suelo el contenido de partículas de $< 2 \mu\text{m}$ (arcilla) es más importante y vemos que esa variable aparece en todas las FET que no incorporan alguno de los dos últimos valores de contenido de agua de la CRHS (modelos 1e, 2e, 1f, 2f, y 3f). De acuerdo con Hartmann y Cornelis (2004), en la parte seca de la CRHS (valores altos del succión del suelo) las propiedades que afectan la superficie específica de las partículas son más importantes en la capacidad de retención de agua (propiedades como: la textura, el contenido de materia orgánica y la mineralogía de las arcillas).

La MO no aparece en este estudio como una variable decisiva en la predicción de θ sin duda porque su efecto se ve reflejado principalmente en la DA . Sin embargo la MO presentó una mayor correlación con θ correspondiente a los valores más altos de succión del suelo. Otro importante papel que cumple la MO es en la formación de los agregados del suelo que a su vez constituyen la estructura.

Para θ correspondiente a los dos valores más altos de presión (pF: 3.48 y 4.18) adicionalmente se incorporaron $\theta_{(pF-3.48)}$ y $\theta_{(pF-4.18)}$ como variables predictoras, según sea el caso, para obtener mejores predicciones. Obviamente la obtención de una de estas dos variables implica un esfuerzo adicional, pero hay que considerar que para su medición se requiere que las muestras estén una semana en el aparato de membrana para presiones altas.

Las FET de este estudio predicen muy bien θ para las muestras de suelos del Austro, pero con las muestras del norte del país la incertidumbre en las predicciones aumenta. Esto puede deberse a que hay pocas muestras del norte y estas se limitan a una zona en concreto, mientras que el área de páramos del norte para la que no se tienen información es grande. La Figura 7 muestra la predicción de θ para una de las muestras del grupo de datos para la validación. Para las muestras del norte el valor de θ es sobrestimado en el punto de saturación.




Figura 7. Comparación de θ medido y estimado a partir de modelos de regresión lineal múltiple (MRLM1) y modelos de redes neuronales (MRNA) para una de las muestras de la validación.

3.5 FET para estimar los 4 parámetros del MVG

3.5.1 En base a MRLM

Se obtuvieron FET en base a MRLM para los 4 parámetros. En la Tabla 7 vemos los modelos con las variables utilizadas en el desarrollo de las FET y en la Tabla 8 se presenta los resultados de estas FET para ambos grupos de datos: el de desarrollo y el de validación. Para las siglas de estas funciones, $TS = \theta_s$, $TR = \theta_r$, $A = \alpha$, y $N = n$.

Tabla 7. Relaciones entre variables para los modelos de regresión lineal múltiple.

FET	Función	R ²
TS-MRLM1	$\theta_s = \lim + MO + DA$	0.808
TR-MRLM1	$\theta_r = \lim + Arc + MO + DA$	0.592
TR-MRLM2	$\theta_r = \lim + Arc + MO + \theta_{(pF-0)}$	0.605
A-MRLM1	$\log\alpha = ar + \lim + MO + \theta_{(pF-0)}$	0.247
N-MRLM1	$\log n = \lim + Arc + \theta_{(pF-0)}$	0.125

Tabla 8. Comparación de la precisión y confiabilidad de las FET en la predicción de los parámetros del MVG.

Desarrollo					Validación N = 13	
Función	N	R ²	R ² _{aj}	AIC	Función	RMSE
TS-				-	TS-	
MRLM1	87	0.808	0.801	483.61	MRLM1	0.1079
TR-				-	TR-	
MRLM1	87	0.592	0.572	448.07	MRLM1	0.1201
TR-				-	TR-	
MRLM2	87	0.605	0.586	450.86	MRLM2	0.1194
A-					A-	
MRLM1	87	0.247	0.211	54.66	MRLM1	0.0113
N-				-	N-	
MRLM1	87	0.125	0.093	230.98	MRLM1	1.2347

Para las FET que predicen θ_s y θ_r se obtuvieron valores aceptables de R² y RMSE, lo que se explica por la relación lineal que existe entre estos dos parámetros y las propiedades del suelo que se incluyeron en los modelos.

En el caso de la función TR-MRLM2 el ajuste del modelo mejora al incluir $\theta_{(pF-0)}$ como variable predictora aunque esta mejora no es significativa (Tabla 8). También observamos que en la predicción de θ_r el contenido de partículas de < 2 μm aparece incluido en el grupo de variables predictoras indicando que la fracción de textura fina es más importante para los valores más altos de pF (p.e. para el punto de marchites).

En el caso de las FET que predicen α y n su precisión y confiabilidad fueron muy bajas (valores altos de RMSE para α y n) además el coeficiente de determinación indica que la relación lineal entre estos dos parámetros y las variables predictoras es muy baja. Esto puede deberse a que las variables disponibles para predecir estos parámetros no tienen mucha relación con los mismos. Los dos parámetros de forma están estrechamente relacionados con la distribución del tamaño de poros en el caso de n y el valor de entrada de aire en el caso de α . Probablemente el valor del porcentaje de contenido de partículas dentro de un cierto rango (p.e. < 2 μm) no sea suficiente para explicar esta relación. Puede ser necesario utilizar

información más precisa obtenida a partir de análisis granulométricos de las partículas del suelo.

El hecho de que se hayan alcanzado relativamente buenos ajustes con el MVG indicaría que este modelo sí podría ser usado para el tipo de suelo analizado, y podría interpretarse como que las variables empleadas en la predicción de los parámetros no son las correctas. También podría ser necesario otro tipo de transformaciones de los dos parámetros o normalizar la información antes de ajustar los modelos. Investigadores como Minasny et al. (1999) encontraron que los MRLM no son indicados para FET que estimen los parámetros del MVG, y Tomasella et al. (2003) concluyeron que las FET que predicen θ para puntos individuales de la CRHS proveen mejores resultados que los obtenidos con FET paramétricas dando como posible explicación el hecho de que las propiedades que controlan el contenido de humedad del suelo a diferentes presiones no están relacionadas directamente con los parámetros del MVG.

3.5.2 En base a MRNA

En la estimación paramétrica los MRNA presentaron resultados no muy alentadores dando en la mayoría de los casos valores incoherentes. Esto confirmaría el hecho de que no existen relaciones lineales entre las variables predictoras usadas y los parámetros α y n . Dado que los MRNA no requieren de un modelo inicial para relacionar las variables y además no importa si la relación es lineal o no, estaríamos frente al hecho de que simplemente no hay relación entre estas variables y los parámetros. Por lo tanto haría falta considerar otras variables predictoras. Otro aspecto a tener en cuenta es el número de muestras empleadas para el entrenamiento. Podría ser que en el caso de la estimación paramétrica, empleando modelos de redes neuronales artificiales, se requiera de un mayor número de muestras.

3.6 FET para estimar la K_s

La Tabla 9 presenta las FET obtenidas para la estimación de K_s en base a MRLM. R^2 fue bajo utilizando como variables predictoras solamente ar , lim , Arc , DA y MO ($R^2 = 0.49$) por lo que fue necesario incluir en todas las funciones la variable $\theta_{(pF-0)}$. La MO no surgió como una variable importante, y de acuerdo con la matriz de correlación de la Tabla 3 el contenido de humedad a $pF-0$ muestra la mayor correlación con K_s . Utilizando una función de tipo polinomial de orden 2 (K-MRLM5) se obtuvo el mejor ajuste y la predicción de K_s también fue la mejor cuando se probó con las muestras para la validación (RMSE = 1.27 cm h⁻¹ y AIC = 57.52). La Tabla 10 presenta los resultados del desarrollo y la validación para las FET mostradas en la Tabla 9.

Tabla 9. FET para estimar K_s .

FET	Función	R ²
K-MRLM1	$K_s = 10.298796 - 0.008463 \lim - 0.05017 \text{ Arc} - 9.309186 \theta_{(pF-0)}$	0.522
K-MRLM2	$K_s = 109.7968 - 0.9344 ar - 0.9504 \lim - 0.9876 \text{ Arc} - 2.8963 DA - 14.7029 \theta_{(pF-0)}$	0.622
K-MRLM5	$K_s = 143 - 1.265 ar - 1.183 \lim - 1.219 \text{ Arc} - 49.98 \theta_{(pF-0)} + 29.21 \theta_{(pF-0)}^2 + 0.0008363 ar^2$	0.705

Tabla 10. Comparación de la precisión y confiabilidad de las FET en la predicción de K_s .

Desarrollo					Validación N = 13	
Función	N	R ²	R ² _{aj}	AIC	Función	RMSE
K-MRLM1	71	0.522	0.500	86.89	K-MRLM1	1.4133
K-MRLM2	72	0.622	0.593	73.55	K-MRLM2	1.7355
K-MRLM5	72	0.705	0.678	57.52	K-MRLM5	1.2763

En general la K_s puede ser estimada con coeficientes de determinación entre 0.52 y 0.70. Estos resultados no son tan buenos como en el caso de la estimación de θ . La conductividad hidráulica depende en gran medida del estado de humedad del suelo, y en el caso de la K_s del contenido de humedad en el punto de saturación. Al respecto parece ser que en algunas ocasiones no se consigue un estado completo de saturación como se ha reportado en mediciones de θ con la caja de arena (Borja y Garrido, 2003). Vereecken et al. (1989) llaman a este hecho *efecto de saturación incompleta* del suelo cuando se mide θ_s , y puede ser una de las causas por las que la correlación entre estas dos variables (K_s y θ_s) no es tan alta como la que podría esperarse y podría explicar las diferencias que existen entre θ_s medido y ajustado.

El modelo de redes neuronales artificiales presentó las mismas dificultades que en el caso de la estimación paramétrica. Los resultados que se obtuvieron con estas FET no fueron satisfactorios.

3.7 Comparación con otras FET

Fueron comparadas gráficamente con las FET de Rawls et al. (1982) (desarrolladas a partir de 2 541 muestras de suelos). Estos gráficos muestran que para las 13 muestras de la validación, el desempeño de las FET de este estudio fue mejor que el obtenido con las FET de Rawls et al. (1982) en la predicción de θ . En la Figura 8 se muestra esta comparación. Los programas Rosetta (Schaap et al., 2001) y RETC (van Genuchten et al., 1991) solo pudieron utilizarse con tres muestras debido a que no están hechos para suelos orgánicos con las características de los Andosoles y otros suelos del páramo cuyas densidades aparentes son muy bajas. Las versiones 1.2 y 6.0 de los programas Rosetta y RETC respectivamente solo admiten valores de densidad aparente dentro del rango de 0.5 a 2 g cm⁻³, y el 76% de las muestras para la validación presentaron valores por debajo de este rango. Los dos programas ofrecen la alternativa de prescindir de la DA y así estimar θ para todas las muestras. Pero esto equivaldría a tratar a estos suelos como si fueran suelos minerales y obviamente la capacidad de retención de agua de un suelo mineral está muy por debajo que en el caso de los Andosoles.

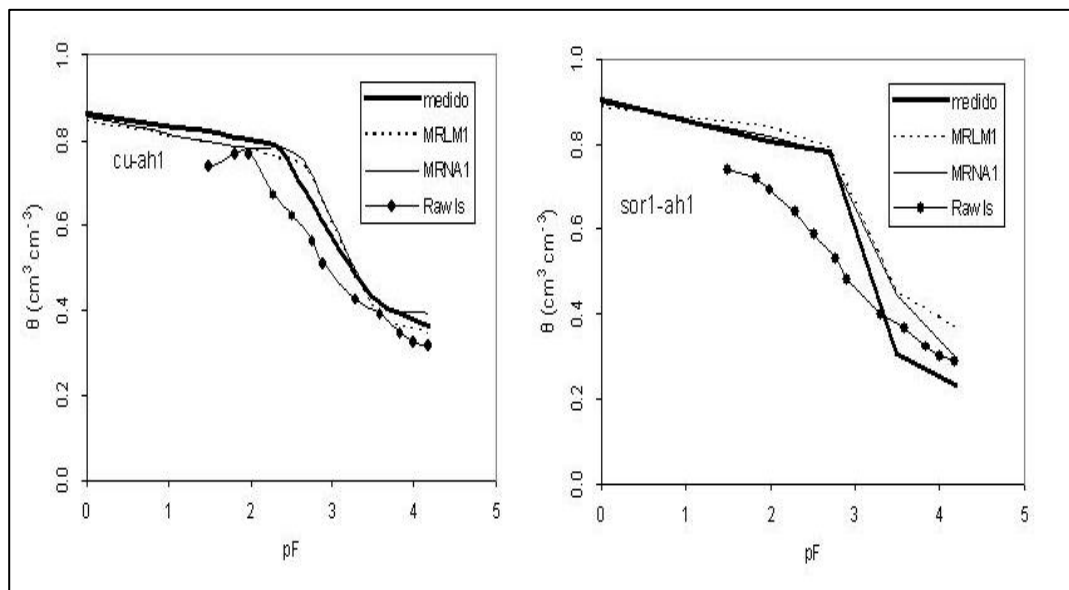


Figura 8. Curvas de retención de humedad del suelo medidas y estimadas con dos FET propuestas en esta tesis y con otras FET disponibles en la literatura. Las curvas coinciden para el caso de RETC y Rosetta (joy-bw).

Los resultados del análisis comparativo revelan que las FET de los dos programas dan exactamente los mismos resultados en la predicción de θ y estos resultados fueron inferiores a los de las FET de este estudio. Ambos programas implementan FET basadas en redes neuronales artificiales y predicen θ y K_s a partir de información textural del suelo, DA y 1 o 2 puntos de retención de agua. Posiblemente las bases de datos que utilizan para el entrenamiento sean las mismas y en el caso de Rosetta los modelos se desarrollaron usando un número de 2085 muestras (Schaap et al., 2001).

Es claro que no se puede usar FET sin una validación previa ya que son funciones empíricas. Todas las FET han sido desarrolladas para grupos de suelos y zonas específicas y aunque presenten muy buenos resultados, cuando se utilizan fuera del rango de datos para el que fueron hechas pierden su poder de predicción. Mientras más grande sea el rango de texturas que cubren las FET mejores serán las posibilidades de predicción que estas tendrán en otros grupos de suelos (Tomasella et al., 2000), sin embargo mientras no se compruebe su validez no deberían ser usadas.

No se hizo una comparación de las FET para predecir K_s ya que se espera que el desempeño de las FET encontradas en la literatura no será mejor que el de las propuestas en este estudio. Al respecto se comparó el programa RETC únicamente para las tres muestras cuya densidad aparente está dentro del rango para el que trabaja el programa (3 muestras del norte del país). El resultado de usar el programa RETC para los tres casos muestra que los valores de K_s son sobreestimados para los Andosoles.

Los Andosoles poseen características muy diferentes a las de otros suelos y la mayoría de FET han sido desarrolladas para suelos minerales. Sobieraj et al. (2001) evaluaron 9 FET de diferentes autores en una cuenca en la Amazonía del Perú, entre ellas las del programa Rosetta, y encontraron que fueron inadecuadas en la predicción de K_s con el propósito de usarse en modelación hidrológica.

4 CONCLUSIONES

- Frente a la necesidad de obtener métodos alternativos para poder estimar la CRHS y la K_s para usarse en modelos que describan los procesos de flujo del agua en el suelo, se llevó a cabo esta investigación cuyo propósito fundamental fue desarrollar Funciones de Edafo-Transferencia para Andosoles.
- Se determinaron importantes relaciones entre las principales propiedades hidráulicas del suelo y otras propiedades básicas. Estas relaciones permitieron desarrollar FET que estiman la CRHS y la K_s en suelos Andosoles con un nivel de precisión razonable. Para seleccionar adecuadamente las variables a partir de las cuales se harán las estimaciones es importante emplear un buen método de selección que nos garantice que los modelos obtenidos presentan el mejor ajuste y con el menor número de variables.
- Las FET basadas en MRLM proporcionaron buenas estimaciones de la CRHS, lográndose en todos los casos valores de R^2 superiores a 0.6. Los modelos de redes neuronales artificiales no mejoraron notablemente la precisión de las FET en comparación con los MRLM, sin embargo su verdadero potencial solo será evidente con bases de datos de gran tamaño. La estimación mejoró al incluir como variables predictoras $\theta_{(pF-0)}$, $\theta_{(pF-3.48)}$ o $\theta_{(pF-4.18)}$ según sea el caso. Se encontró que las FET de este estudio ofrecen mejores predicciones para las muestras que provienen del Austro, mientras que para las muestras del norte del país el contenido de humedad al punto de saturación tiende a ser sobreestimado.
- La estimación de los parámetros α y n de la ecuación de van Genuchten mediante MRLM y MRNA no fue satisfactoria cuando se trató de relacionarlos con las propiedades básicas del suelo.
- La capacidad de estimación de K_s por parte de las FET basadas en MRLM no fue tan buena como la conseguida en la estimación de θ .
- Si bien los ajustes obtenidos con el MVG para las muestras de este estudio se consideran aceptables, no son tan buenos como los que se obtienen para otros grupos de suelos. Al respecto Buytaert (2004) concluye que el MVG no es el más adecuado para describir la CRHS de los Andosoles, y esta podría ser la razón por la cual no se obtuvieron buenos resultados en la estimación paramétrica.
- Las FET obtenidas en este estudio ofrecen mejores resultados, en la estimación de las principales propiedades hidráulicas de los Andosoles, que las FET de Rawls y Brakensiek (1982), Rosetta (Schaap et al, 2001) y RETC (van Genuchten et al., 1991). Sin embargo es importante señalar que las FET de estos autores no fueron desarrolladas para usarse con suelos orgánicos.

REFERENCIAS

- Alomía M., 2005. Efectos de la producción agropecuaria en los suelos de los páramos: El caso de Guanga. Rev. Ecuador – Debate. Quito, Ecuador, 65.

- Borja, P. y Garrido, J., 2003. Análisis de las características hidrofísicas de los Andosoles y la influencia del uso del suelo en su capacidad de retención de agua. PROMAS – Universidad de Cuenca. Tesis de Ingeniero Agrónomo.
- Buytaert, W., 2000. De invloed van landgebruik op de hydrologische eigenschappen van vulkanische bodems. Katholieke Universiteit Leuven. Tesis.
- Buytaert, W., 2004. The properties of the soils of the south Ecuadorian páramo and the impact of land use changes on their hydrology. Katholieke Universiteit Leuven. Tesis de Ph.D.
- Buytaert, W., Wyseure, G., De Bièvre, B. y Deckers, J., 2005. The effect of land use changes on the hydrological behaviour of Histic Andosols in south Ecuador. *Hydrological Processes*, 19: 3985-3977.
- Crespo, 2006. Efecto de la escala de la información sobre el desempeño del modelo SWAT en una microcuenca de montaña. PROMAS – Universidad de Cuenca. Tesis de M.Sc.
- Dercon, G., Bossuyt, B., De Bièvre, B., Cisneros, F. y Deckers, J., 1998. Zonificación Agroecológica del Austro Ecuatoriano. U Ediciones, Cuenca, Ecuador.
- Durner, W., 1995. SHYPPFIT 0.22, User's manual. Research Report 95.1, Department of Hydrology, University of Bayreuth, D-95440 Bayreuth, Germany, 25pp.
- Faraway, J., 2002. Practical Regression and Anova using R. Copyright© 1999, 2000, 2002 Julian J. Faraway, 212pp.
- Hartmann, R. y Cornelis, W., 2004. Soil Physics. Dept. Soil Management and Soil Care. Gent University. Belgium, 188 pp.
- Iñiguez, V., 2003. Balance hídrico de microcuencas de páramo. PROMAS – Universidad de Cuenca. Tesis de Ingeniero Civil.
- ISSS Working Group RB, 1998. World Reference Base for Soil Resources: Introduction. (Deckers, J.A., Nachtergaele, F.O. y Spaargaren, O.C.) First Edition. International Society of Soil Science (ISSS), International Soil Reference and Information Centre (ISRIC) and Food and Agriculture Organization of the United Nations (FAO). Acco. Leuven, 157 pp.
- Jackson, M., 1982. Análisis Químico de Suelos. Cuarta edición. Ediciones Omega, S.A., Barcelona.
- Jain, S., Singh, V. y van Genuchten, M. Th., 2004. Analysis of Soil Water Retention Data Using Artificial Neural Networks. *Journal of Hydrologic Engineering*, ASCE, 9 (5): 415-420.
- Mejía, S., 2004. Prestación de servicios de laboratorio a Ecociencia, para análisis de propiedades hidrofísicas de suelos Andosoles. Laboratorio de hidrofísica de suelos. PROMAS – Universidad de Cuenca.
- Mendenhall, W. y Sincich, T., 1995. Statistics for Engineering and the Sciences. Fourth Edition. Prentice Hall, Inc. Upper Saddle River; NJ 07458.
- Minasny, B., McBratney, A. B. y Bristow, K. L., 1999. Comparison of different approaches to the development of pedotransfer functions for water-retention curves. *Geoderma*, 93: 225–253.
- Mogrovejo, D. y Palacios, J., 2005. Propiedades hidrofísicas de los suelos del Páramo y respuesta hidrológica frente a un evento extremo de lluvia a escala de ladera. PROMAS – Universidad de Cuenca. Tesis de Ingeniero Civil.
- Raes, D., 2002. Budget: A soil water and salt balance model. Reference manual, version 5.0. Institute for Land and Water Management. K.U. Leuven.
- Rawls, W. J., Brakensiek, D. L. y Saxton, K. E., 1982. Estimation of soil water properties. *Trans. ASAE*, 25: 1316-1320.
- Schaap, M.G., Leij, F. J., y van Genuchten, M., Th., 2001. ROSETTA: A computer program for estimating soil hydraulic parameters with hierarchical pedotransfer functions. *Journal of Hydrology*, 251: 163-176.
- Sobieraj, J., Elsenbeer, H. y Vertessy, R., 2001. Pedotransfer functions for estimating saturated hydraulic conductivity: implications for modeling storm flow generation. *Journal of Hidrology*, 251: 202-220.
- Soil Survey Staff, 2006. Keys to soil Taxonomy. Tenth Edition. United States Department of Agriculture, Washington D.C.

- Tomasella, J., Hodnett, M.G. y Rossato, L., 2000. Pedotransfer Functions for the Estimation of Soil Water Retention in Brazilian Soils. *Soil Science Society of America Journal*, 64: 327-338.
- Tomasella, J., Pachepsky, Y.A., Crestana, S., Rawls, W.J., 2003. Comparison of two approximation techniques to develop pedotransfer functions for water retention of Brazilian soils. *Soil Science Society of America Journal*, 67: 1085-1092.
- van Dam, J. C., Stricker, J. N. y Droogers, P., 1992. Inverse method for determining soil hydraulic functions from one-step outflow experiments. *Soil Science Society of America Journal*, 56: 1042-1050.
- van Genuchten, M. Th., 1980. A closed-form equation for predicting the hydraulic conductivity of unsaturated soils. *Soil Science Society of America Journal*, 44: 892-898.
- van Genuchten, M. Th., Leiji, F. J., y Yates, S.R., 1991. The RETC code for quantifying the hydraulic functions of unsaturated soils. Report No. EPA/600/2-91/065.
- Verdugo, V., 2004. Efecto del cambio de uso de suelo sobre sus propiedades físicas en tres zonas de la cuenca del río Paute. PROMAS – Universidad de Cuenca. Tesis de M.Sc.
- Vereecken, H., Maes, J., Feyen, J. y Darius, P., 1989. Estimating the soil moisture retention characteristic from texture, bulk density, and carbon content. *Soil Science*, 148: 389-403.