

**DESARROLLO DE FUNCIONES DE EDAFOTRANSFERENCIA PARA SUELOS
ANDINOS NEOTROPICALES**

JAIME IZQUIERDO BAUTISTA

**Tesis doctoral presentada como requisito parcial para optar al título de
Doctor en Planificación y Manejo Ambiental de Cuencas Hidrográficas**

Director

MIGUEL IGNACIO BARRIOS PEÑA

Dr. Ingeniería del Agua y Medioambiental

Codirector

EDGAR ÁLVARO ÁVILA PEDRAZA

Dr. en Ciencias Agrarias

UNIVERSIDAD DEL TOLIMA

FACULTAD DE INGENIERIA FORESTAL

DOCTORADO EN PLANIFICACIÓN Y MANEJO AMBIENTAL DE CUENCAS

HIDROGRÁFICAS

IBAGUE – TOLIMA

2020

**FACULTAD DE INGENIERIA FORESTAL
DOCTORADO EN PLANIFICACIÓN Y MANEJO AMBIENTAL DE CUENCAS
HIDROGRÁFICAS**

ACTA DE SUSTENTACIÓN DE TESIS

Ciudad y fecha: Ibagué, 26 de agosto de 2020.

Título de la Tesis Doctoral			
Desarrollo de funciones de edafotransferencia para suelos andinos neotropicales			
Doctorando		Jaime Izquierdo Bautista	
Supervisión	Nombre y Apellidos	Institución/Departamento	Categoría o Cargo
Director/a	Dr. Migue Ignacio Barrios Peña	Universidad del Tolima	Profesor Asociado
Director/a	Dr. Edgar Álvaro Avila Pedraza	Universidad del Tolima	Profesor Asociado
Codirector/a			

Tribunal de Evaluación		Nombre y Apellidos	Número de Identificación Personal o Pasaporte	Universidad o Institución	Departamento/ Dependencia/Unidad	Categoría o Cargo
Evaluador 1 (Presidente)	Dra.	Luz Amalia Forero Peña	65.731.395 de Ibagué	Universidad del Tolima	Ciencias Forestales	Profesora Asistente
Evaluador 2 (Vocal)	Dr.	Yesid Carvajal Escobar	16.732.148 de Cali	Universidad del Valle	Escuela de Recursos Naturales y del Ambiente Agua y Suelo	Profesor Titular
Evaluador 3 (Secretario)	Dr.	Sofiane Ouazaa	CE: 600846	Corporación Colombiana de Investigación Agropecuaria-AGROSAVIA		Investigador PhD

Evaluación				
Criterio	Evaluador 1	Evaluador 2	Evaluador 3	Promedio
Documento de Tesis (planteamiento del problema de Investigación, estado del arte, formulación de objetivos, coherencia del documento, pertinencia de la metodología, grado de originalidad del aporte al conocimiento científico)	4.7	4.2	3.0	4.0
Defensa de la Tesis Doctoral (pertinencia y claridad de las respuestas a las preguntas formuladas; seguridad, capacidad de argumentación, dominio del tema y facilidad de expresión, producción científica derivada de la tesis)	4.1	4.1	3.9	4.0
Valoración total	Promedio			4.0

Fdo,

			
Luz Amalia Forero Peña Evaluador 1	Yesid Carvajal Escobar Evaluador 2	Sofiane Ouazaa Evaluador 3	Omar A. Melo Cruz Director del Programa

In memoriam

Jaime Santiago Izquierdo Polanco



5 de noviembre de 2004

† 22 de julio de 2016

AGRADECIMIENTOS

En el curso de esta investigación he vivido sucesos trascendentales e irreversibles que me han transformado. Dichos acontecimientos me han llevado a evolucionar como investigador y ser humano en la forma en la cual ahora percibo las situaciones diarias, la misma ciencia y la vida. En este trasegar —extenso, arduo y constante— he tenido la oportunidad de conocer personas invaluablemente dispuestas a acompañarme sin esperar nada a cambio; solo, generosamente, cada una de ellas me ha tendido la mano cada vez que lo he necesitado.

En su orden, quiero agradecer al Doctor Miguel Ignacio Barrios Peña, persona incansable en su trabajo y dedicado a orientar a sus estudiantes y a todo aquel que lo requiera.

Al doctor Edgar Álvaro Ávila Pedraza por su orientación en toda la parte de suelos y recolección de muestras, desplazamientos en campo, y su enseñanza persistente en cuanto a los paisajes y la edafología.

A Andrés Cruz y a Juan Carlos Tapiero por su compañía en las travesías incansables por las montañas del Tolima y Quindío.

Al profesor Jhon Jairo Arévalo, coordinador del laboratorio de suelos de la Universidad Surcolombiana, por haberme apoyado en el análisis de las innumerables muestras de suelo que, junto con sus colaboradores, Cristian Reyes, Natalia Quevedo, Eliana Mosquera, y Efrén Mosquera, trabajamos durante arduas horas en los análisis de laboratorio.

A aquellos que he conocido y me han colaborado en la Universidad del Tolima: Cristina Mora, compañera de esta travesía; María Angélica Molina, orientadora en los aspectos administrativos; Jhoana Forero; Luis Eduardo Peña; Félix Salgado; Ligia Mejía; Doris Serrano y a todos quienes nos colaboraron en estos años de aprendizaje.

A todos ellos ¡Gracias!

CONTENIDO

INTRODUCCIÓN	21
1. ESTADO DEL ARTE	27
1.1 PROPIEDADES HIDROFÍSICAS DEL SUELO	27
1.2 TIPOS DE SUELOS MUESTREADOS	31
1.3 MÉTODOS DE LABORATORIO PARA DETERMINAR LAS PROPIEDADES FÍSICAS DEL SUELO	34
1.4 CARACTERÍSTICAS DE LAS PRINCIPALES VARIABLES HIDRODINÁMICAS DEL SUELO	39
1.5 DESARROLLO DE NUEVAS FUNCIONES DE EDAFOTRANSFERENCIA ...	41
1.6 FUNCIONES DE EDAFOTRANSFERENCIA	42
1.7 TÉCNICAS DE DESARROLLO DE NUEVAS FUNCIONES DE EDAFOTRANSFERENCIA	44
1.8 PROPIEDADES DEL SUELO USADOS COMO PREDICTORES	45
1.9 <i>SOFTWARE</i> DISPONIBLE E INVESTIGACIONES CON USO DE FUNCIONES DE EDAFOTRANSFERENCIA	46
1.10 TÉCNICAS DE APRENDIZAJE DE MÁQUINA APLICADOS AL DESARROLLO DE FUNCIONES DE EDAFOTRANSFERENCIA	58
2. METODOLOGÍA	68
2.1 ÁREA DE ESTUDIO	68
2.2 TOMA DE MUESTRAS Y ANÁLISIS DE LABORATORIO	71
2.3 DESCRIPCIÓN DE LA BASE DE DATOS	81
2.4 TRATAMIENTO DE LA COLINEALIDAD DE LAS VARIABLES PREDICTIVAS	88
2.5 FUNCIONES DE EDAFOTRANSFERENCIA COMPARADAS	90
2.6 CRITERIOS DE EVALUACIÓN DEL AJUSTE DE LOS MODELOS	98
2.7 DESARROLLO DE NUEVAS FUNCIONES DE EDAFOTRANSFERENCIA .	100

3. RESULTADOS	113
3.1 TEXTURA	113
3.2 DENSIDAD APARENTE	114
3.3 CARBONO ORGÁNICO Y MATERIA ORGÁNICA	115
3.4 RETENCIÓN DE HUMEDAD	116
3.5 ANÁLISIS DE LAS VARIABLES PREDICTIVAS, CON LOS MODELOS EXISTENTES.....	117
3.6 RESULTADOS DE LOS MODELOS DE EDAFOTRANSFERENCIA DESARROLLADOS CON REDES NEURONALES	140
3.7 DENSIDAD APARENTE	157
3.8 PUNTO DE MARCHITEZ PERMANENTE	158
3.9 CAPACIDAD DE CAMPO	160
3.10 RETENCIÓN DE AGUA EN EL SUELO	162
3.11 RESULTADOS DE LOS ÁRBOLES ALTAMENTE ALEATORIZADOS (<i>EXTRA TREES</i>).....	165
4. ANÁLISIS DE RESULTADOS	172
4.1 CARACTERÍSTICAS FÍSICAS DE LOS SUELOS	172
4.2 PUNTO DE MARCHITEZ.....	173
4.3 CAPACIDAD DE CAMPO	175
4.4 RETENCIÓN DE AGUA.....	176
4.5 VARIABLES PREDICTIVAS	177
4.6 REDES NEURONALES	180
4.7 ÁRBOLES ALTAMENTE ALEATORIZADOS.....	183
5. CONCLUSIONES	189
FUTURAS LÍNEAS DE INVESTIGACIÓN	192
REFERENCIAS	194

LISTA DE FIGURAS

Figura 1: Localización de los puntos de muestreo de la cuenca El Billar, Combeima, departamento del Tolima.	55
Figura 2: Localización de los puntos de muestro en el departamento del Quindío.	56
Figura 3: Calicata típica muestreada en el departamento del Quindío.	58
Figura 4: Calicata muestreada en la cuenca El Billar, Combeima, departamento del Tolima.	59
Figura 5: Triangulo textural de las muestras analizadas en laboratorio por el método de Bouyucos.	88
Figura 6: Dispersión de los datos de la densidad aparente con respecto a la profundidad.	89
Figura 7: Dispersión de los datos de la relación del porcentaje de carbono orgánico y la profundidad a la que se obtuvieron las muestras.	90
Figura 8: Dispersión de los datos de la retención de agua con respecto a la profundidad.	91
Figura 9: Dispersión de los datos de la retención de agua y el contenido de carbono orgánico encontrado en las muestras.	91
Figura 10: Densidad aparente (DA) observada y comparada con el modelo de Baumer.	92
Figura 11: Densidad aparente observada y comparada con el modelo de Rawls.	93
Figura 12: Punto de marchitez (WP) observado y comparado con el modelo de Baumer.	94
Figura 13: Punto de marchitez (WP) observado y comparado con el modelo de Brakensiek.	95
Figura 14: Punto de marchitez (WP) observado y comparado con el modelo de British Soil Survey Subsoil (BSS).	95

Figura 15: Punto de marchitez (WP) observado y comparado con el modelo de British Soil Survey Topsoil (BST).	96
Figura 16: Punto de marchitez (WP) observado y comparado con el modelo de Hutson.	96
Figura 17: Punto de marchitez (WP) observado y comparado con el modelo de Manrique.	97
Figura 18: Punto de marchitez (WP) observado y comparado con el modelo de Rawls.	97
Figura 19: Punto de marchitez (WP) observado y comparado con el modelo de Tomasella.	98
Figura 20: Punto de marchitez (WP) observado y comparado con el modelo de Saxton y Rawls.	98
Figura 21: Punto de marchitez (WP) observado y comparado con el modelo RETC.	99
Figura 22: Punto de marchitez observado y comparado con el modelo Rosetta.	99
Figura 23: Capacidad de campo (FC) observada y comparada con el modelo de Baumer.	101
Figura 24: Capacidad de campo (FC) observada y comparada con el modelo de Brakensiek.	101
Figura 25: Capacidad de campo (FC) observada y comparada con el modelo de British Soil Survey Subsoil (BSS).	102
Figura 26: Capacidad de campo (FC) observada y comparada con el modelo de British Soil Survey Topsoil (BTS).	102
Figura 27: Capacidad de campo (FC) observada y comparada con el modelo de Hutson.	103
Figura 28: Capacidad de campo (FC) observada y comparada con el modelo de Manrique.	103
Figura 29: Capacidad de campo (FC) observada y comparada con el modelo de Rawls.	104

Figura 30: Capacidad de campo (FC) observada y comparada con el modelo de Tomasella.	104
Figura 31: Capacidad de campo (FC) observada y comparada con el modelo de Saxton y Rawls.	105
Figura 32: Capacidad de campo (FC) observada y comparada con el modelo RETC	105
Figura 33: Capacidad de campo (FC) observada y comparada con el modelo Rosetta.	106
Figura 34: Capacidad de retención de agua (AW) observada y comparada con el modelo de Baumer.	106
Figura 35: Capacidad de retención de agua (AW) observada y comparada con el modelo de Brakensiek.	107
Figura 36: Capacidad de retención de agua (AW) observada y comparada con el modelo de British Soil Survey Subsoil (BSS).	107
Figura 37: Capacidad de retención de agua (AW) observada y comparada con el modelo de British Soil Survey Topsoil (BTS).	108
Figura 38: Capacidad de retención de agua (AW) observada y comparada con el modelo de Hutson.	108
Figura 39: Capacidad de retención de agua (AW) observada y comparada con el modelo de Manrique.	109
Figura 40: Capacidad de retención de agua (AW) observada y comparada con el modelo de Rawls.	109
Figura 41: Capacidad de retención de agua (AW) observada y comparada con el modelo de Tomasella.	110
Figura 42: Capacidad de retención de agua (AW) observada y comparada con el modelo de Saxton y Rawls.	110
Figura 43: Capacidad de retención de agua (AW) observada y comparada con el modelo RETC.	111

Figura 44: Capacidad de retención de agua (AW) observada y comparada con el modelo Rosetta.	111
Figura 45: Variables seleccionadas para red neuronal en la predicción de la densidad aparente (BD).	114
Figura 46: Variables seleccionadas para red neuronal en la predicción del agua retenida por el suelo (AW).	115
Figura 47: Variables seleccionadas para red neuronal en la predicción de la capacidad de campo (FC).	115
Figura 48: Variables seleccionadas para red neuronal en la predicción del punto de marchitez permanente (WP).	116
Figura 49: Representación gráfica de la red neuronal para la predicción del agua disponible retenida en el suelo (AW).	117
Figura 50: Representación gráfica de la red neuronal para la predicción de la densidad aparente (BD) del suelo.	117
Figura 51: Representación gráfica de la red neuronal para la predicción de la variable capacidad de campo (FC).	118
Figura 52: Representación gráfica de la red neuronal para la predicción del punto de marchitez permanente (WP).	118
Figura 53: Modelos generados por la red neuronal para la selección del mejor modelo de predicción para la capacidad de campo (FC) [arriba izquierda], el punto de marchitez permanente (WP) [arriba derecha], el agua retenida por el suelo (AW) [abajo izquierda] y la densidad aparente (BD) [abajo derecha].	119
Figura 54: Modelo de predicción de la red neuronal de la densidad aparente (DA) en la etapa de entrenamiento.	126
Figura 55: Modelo de predicción de la red neuronal de la densidad aparente (DA) en la etapa de validación.	126
Figura 56: Modelo de predicción de la red neuronal de la densidad aparente en la etapa de test.	127

Figura 57: Modelo de predicción de la red neuronal del punto de marchitez permanente (WP) en la etapa de entrenamiento.	128
Figura 58: Modelo de predicción de la red neuronal del punto de marchitez permanente (WP) en la etapa de validación.	128
Figura 59: Modelo de predicción de la red neuronal del punto de marchitez permanente (WP) en la etapa de test.	129
Figura 60: Modelo de predicción de la red neuronal de la capacidad de campo en la etapa de entrenamiento.	130
Figura 61: Modelo de predicción de la red neuronal de la capacidad de campo en la etapa de validación.	130
Figura 62: Modelo de predicción de la red neuronal de la capacidad de campo en la etapa de test.	131
Figura 63: Modelo de predicción de la red neuronal del agua retenida por el suelo (AW) en la etapa de entrenamiento.	132
Figura 64: Modelo de predicción de la red neuronal del agua retenida por el suelo (AW) en la etapa de validación.	132
Figura 65: Modelo de predicción de la red neuronal del agua retenida por el suelo (AW) en la etapa de test.	133
Figura 66: Evolución de los 100 modelos generados por árboles extremadamente aleatorizados en la fase de calibración y validación, para el agua disponible en el suelo (AW).	134
Figura 67: Evolución del modelo seleccionado por árboles extremadamente aleatorizados en validación y calibración, para el agua disponible en el suelo (AW).	134
Figura 68: Evolución de los 100 modelos generados por árboles extremadamente aleatorizados en la fase de calibración y validación para la capacidad de campo (FC).	135
Figura 69: Evolución del modelo seleccionado por árboles extremadamente aleatorizados en validación y calibración para capacidad de campo (FC).	136

Figura 70: Evolución de los 100 modelos generados por árboles extremadamente aleatorizados en la fase de calibración y validación, para el punto de marchitez (WP).	136
Figura 71: Modelo seleccionado por árboles extremadamente aleatorizados en las fases de validación y calibración, para el punto de marchitez (WP).	137
Figura 72: Evolución de los 100 modelos generados por árboles extremadamente aleatorizados en la fase de calibración y validación, para la densidad aparente (BD).	138
Figura 73: Modelo seleccionado por árboles extremadamente aleatorizados en las fases de validación y calibración para la densidad aparente (BD).	138

LISTA DE TABLAS

Tabla 1: Modelos de edafotransferencia comparados.....	91
Tabla 2: Variables seleccionadas (las casillas sombreadas) para alimentar el modelo de red neuronal mediante la aplicación del método paso a paso	106
Tabla 3: Evaluación de ajuste de los modelos para la densidad aparente (BD)..	118
Tabla 4: Evaluación de ajuste de los modelos para el punto de marchitez (WP) en el suelo.	120
Tabla 5: Evaluación de ajuste de los modelos para la capacidad de campo (FC) en el suelo	127
Tabla 6: Evaluación de ajuste de los modelos para la capacidad de retención de agua (AW) en el suelo.....	139
Tabla 7: Variables predictivas observadas	140
Tabla 8: Síntesis estadística para cada etapa de las variables dependientes analizadas.	148

RESUMEN

El contenido de agua en el suelo relaciona la capacidad de campo y el punto de marchitez permanente, fundamental para el riego en la agricultura, la disponibilidad del agua potable, la generación de energía, la industria y el comportamiento de los ecosistemas, entre otros. Para su determinación exacta hacen falta recursos humanos, técnicos y económicos. Por lo anterior, se han desarrollado funciones que pueden calcular los valores de retención de agua en el suelo, lo cual los hace mucho más económicos y permiten ahorrar tiempo. Sin embargo, no todas las funciones propuestas por diferentes investigadores son precisas para aplicar en todos los lugares.

En esta investigación se escogieron 80 lugares entre los departamentos del Tolima y Quindío para la toma de muestras, a las cuales se les tomaron datos de campo como la ubicación y cobertura. Estas se llevaron al laboratorio donde se realizaron análisis de textura, densidad aparente, y puntos de retención de humedad a 0,3, 1, 5, 10 y 15 bar; también se les halló el contenido de materia orgánica.

En cuanto a la evaluación de redes neuronales artificiales, árboles altamente aleatorizados (ET) e investigadores de funciones de edafotransferencia, estos se usaron para predecir el contenido de agua disponible para las plantas en el suelo (AW), el punto de marchitez permanente (WP), la capacidad de campo (FC) y la densidad aparente (BD) en suelos del Tolima y Quindío en Colombia. Para ello, se tomaron 175 muestras de suelo a diferentes profundidades en 80 puntos y, de este modo, generar funciones de edafotransferencia con las redes neuronales y la clasificación de las variables de mayor influencia con los árboles altamente aleatorizados.

Con respecto a las funciones de edafotransferencia propuestas por Baumer, Rawls, Brakiensek, Hutson, British Soils, Manrique, Tomasella, Saxton, RETC y Rosetta, estas no arrojaron buenos resultados de predicción. Así, los R^2 máximos alcanzados fueron de 0,18 —obtenidos por Baumer— al predecir BD. En la predicción de AW, FC y WP los

R^2 oscilaron entre 0,06 y 0,01. A su vez, el RMSE alcanzó valores de 0,40 y 0,04, donde se observó claramente que estos no reflejan bien la predicción para este tipo de suelos; además, utilizan la textura y la densidad aparente como variables para calcular el agua disponible en el suelo.

En lo que concierne a las variables de entrada procedentes de los datos tomados en campo, laboratorio, como del modelo de elevación digital, se utilizaron las siguientes 12: latitud, elevación, pendiente, curvatura del terreno, drenaje acumulado, espesor del horizonte, profundidad al centroide, % de arenas, % de arcillas, carbono orgánico, cobertura y densidad aparente.

En relación con las redes neuronales se seleccionaron las variables más relevantes por el método paso a paso. De esta forma, se escogieron aquellas de entrada de la red para la predicción de BD: latitud, carbono orgánico, altura, % de arenas, pendiente, % de arcillas y la cobertura. Para la predicción AW se eligieron las variables: elevación, latitud, densidad aparente, espesor del horizonte, carbono orgánico, cobertura y % de arenas. Para la predicción de la FC se seleccionaron la densidad aparente, la latitud, la pendiente, la altura y la cobertura. Para WP se eligieron la densidad aparente, la latitud, la elevación, la pendiente y el % de arcillas.

En lo que respecta a las redes neuronales, los datos se dividieron en tres grupos: el 70 % para el entrenamiento, el 15 % para la validación y 15 % para la prueba final. Con relación a WP, el coeficiente de determinación (R^2) varió entre 0,64 y 0,79, y la raíz del error cuadrático medio (RMSE) entre 0,17 y 0,23. En cuanto a FC el R^2 estuvo entre 0,74 y 0,75, mientras que RMSE varió entre 0,18 y 0,20. En lo concerniente a AW el R^2 osciló entre 0,75 y 0,84, y el RMSE se encontró entre 0,06 y 0,10. Por último, en BD el R^2 estuvo entre 0,76 y 0,78, y el RMSE entre 0,11 y 0,19.

En lo que respecta a los ET se utilizaron las mismas 12 variables seleccionadas previamente, se generaron 100 modelos y se escogió el de mejor rendimiento en R^2 — tanto en validación como en calibración— al utilizarse la validación cruzada. En AW el

R^2 alcanzó los 0,94 en calibración y 0,56 en validación, al seleccionarse tres variables relevantes (la altura, la densidad aparente y la curvatura del terreno). Para FC el R^2 fue de 0,94 en calibración y 0,60 en validación, donde dos variables (la densidad aparente y la latitud) fueron las más destacadas. En cuanto a WP, el R^2 en calibración alcanzó el valor de 0,96 y en validación el 0,59 con tres variables principales (latitud, densidad aparente y altura). Finalmente, para BD en calibración el R^2 fue de 0,98 y en validación 0,54, donde cuatro variables (carbono orgánico, % de arcillas, latitud y drenaje acumulado) fueron seleccionadas.

Con relación a las redes neuronales, estas presentaron gran capacidad de predicción de las variables. Si bien, los ET no alcanzaron el mismo rendimiento que las redes neuronales, estos representan una alternativa para la predicción de AW, FC, WP y BD en los suelos del Tolima y el Quindío sobre la cordillera central. A su vez, las ecuaciones propuestas por investigadores de otras latitudes no ofrecen confiabilidad en sus predicciones en cuanto al contenido de agua en el suelo y densidad aparente.

Palabras claves: Edafotransferencia, redes neuronales, capacidad de campo, punto de marchitez permanente, agua retenida por el suelo, densidad aparente.

ABSTRACT

Soil moisture relates field capacity and permanent wilting point, crucial for many hydrological applications, including irrigation, drinking water supply, hydropower generation, industrial applications, and ecosystem dynamics, among others. Estimating soil moisture is expensive and requires substantial human, technological and economic resources. Therefore, pedotransfer functions that determine water retention parameters are less costly and labor-intensive methodologies. However, not all the pedotransfer functions proposed by different researchers are accurate to apply in all locations.

In this research, 80 sampling locations were chosen between the departments of Tolima and Quindío, from which field data such as location and coverage were recorded. Once in the laboratory, the following analyses were carried out: texture, bulk density, and moisture retention points at 0.3, 1, 5, 10, and 15 bar; furthermore, organic matter content was also established.

Artificial neural network, extremely-(randomized)-trees or extra trees (ET), and pedotransfer function assessments were used to predict soil moisture content (AW), permanent wilting point (WP), field capacity (FC), and apparent or bulk density (BD) in the soils of Tolima and Quindío in Colombia. One hundred seventy-five soil samples were taken at different depths and in 80 points to generate pedotransfer functions with artificial neural networks and the classification of the highest influencing variables employing extremely randomized trees.

The pedotransfer functions proposed by Baumer, Rawls, Brakiensek, Hutson, British Soils, Manrique, Tomasella, Saxton, RETC, and Rosetta did not provide good prediction results. The maximum R^2 reached was 0.18 achieved though Baumer when predicting BD. In the prediction of AW, FC, and WP, the R^2 oscillated between 0.06 and 0.01. The RMSE reached values of 0.40 and 0.04, clearly observing that they do not reflect well the

prediction for this type of soil; besides, they use texture and bulk density as variables to calculate the soil moisture.

Regarding the input variables derived from the data taken in the field, laboratory and from the digital elevation model, the following 12 variables were used: latitude, elevation, slope, terrain curvature, accumulated drainage, horizon thickness, depth to the centroid, % of sands, % of clays, organic carbon, coverage, and bulk density.

For the artificial neural networks, the most relevant variables were selected by the step-by-step method. Hence, the input variables of the network for the prediction of BD were selected: Latitude, organic carbon, height, % of sands, slope, % of clays, and coverage. For the AW prediction, the following variables were chosen: elevation, latitude, bulk density, horizon thickness, organic carbon, coverage, and % of sands. For the prediction of FC, bulk density, latitude, slope, height, and coverage were selected. For WP, bulk density, latitude, elevation, slope, and % of clays were chosen.

Concerning artificial neural networks, the data were divided into three groups, 70 % for training, 15 % for validation, and 15 % for the final test. For WP, the coefficient of determination (R^2) varied between 0.64 and 0.79, and the root mean square error (RMSE) ranged between 0.17 and 0.23; for FC, R^2 varied between 0.74 and 0.75, while RMSE ranged between 0.18 and 0.20; in AW the R^2 ranged between 0.75 and 0.84, and the RMSE varied between 0.06 and 0.10; in BD, the R^2 varied between 0.76 and 0.78, and the RMSE between 0.11 and 0.19.

In the extra trees method, the same 12 previously selected variables were used, generating 100 models, and the one with the best performance in R^2 was chosen –both under validation as well as under calibration– using cross-validation. In AW, the R^2 reached 0.94 under calibration and 0.56 under validation, selecting three relevant variables (height, bulk density, and terrain curvature). For FC, R^2 was 0.94 under calibration and 0.60 under validation with two variables (bulk density and latitude). In WP, the R^2 under calibration reached 0.96 and under validation 0.59 with three main variables

(latitude, bulk density, and height). Finally, for BD, under calibration, the R^2 was 0.98, and under validation, it was 0.54, where four main variables were selected (organic carbon, % clays, latitude, and accumulated drainage).

The artificial neural networks showed a high predictive capacity for the variables considered. Although the extra trees method did not achieve the same performance as the artificial neural networks, they represent an alternative for the prediction of AW, FC, WP, and BD in the Tolima and Quindío soils on the central mountain range. Moreover, the equations proposed by researchers from other latitudes are not reliable in their soil moisture content and bulk density predictions.

Keywords: Pedotransference, neural networks, field capacity, permanent wilting point, water retained by the soil, apparent density.

INTRODUCCIÓN

A lo largo de la historia de la humanidad, el agua es y ha sido fundamental para el desarrollo de la vida humana, animal y vegetal. Asimismo, ha sido protagonista en los contextos sociales, económicos y culturales de todos los países a nivel mundial. Por lo anterior, el hombre ha tratado de controlar este elemento y ha procurado tenerlo siempre a su disposición. En este contexto, el suelo es la matriz que está a disposición de las plantas y en la cual ocurre ese intercambio natural, así como el escenario donde se mantiene, o no, el caudal base en una cuenca (Martínez, 2008).

Así, la variación entre los periodos de lluvias y sequias obliga a la planeación y control del uso del recurso en la agricultura, la industria, y el consumo humano por medio de los acueductos tanto rurales como urbanos. Por tanto, conocer el contenido del agua en el suelo, y cómo esta se va agotando, está relacionado con las condiciones físicas del suelo, y de ahí la importancia de su estudio (Villar y Ferrer, 2005).

De este modo, la capacidad de retención de agua en el suelo determina la disponibilidad de este recurso para las plantas, el agua cedida para el caudal base en una cuenca, así como su comportamiento hidrodinámico, el transporte de solutos, el drenaje y la infiltración, entre otros (Walczack et al., 2006; Hernández, 2011). Esta retención está determinada por dos propiedades que presenta el suelo: la capacidad de campo y el punto de marchitez permanente, las cuales se establecen a partir de la curva de retención de humedad y, esta a su vez, guarda una estrecha relación con las características fisicoquímicas del suelo (Fredlund et al., 1994; Cousin et al., 2003; Chiristensen, 2005; Fredlund et al., 2007)

En Colombia, en este ámbito, algunos autores infieren que hay poca investigación sobre los aspectos hidrológicos, los cambios de uso del suelo y el cambio climático (Arroyave, 2007). Cualquier investigación en estos temas es de suma importancia para aumentar el

conocimiento del comportamiento de los bosques, el suelo y el ambiente en las zonas de las cordilleras.

No obstante, los estudios en estas zonas han sido difíciles dadas las condiciones que existen, pues se presenta gran variabilidad ambiental física y geográfica (Brujinzeell, 2001). Sin embargo, cuando se enfrentan estas dificultades y se logra adquirir información de los suelos, los bosques, los comportamientos climáticos o hidrológicos, aumenta el conocimiento en estas áreas de las cuales se tiene poca información.

En el país, la gran relevancia que reviste el conocimiento de los suelos, los bosques, el clima, los procesos hidrológicos, y los estudios de los ecosistemas en las zonas de montaña, es alimentar el conocimiento del comportamiento de estas variables y sus interacciones. A su vez, la producción de agua, la conservación de los suelos, la protección de la flora, y los servicios ecosistémicos que prestan, hacen que los estudios que se realicen sean de suma importancia, ya que se obtiene nueva información que contribuye al conocimiento del comportamiento de este recurso (Tobón, 2009; Brujinzeell, 2001)

Según todo lo anterior, el suelo es uno de los principales factores que inciden en la regulación del agua en una cuenca —y en las montañas andinas colombianas— con materiales derivados de cenizas volcánicas y alto contenido de materia orgánica (Cavelier, 1991; Tobón et al., 2004). Este contenido de materia orgánica y su origen volcánico le dan a los suelos de estas zonas unas propiedades físicas e hidráulicas especiales, junto con unas densidades aparentes bajas, alta porosidad, buena retención de agua, alta infiltración y conductividad hidráulica, lo cual les da una buena capacidad de regulación hídrica en las cuencas (Díaz-Granados et al., 2005; Osorio y Bahamon, 2008).

Estas condiciones de suelo hacen que se presenten bajas escorrentías superficiales, lo que permite que la porosidad, infiltración y conductividad regulen el flujo base de las quebradas y ríos en estas zonas (Lloret, 2000; Pacheco y Ataroff, 2002; Morales, 2008).

Para la estimación de las características anteriormente mencionadas (densidad aparente, capacidad de campo, punto de marchitez permanente, textura, entre otras) se han creado mecanismos para determinar estas propiedades, con base en los suelos o condiciones similares. También es posible inferir otras propiedades a partir de unos pocos datos, lo que implica un ahorro de tiempo y de recursos. A esto la literatura sobre suelos lo ha denominado funciones de edafotransferencia (Baker y Ellison, 2007; García y Medina, 2009)

En este ámbito, en zonas tropicales, se han reportado pocos estudios. Mientras que en varios países de Suramérica se han desarrollado algunas funciones de edafotransferencias enfocadas a suelos asociados al bosque húmedo tropical (Tomasella et al., 2000; Zimmermann y Basile, 2011), en la zona andina no se reporta ningún estudio de funciones de edafotransferencia. Esto, a pesar de ser una región relevante para Colombia, donde se aloja la mayor parte de la población que aprovecha su oferta ambiental para satisfacer los requerimientos de agua para el consumo humano, la agricultura, la industria, la recreación, y la generación de energía eléctrica, entre otros. Es por ello que se hace necesario el desarrollo de funciones de edafotransferencia que reflejen el comportamiento de la retención de agua en el suelo para la zona andina en Colombia. Las funciones de las que se dispone actualmente se han propuesto a partir de los datos de suelos procedentes de latitudes septentrionales, los cuales presentan características diferentes a los encontrados en la zona andina.

De acuerdo con lo anterior, esta investigación plantea evaluar el desempeño de las ecuaciones de edafotransferencia existentes —y desarrolladas para otras latitudes— en las condiciones ambientales de suelos de la región andina colombiana. Dicha evaluación se basó en la recolección de muestras de suelo de los departamentos de Quindío y Tolima, para determinar en laboratorio algunas propiedades tales como la textura, la curva de retención de humedad, la materia orgánica y la densidad aparente. Con los datos obtenidos, se comparó la predicción de los parámetros hidrodinámicos, mediante

la aplicación de ecuaciones establecidas, al realizar el cotejo de los datos obtenidos con los realmente determinados en campo.

Para una mayor precisión en la predicción de las propiedades hidráulicas de suelos andinos neotropicales, se plantearon nuevas ecuaciones de edafotransferencia, desarrolladas mediante la aplicación de redes neuronales artificiales y árboles altamente aleatorizados (*Extremely-(randomized)-Trees (ET)* o *Extra tres*). A su vez, además de las propiedades físicas del suelo, como la textura, la densidad aparente y el contenido de materia orgánica, entre otros, en los modelos de edafotransferencia desarrollados, se incluyeron variables cartográficas del terreno como pendiente, elevación, cobertura, curvatura y drenaje.

También se hizo la comparación de las variables relevantes mediante el modelo de árboles altamente aleatorizados (*extra trees*), donde se evidencia que la combinación de los datos de las propiedades físicas de los suelos —sumadas a las tomadas a partir de los modelos de elevación digital— permite generar modelos de predicción de los contenidos de agua en el suelo, y la densidad aparente, con una precisión alta comparado con los modelos utilizados actualmente.

Según este contexto, el problema de investigación se ha enmarcado en comparar los resultados de la predicción del contenido de agua en el suelo y la densidad aparente con las funciones de edafotransferencias ya establecidas, generadas principalmente de regresiones lineales, con variables sencillas como la textura del suelo, la densidad aparente y el contenido de materia orgánica. También se hace la comparación del desempeño de estas variables con una red neuronal, a la cual se le introducen nuevas variables extraídas de un modelo de elevación digital, tales como la pendiente, la elevación, la ubicación y la dirección de la escorrentía, al observar los errores medios y la raíz cuadrada del error cuadrático medio, para advertir si la predicción del contenido de agua en el suelo y la densidad aparente de este, es mejor que con los métodos ya establecidos.

De acuerdo con lo anterior, esta tesis doctoral aborda las siguientes preguntas de investigación:

1. ¿Cómo es la eficiencia de las funciones de edafotransferencia ya establecidas en trabajos anteriores, con respecto a los datos observados en los suelos estudiados en esta Investigación?
2. ¿Cuáles son las variables más relevantes de laboratorio y derivadas del modelo de elevación digital, para estimar el agua disponible (AW), el punto de marchitez permanente (WP), la capacidad de campo (FC) y la densidad aparente del suelo (DA), para el desarrollo de modelos de edafotransferencia basados en redes neuronales artificiales en suelos andinos neotropicales?
3. ¿Cómo es el desempeño de la red neuronal artificial, en relación con los datos obtenidos en laboratorio de la retención de humedad y la densidad aparente del suelo?
4. ¿Cuáles son las variables de laboratorio y derivadas del modelo de elevación digital para estimar el agua disponible (AW), el punto de marchitez permanente (WP), la capacidad de campo (FC) y la densidad aparente del suelo (DA) para el desarrollo de modelos de edafotransferencia basados en árboles altamente aleatorizados?
5. ¿Cómo es el desempeño de los modelos generados por los árboles altamente aleatorizados?

OBJETIVOS

Objetivo general

Este trabajo de investigación se centra en evaluar las funciones de edafotransferencia para estimar el agua disponible (AW), el punto de marchitez permanente (WP), la capacidad de campo (FC) y la densidad aparente del suelo (DA), en suelos andinos neotropicales de cuencas de montaña, mediante la utilización de algunos métodos estadísticos no paramétricos.

Objetivos específicos

Evaluar la capacidad de predicción de las siguientes variables: textura, densidad aparente y contenido de materia orgánica en las funciones de edafotransferencia propuestas por diferentes investigadores en suelos andinos neotropicales, con relación a la capacidad de campo (FC), el punto de marchitez permanente (WP) y el agua disponible (AW).

Establecer funciones de edafotransferencia específicas para los suelos estudiados, mediante redes neuronales artificiales y árboles altamente aleatorizados al involucrar variables hidrodinámicas del suelo, de la ubicación de los puntos, de la pendiente, la cobertura y el drenaje.

1. ESTADO DEL ARTE

1.1 PROPIEDADES HIDROFÍSICAS DEL SUELO

Las propiedades hidrofísicas de los suelos son las encargadas de llevar a través de este el aire, el calor, el agua, los nutrientes y su disposición para el uso de las plantas y los microorganismos. Estas propiedades pueden ser muy variables según las características del suelo como la textura, la cantidad de poros y la materia orgánica contenida, entre otras (Sánchez y Camacho, 1981).

Profundidad del suelo: esta propiedad es importante para el sustento de las plantas. Puede verse afectada por los efectos de la meteorización, la erosión o las intervenciones humanas. En su extensión, se pueden distinguir varias capas u horizontes, las cuales pueden variar en su composición en la fracción mineral, la facilidad del paso del aire, agua y nutrientes, así como el contenido de fragmentos de rocas de diferentes tamaños. La profundidad que representa la medida vertical en metros de todos los horizontes varía en su magnitud, según sea el desarrollo del suelo. En las zonas del Quindío y Tolima se encuentran Inceptisoles, Andisoles y Entisoles que son considerados poco a medianamente evolucionados, con contenido de materiales volcánicos y materia orgánica. Para los Inceptisoles, su profundidad varía entre uno y dos metros (IGAC, 2006), en el caso de los Andisoles, su espesor está entre 1 y 1,8 m (Jaramillo, 2000) y para los Entisoles esta profundidad se encuentra entre 1 y 2 m (Malagón, 2003).

Estructura del suelo: esta se refiere al tamaño, la forma y la acomodación de las partículas principales que con su agregación pueden formar partículas compuestas. Dichas partículas permiten el movimiento del agua y del aire en el suelo a diferentes velocidades.

La estructura está ligada con la estabilidad de estas partículas. Así, las de mayor magnitud, tienen contenidos altos de arcilla que agrega y mantiene unidas estas estructuras al resistir al desgaste mecánico.

Otros factores que intervienen son el contenido de materia orgánica y demás minerales como los óxidos de hierro, sílice y aluminio, los cuales forman partículas que alcanzan los dos milímetros con alta estabilidad y que pueden pasar por texturas gruesas (Escobar et al., 1972).

Retención de agua en el suelo: es el contenido del agua en el suelo a una determinada succión o su disponibilidad para las plantas. Este contenido se ha establecido con algunos límites; de este modo, con una tensión de succión de -33 kPa se estableció como capacidad de campo. Es el suelo saturado, pero donde el agua libre ha sido removida por efecto de la gravedad, las plantas pueden tomar el agua con muy poco esfuerzo o gasto energético. El otro límite es el punto de marchitez permanente con -1500 kPa de succión, en este estado del suelo no hay agua disponible para las plantas.

La textura: a la proporción de los elementos minerales del suelo —expresado como arenas, limos y arcillas— se le denomina la textura del suelo, y es una de las propiedades más destacadas. Un suelo puede tener una buena textura cuando los elementos que la constituyen le dan una buena fijación a las plantas y hay alimento disponible para ellas. Si bien, la textura se ve reflejada por la influencia de la naturaleza y la roca madre le puede dar su característica principal, según sean los procesos evolutivos del suelo, las migraciones de los elementos y la acumulación de la materia orgánica pueden variar sus proporciones.

En cuanto a la clasificación del suelo, de acuerdo con el tamaño de las partículas constitutivas, está orientada hacia la mayor proporción que se tenga. Así, un suelo puede ser arenoso, limoso o arcilloso, o la combinación de las fracciones minerales.

Con respecto a las fracciones gruesas del suelo, que pueden ser las gravas y arenas — sin la compañía de los otros elementos— presentan baja o nula plasticidad, así como resistencia a su deformación. De igual forma, la capacidad de retención de agua es muy baja, pues se presentan grandes poros por la acomodación de las partículas, donde actúa la gravedad y el agua pasa rápidamente.

Con relación a la fracción intermedia, que la ocupan los limos, son principalmente cuarzos de tamaño microscópico. Estos pueden tener algún grado de plasticidad, cohesión y absorción aunado a las partículas de arcillas que tienen adheridas.

Por último, la parte fina está compuesta por las arcillas, en general, de estructura laminar y en presencia de agua son muy plásticas. Estas se pueden expandir y se vuelven pegajosas, lo cual le otorga al suelo la lentitud en el movimiento del agua y el aire; sin embargo, un suelo de textura fina puede tener buen drenaje y aireación si su estructura es buena, junto con las otras fracciones minerales (Rucks et al., 2004; USDA, 2014).

La densidad: es una propiedad del suelo muy relacionada con la textura, la porosidad y la estructura. Se presenta como dos conceptos relacionados con respecto al suelo. En primer lugar, la densidad aparente es la relación entre el peso seco de la muestra de suelo y el volumen que esta ocupa. En esta relación se tienen en cuenta tanto las fracciones de la textura o los sólidos y los poros que se tengan dentro de ella.

De esta forma, la densidad aparente se determina a partir de las muestras tomadas en el sitio de interés, con las muestras no disturbadas. Esta medida se hace con el suelo seco, generalmente al dejarlo por 24 horas en un horno a 105 °C. Con estas muestras se obtiene el peso de los sólidos y el volumen de la muestra, que generalmente está representada por un anillo metálico (Flores y Alcalá, 2010).

En segundo lugar, la determinación de la densidad real se determina como la relación entre todos los sólidos que componen la muestra y el volumen que ocupan estos. Esta propiedad puede variar de acuerdo con la proporción de los elementos que la componen.

Así, con minerales como el cuarzo o el feldespato, ésta puede estar por el orden de los $2,6 \text{ g/cm}^3$ y, cuando la influencia de la materia orgánica es alta, esta característica puede tomar valores cercanos a los $1,5 \text{ g/cm}^3$.

La porosidad: los poros en el suelo juegan un papel muy importante, ya que de ellos dependen muchos fenómenos tales como el transporte del aire y los nutrientes, el paso del agua y el desarrollo de las plantas. Estos espacios del suelo no ocupados por los sólidos se dividen en macroporos y microporos. Los macroporos representan el drenaje del suelo, pues no retienen el agua, al igual que por ellos circula el aire y es donde crecen las raíces.

Los microporos son los que retienen el agua y permiten que esta esté disponible para el uso de las plantas. La suma de los macro y microporos representan la parte de los espacios del suelo y están estrechamente relacionados con la estructura y la textura del suelo. Cuando en el suelo predominan las arcillas, la mayor parte de la porosidad está en los microporos; por el contrario, si la fracción gruesa es la que impera, la mayor cantidad es de macroporos (Rucks et al., 2004; USDA, 2014).

Materia orgánica: es un elemento que se encuentra en el suelo e interviene en diferentes procesos. Dicha materia produce cementación en el suelo, lo cual ocasiona la agregación de las partículas y ayuda a la formación de la estructura junto con las arcillas. El contenido de la materia orgánica influye en los microorganismos, pues estos ayudan a su transformación y estabilización. A su vez, interviene en la estabilidad de los agregados, ya que es más alta en presencia de materia orgánica.

En cuanto al contenido de agua, este puede variar en el suelo por su presencia o no, dado que al disminuir la cantidad de esta en un suelo, su capacidad de retención de agua disminuye; por el contrario, al adicionarla, la capacidad del suelo de retener el agua aumenta (Rucks et al., 2004).

El color del suelo: es una característica fácil de observar y puede identificar un tipo de suelo en un área determinada. El color generalmente proviene del origen de las rocas o por los procesos de formación. El color no es relevante para la clasificación de los suelos, pues su coloración o matices pueden ocurrir por fenómenos diferentes.

Las principales sustancias que le proveen color al suelo son el humus, los óxidos, los sulfuros y los carbonatos, entre otros. En general, los colores oscuros son generados por el humus, el bióxido de manganeso o los sulfuros de hierro. El color claro se puede derivar de minerales claros o incoloros (IGAC, 2003; Rucks et al., 2004; USDA, 2014).

1.2 TIPOS DE SUELOS MUESTREADOS

En relación con los suelos dominantes en la zona de estudio, estos son de los órdenes Inceptisol, Andisol y Entisol. A continuación se describe cada uno de ellos.

Inceptisol: de acuerdo con su etimología latina, su nombre proviene de la palabra incipiente, del comienzo, cuando se empiezan a desarrollar. Dentro de sus perfiles se pueden encontrar horizontes poco evolucionados, donde los horizontes pueden estar mezclados con rápida formación y pueden tener meteorización externa.

En la zona de estudio, este tipo de suelos está presente en diversos climas, desde los páramos hasta los valles de los ríos que descienden de estos. Su régimen de humedad es variable; sin embargo, estos presentan en particular un buen drenaje, el cual se puede ver favorecido cuando ocurren en pendientes fuertes. La presencia de vegetación es siempre recurrente en este tipo de suelos, desde las laderas hasta los depósitos coluviales donde los sedimentos son depositados. En las zonas en las cuales la pendiente es alta, la erosión junto con la gravedad elimina continuamente la parte superficial.

Una característica especial de este tipo de suelos es que pueden presentar uno o más horizontes en los primeros 50 cm de profundidad, por debajo del horizonte mineral, y contener bajos niveles de arcillas.

En cuanto a la vegetación, estos pueden soportar bien los ecosistemas de bosques, cultivos y pastos en presencia de humedad suficiente para mantener las plantas. En zonas con alguna pendiente, la pérdida de la vegetación lleva rápidamente a la erosión (Ibañez et al., 2011c).

Andisol: estos suelos son denominados así por el sistema de clasificación taxonómica dado su origen volcánico. Solo se encuentran en zonas con volcanes donde la presencia de material piroclástico es redundante y es el material parental. En este entorno, se da algún grado de desarrollo, donde sus componentes provienen de los volcanes en sus diferentes erupciones.

Después de la erupción se presenta un rápido enfriamiento de los materiales arrojados por el volcán. Este enfriamiento no permite la formación de cristales de los minerales contenidos, lo cual da como resultado un material vítreo amorfo. Pueden ser poco alterados o muy meteorizados, pero siempre con gran cantidad de vidrio volcánico. Esta una de las principales características para su clasificación.

Su evolución está condicionada por los entornos ambientales reinantes. En la zona tropical, estos han tenido una evolución mucho más rápida. El material parental es el que caracteriza el perfil de suelo, pues depende de la naturaleza de este para generar los diferentes horizontes. En general, este material expulsado posee grandes contenidos de aluminio y silicio presente en el vidrio volcánico.

A su vez, el clima es un gran formador de este tipo de suelos, donde la lluvia ha permitido el desarrollo de la vegetación que, junto con la percolación de esta en el suelo, han formado los horizontes bien diferenciados. Asimismo, junto con la temperatura, la cual acelera o retarda las reacciones químicas, se van formando los horizontes.

Es así como la percolación vertical va sumando elementos minerales en el perfil del suelo, donde se producen translocaciones entre los horizontes. De este modo, se puede producir la silización en un horizonte en detrimento de otro, que será desilizado por el movimiento del sílice, como ejemplo en este caso; pero también puede haber migración de otros componentes como calcio o dolomita.

Generalmente, en la parte superior de este, se presenta un color oscuro o melanización debido a la acumulación de humus, hierro y aluminio. Estos son poco solubles y se acumulan en la superficie y dan este resultado con frecuencia en presencia de la vegetación. Esto puede dar lugar a la mineralización de la materia orgánica y la humificación.

Dado que estos suelos poseen buenas propiedades minerales y contenidos de materia orgánica —en especial— son propicios para la producción agrícola de frutales o cultivos de café. Si su ubicación está en zonas de pendiente fuerte, estos son susceptibles de degradarse, sumado a su baja densidad con fácil mecanización (Ibañez et al., 2011a).

Entisol: son los suelos más jóvenes y recurrentes en el mundo de acuerdo con la taxonomía de suelos. En cuanto al desarrollo de los horizontes, estos son incipientes o nulos, por lo tanto sus propiedades son derivadas de los materiales originales. A su vez, se han desarrollado sobre el material parental el cual no está consolidado, por lo que se puede identificar un horizonte A y en profundidad solo el horizonte C o los elementos originales formadores.

Su poco desarrollo se puede deber a varios factores, entre otros, al tiempo corto para su formación, al tener materiales de difícil alteración como cuarzos o minerales primarios que el ambiente poco puede atacar, y al depósito de materiales nuevos como los transportados por los ríos que continuamente los están renovando.

Cuando estos suelos están sometidos a saturación continua, entonces puede suceder que algunos minerales como el hierro y el manganeso sean solubles y tiendan a colorearse de gris a azulados. Por lo anterior, estos pueden generar moteados de colores intensos como negros, rojos o amarillos. Debido a que solo es posible distinguir el horizonte superior a causa de la acumulación de materia orgánica, estos pueden presentar melanización con colores oscuros (Ibañez et al., 2011b).

1.3 MÉTODOS DE LABORATORIO PARA DETERMINAR LAS PROPIEDADES FÍSICAS DEL SUELO

1.3.1 El agua disponible para las plantas en el suelo. Esta característica se puede determinar a partir de diversas propiedades, según sea la masa o el volumen del agua y suelo. De esta forma, la humedad gravimétrica se expresa como el porcentaje de masa de agua contenida por unidad de masa de los sólidos del suelo.

En cuanto al porcentaje en humedad gravimétrica, este resulta de la diferencia de la masa entre el suelo húmedo y el secado al horno a 105 °C (durante 24 horas), dividido entre la masa del suelo seco. El secado al horno debe extraer el agua hasta que su masa sea constante; por lo tanto, no se retira el agua químicamente ligada a las fracciones del suelo. Posteriormente, con este suelo seco, se pueden determinar varias propiedades del suelo, tales como la capacidad de intercambio catiónico y la materia orgánica, entre otros (U.S. Department of Agriculture, Natural Resources Conservation Service (2014).

Así, la humedad del suelo influye en varias propiedades físicas del suelo tales como densidad aparente, macroporos, compactación, resistencia al corte, consistencia, color del suelo y el agua que puede absorber. Por lo anterior, es relevante esta determinación para saber cuáles son las condiciones de varias de las propiedades del suelo.

Dicha humedad varía constantemente y se ve influenciada por la lluvia, la cobertura, la profundidad del suelo, las características y las condiciones físicas en el momento de la toma de la muestra.

En cuanto a la humedad volumétrica, expresa la relación entre el volumen del agua en el suelo y el volumen total del suelo. Al multiplicarlo por cien indica el porcentaje en este contenido. También, se puede expresar como la lámina de agua contenida en un determinado espesor de suelo, en relación con la lluvia caída en una zona o el riego aplicado (Forsythe, 1975).

Retención de humedad:

Dado que las humedades descritas anteriormente se determinan a partir del contenido de agua que tenga el suelo en un momento dado, es necesario determinar la humedad asociada a diferentes presiones de succión del suelo. Esto se puede lograr al utilizar ollas de presión y platos de cerámica porosos —según diferentes tensiones de succión— que simulan las condiciones del suelo y el agotamiento del agua por la absorción de las plantas.

Así, las muestras de suelo no disturbadas se saturan durante 24 horas junto con los platos porosos. Después de este tiempo se deja que el exceso de agua drene por acción de la gravedad, se pesan y se meten en las ollas de presión a las diferentes tensiones de succión. Comúnmente, los investigadores calculan las curvas de retención de humedad del suelo con base en el cálculo de la humedad a un tercio de bar (-33 kPa), medio bar (-50 kPa), un bar (-100 kPa), cinco bares (-500 kPa) y quince bares (-1500 kPa) de tensión de succión.

Con estos puntos, se calcula una curva continua que representa el comportamiento del suelo en la retención del agua. Es de aclarar que para cada tensión se utiliza un plato diferente. Luego, en cada cambio de presión de succión, se pesan las muestras y al final se secan en un horno a 105 °C por 24 horas, para determinar cuál es su densidad aparente.

Cada prueba de succión puede durar semanas, pues este proceso se sigue hasta que las muestras alojadas en la cámara de presión ya no drenen más agua. Según sea la

textura de las muestras y su contenido de materia orgánica, el agua puede durar mayor tiempo en ser desalojada (Calle y Proaño, 2006).

1.3.2. Determinación de la densidad real. Esta propiedad del suelo se puede determinar de varias maneras. En una de ellas, la densidad de las partículas de suelo se puede calcular con el uso del agua. Para esto, se toma una muestra de suelo secada al horno y se hierve con agua en un frasco volumétrico; luego, se enfría y se completa con agua destilada hasta su volumen aforado. Lo anterior se hace con el fin de eliminar las burbujas de aire atrapadas en la muestra de suelo. En cuanto a la temperatura del agua, esta debe ser precisa, pues está relacionada con su densidad y, a partir de ella, se puede calcular la densidad de las partículas que conforman el suelo. Con respecto a las densidades mayores, estas están relacionadas con la composición principal de las arenas y varía con la proporción de los otros componentes como los limos y las arcillas (Forsythe, 1975).

En otro método alternativo, se usa aceite combustible para su determinación y tiene la particularidad que no tiene afinidad con las arcillas, a diferencia de los métodos basados en el uso de agua. Por lo tanto, este método es mucho más preciso para suelos pesados con altos contenido de arcillas.

Actualmente se usan métodos más sencillos como el del picnómetro, el cual incluye un recipiente perfectamente aforado. Para ello, se introduce la muestra de suelo secada al horno con una masa conocida, luego se llena con agua destilada y se pesa todo el conjunto; de esta forma, se puede obtener la densidad real. A un picnómetro aforado de 25 mililitros se le adicionan 10 gramos de suelo previamente pesado. Con anterioridad, este suelo ha sido tamizado y solo se han dejado las partículas que pasan por el tamiz de abertura de 2 milímetros.

Así, este conjunto se pesa y se le adiciona agua destilada hasta la mitad de la altura, luego, se procede a agitar suavemente para permitir la salida de las burbujas de aire que

hayan podido quedar atrapadas. Si es necesario, se puede someter a una cámara de vacío por treinta minutos.

Posterior a esto, se llena totalmente el picnómetro, se tapa y se seca para pesar todo el grupo de elementos. Esta medida se compara con el picnómetro lleno de agua pura destilada. Por último, los cálculos a realizar se expresan en unidades de peso en el volumen de suelo.

$$R_p = \frac{R_w (W_s - W_a)}{[(W_s - W_a) - (W_{sw} - W_w)]}$$

Ecuación 1: Densidad aparente del suelo

Donde:

R_p = Densidad real de las partículas del suelo (mg / m^3)

R_w = Densidad del agua (g / cm^3) a la temperatura medida

W_s = Peso del picnómetro con la muestra de suelo secada a 105°C

W_a = Peso del picnómetro vacío

W_{sw} = Peso del picnómetro en conjunto (suelo y agua)

W_w = Peso del picnómetro lleno de agua destilada a la temperatura medida

1.3.3 Densidad aparente. Esta densidad es la relación entre la masa de suelo secada al horno y el volumen del suelo no disturbado (es decir, como se tomó en el sitio de muestreo). Este parámetro sirve para calcular: i. la lámina de agua del suelo, ii. la porosidad total, junto a la densidad de las partículas constitutivas del suelo, y iii. la compactación junto con la porosidad, entre otras características.

Para su determinación, se utilizan anillos metálicos biselados, los cuales se introducen en el suelo para extraer una muestra de suelo en las condiciones en las cuales se encuentra naturalmente. Con esta muestra, en el laboratorio se toman las medidas reales del anillo para encontrar el volumen real, y se someten a secado por 24 horas a

105 °C; luego de este tiempo, se pesan y de estos valores se obtiene la densidad aparente.

Con el método del terrón parafinado, se puede utilizar una muestra de suelo no disturbado de la cual se extrae un terrón. Este último se ata con una cuerda, se sumerge en parafina líquida varias veces hasta que alcanza una capa lo suficiente para impermeabilizar la muestra. Con este terrón se determina su desplazamiento al sumergirlo en agua, lo cual permite hallar el volumen. Posteriormente, hay que determinar el agua disponible que tiene la muestra inicial para restarla del peso final por medio del secado a 105 °C por 24 horas.

1.3.4 Determinación del carbono orgánico. La mayoría de los métodos para hallar el valor del carbono orgánico se basan en la oxidación húmeda. Para ello, se genera una reacción química con dicromato de potasio y ácido sulfúrico. Con el ácido crómico se puede medir colorimétricamente a cierta longitud de onda. Dado que esta oxidación no es completa, (aproximadamente el 76 %), es necesario hacerle una corrección.

Cuando no se hace por espectrofotometría, las muestras se titulan diluidas en agua destilada, y se comparan con un blanco o con una reacción que no contiene suelo. Con esto, se puede determinar el viraje o cambio de color ante un indicador y se calcula el carbón orgánico contenido en la muestra del suelo.

En cuanto a todos los análisis de laboratorio, estos se ajustan a los procedimientos establecidos y estandarizados para que los resultados sean fidedignos. Los resultados mencionados son fieles a las características que tiene el suelo. Por lo anterior, estos son preferibles a los datos obtenidos por métodos indirectos; sin embargo, debido al costo y al tiempo que se invierte en la obtención de las propiedades de un suelo, las funciones de edafotransferencia permiten calcular dichos datos en un corto tiempo y con una mínima inversión de dinero.

1.4 CARACTERÍSTICAS DE LAS PRINCIPALES VARIABLES HIDRODINÁMICAS DEL SUELO

Las variables hidrodinámicas se refieren al movimiento y al almacenamiento del agua en el suelo. Esto es importante porque representa la cantidad que puede estar disponible para las plantas y la almacenada que se puede ceder como caudal base en una cuenca. El agua es retenida en el suelo por varios mecanismos, y las propiedades químicas hacen su trabajo mediante los puentes de hidrógeno y la bipolaridad, lo cual permite que sus moléculas se adhieran a las superficies que la rodean (Wang, 2005).

En este contexto, las partículas del suelo forman canales, llamados poros, donde se forman películas de agua que se adhieren a estas superficies; no obstante, la cantidad de agua que se puede retener depende del tipo de suelo, de los poros en él, de la compactación, y de la distribución de las partículas minerales (Taiz y Zeiger, 2002). En el caso de los suelos con partículas dominadas por arcillas hay gran cantidad de microporos que retienen fuertemente el agua; mientras que en un suelo con mayor cantidad de arenas predominan los macroporos, donde el agua permanece a medida que es alimentada por el riego o la lluvia. Cuando esta condición cesa, la gravedad hace que esta agua sea drenada (Lambers et al., 1997).

Capacidad de campo: esta propiedad del suelo está determinada como el contenido de agua que puede retener el suelo después de ser saturado y drenado por gravedad. Como medida estándar, se ha tomado como el agua que queda retenida después de hacer una succión de 0,3 bares (Lambers et al., 1997; Mariño, 2006).

En cuanto al agua en el suelo, esta se encuentra en los poros y, dentro de estos, se puede distinguir la capilar (presente en los capilares). Dichos capilares varían su diámetro entre 0,2 y 8 micras, donde se aloja el agua absorbible y la no absorbible en los poros menores a esta cifra. También se puede contar con el agua higroscópica que es una película muy delgada adherida a las partículas del suelo y que no está disponible para las plantas (Dorronsoro, 2005).

Asimismo, el contenido de agua puede variar según sea la textura del suelo. En suelos arcillosos con altos contenidos de materia orgánica, o la combinación de estos dos factores, el contenido puede que sea mayor en comparación con un suelo mineral que alcanza retenciones de hasta el 60 %; mientras, en suelos arenosos, alcanza el 50 % como máximo y en los arcillosos sobrepasa el 50 % (Mariño, 2006).

Punto de marchitez permanente: se define como el contenido de agua en el suelo donde las plantas no pueden extraer el agua de este; por tanto, las hojas de las plantas ya no recobran su turgencia. Para la mayoría de las plantas este punto está limitado a 15 bares de succión de agua en el suelo; no obstante, existen plantas que pueden extraer el agua del suelo por debajo de este valor (Singer y Munns, 1999; Mariño, 2006).

Agua disponible: se puede definir de manera sencilla como el intervalo de humedad volumétrica entre la capacidad de campo y el punto de marchitez permanente. Sin embargo, puede haber diferencias en su evaluación entre las mediciones que se realizan en laboratorio y los fenómenos que realmente se suceden en campo (Ratliff et al., 1983; Vanderlinden et al., 2003).

Estas diferencias ocurren según sea la forma como se determinan estos valores. Así, el uso de las muestras de suelo disturbadas no refleja los fenómenos, la ordenación de las partículas, ni los poros o gravas que presenta el medio en el sitio real.

En algunos modelos, como en el de Milly (1994), el suelo es un depósito o un tanque en el cual se almacena el agua (la que está disponible), con una capacidad de almacenamiento definida, gracias a la lluvia que cae en determinada región y que varía en su almacenamiento debido a la evapotranspiración. Así, cuando el volumen almacenado se llena, se produce la escorrentía.

Densidad aparente: es una propiedad relevante del suelo y relaciona su masa con el volumen que presenta el suelo en condición natural. Al aumentar su valor se perturba la

retención de agua debido a la compactación que presenta el suelo, la cual termina afectando el desarrollo de las plantas (Salamanca y Sadeghian, 2005).

La densidad aparente está estrechamente relacionada con las partículas constitutivas del suelo, en particular, las arenas, los limos y las arcillas, la materia orgánica y la distribución de los poros en el suelo.

La densidad aparente varía considerablemente según sean los contenidos de materia orgánica donde esta se acumula y, si no hay intervenciones, se pueden observar valores de $0,5 \text{ g/cm}^3$, según lo reportan Salamanca y Sadeghian (2005). Esta variable puede explicar su comportamiento en relación con el contenido de agua disponible a capacidad de campo, su distribución de partículas y el contenido de materia orgánica (Heuscher et al., 2005; Salamanca y Sadeghian, 2005).

1.5 DESARROLLO DE NUEVAS FUNCIONES DE EDAFOTRANSFERENCIA

El desarrollo de nuevas funciones es complejo, pues se requiere de lo siguiente: i. los datos base para la propuesta de estas, ii. un análisis estadístico concienzudo, iii. la calibración y iv. la prueba de la efectividad de la nueva función. Por lo anterior, algunos autores recomiendan empezar por funciones ya existentes y determinar su efectividad o exactitud en la determinación de las variables (Minasny et al., 2003; Nemes, 2003; Martínez, 2008).

Sin embargo, las funciones ya establecidas tienen la limitante que no pueden extrapolarse más allá de los límites para los cuales su autor no las haya investigado. En este contexto, algunos modelos permiten alimentar su base de datos a partir de los valores de las muestras analizadas en otros lugares, según los nuevos registros; sin embargo, hay que calibrar y probar el modelo para ver qué tan efectivo es, pues gran parte de las funciones se han propuesto desde latitudes templadas (Nemes et al. 2003). Otra causa a considerar en el uso de funciones establecidas es el desconocimiento que se tienen en cuanto a las causas de los errores o diferencias entre las múltiples

funciones; así como la diferencia entre los algoritmos desarrollados o las diferencias entre las predicciones que se observan en una u otra función propuesta.

1.6 FUNCIONES DE EDAFOTRANSFERENCIA

1.6.1 Métodos para hallar funciones de edafotransferencia. En cuanto a las propiedades hídricas del suelo no siempre es posible hallarlas directamente en campo o en el laboratorio. Esto se puede deber a las diversas metodologías que se pueden emplear y que presentan inconvenientes como el alto costo, excesivo tiempo para la adquisición de las muestras y la toma de estas cuando implican mucha dificultad.

Por lo anterior, se han hecho diversas investigaciones dirigidas en la búsqueda de nuevos métodos estimativos y predictivos. De esta forma, se pueden estimar algunas propiedades a partir de otras que son fáciles de conseguir o estimar, no necesariamente dirigiéndose hasta el sitio especificado. Estos métodos han sido denominados como funciones de edafotransferencia donde muchas de estas han sido sistematizadas por sus autores o han sido publicadas las ecuaciones encontradas para que sean usadas por otros usuarios.

Debido a la necesidad de tener datos sobre las propiedades hídricas de los suelos, con el fin de alimentar los modelos desarrollados previamente (como los hidrológicos) se han adelantado estudios específicos. De este modo, los modelos que tienen una base sólida estadística para determinar variables de difícil estimación —a partir de variables de fácil consecución— son llamadas funciones de edafotransferencia. Estas últimas se obtienen a partir de técnicas de regresión, donde se relacionan propiedades físicas básicas del suelo junto con las propiedades hidráulicas. Es así como estas reflejan el comportamiento hidráulico de los suelos. Para lo anterior, las funciones de edafotransferencia tienen una alta precisión y fiabilidad de los atributos del suelo, que no son fáciles de determinar en laboratorio (Martínez et al., 2004; Villar y Ferrer, 2005).

1.6.2 Clasificación de las funciones de edafotransferencia. De acuerdo con los modelos utilizados son los siguientes:

- i. Modelos basados en ecuaciones de regresión, los cuales pueden ser de tres tipos (de regresión lineal múltiple, de regresión no lineal extendida y las redes neuronales).
- ii. Modelos de simulación: de acuerdo con el tipo de predicción que se realice a partir de las funciones de edafotransferencia.
- iii. Los que predicen las propiedades hidrodinámicas a partir de otros modelos basados en las propiedades del suelo.
- iv. Los que predicen determinados valores de la curva característica de humedad.
- v. Los que predicen los parámetros que permiten construir de forma completa la relación entre la humedad volumétrica y el potencial matricial.

De acuerdo con el tipo de información que usa:

- i. Funciones de edafotransferencia básicas.
- ii. Funciones de edafotransferencia de clase: predicen ciertas propiedades de los suelos con base en la textura. Además, tienen en cuenta las fracciones minerales del suelo como la arena, el limo y la arcilla, y adicionalmente, también se pueden involucrar datos adicionales como el contenido de la materia orgánica.
- iii. Funciones de edafotransferencia continuas: predicen algunas propiedades de los suelos como función continua de las variables que se han encontrado; esta se complementa con datos tales como la descripción del perfil, el tipo de suelo y su clase.

De acuerdo con el desarrollo de la función de edafotransferencia:

- i. Totalmente empíricos: se hacen relaciones entre las variables predictoras y las estimadas al usar un análisis de regresión o modelos matemáticos.

- ii. Físicos empíricos: además de las relaciones, las propiedades de los suelos son calculados mediante principios físicos.

De acuerdo con el tipo de datos que se quiere predecir:

- i. Funciones de edafotransferencia por puntos simples, que predicen una propiedad del suelo.
- ii. Funciones de edafotransferencia paramétricas, al calcular los parámetros de un modelo (variable dependiente en una función de la variable independiente). Este tipo es mucho más aceptado, pues es una función continua y puede representar todo el fenómeno, como la retención de agua en el suelo (Pineda y Vilorio, 1992; Minasny et al., 1999; Rubio y Loorenz, 2003; Martínez, 2008).
- iii.

1.7 TÉCNICAS DE DESARROLLO DE NUEVAS FUNCIONES DE EDAFOTRANSFERENCIA

Para la obtención de funciones de edafotransferencia se han empleado diversas técnicas, entre ellas, las de regresión lineal y correlaciones estadísticas. Sin embargo, recientemente se han propuesto técnicas de análisis con redes neuronales. En este ámbito y procedimientos han trabajado muchos investigadores, lo cual avala dicha técnica; además, estos han mostrado mejor desempeño con respecto a las regresiones utilizadas.

Dado que la relación entre las diferentes variables del suelo es compleja, las redes neuronales tienen la ventaja de simular el comportamiento de un sistema complejo, al variar la influencia de los componentes de la red —llamados pesos— en la conexión entre las diferentes partes de la red.

Una red neuronal puede ejecutar una función particular, donde se generan unas entradas que producen unos pesos que se van modificando en las etapas de aprendizaje. En cuanto a su ventaja es que no está parametrizada; por ende, la red se entrena con los datos de entrada, para especificar una salida objetivo con un aprendizaje supervisado. El resultado final es que la red neuronal extrae al máximo la cantidad de información de los datos.

Otra técnica de uso reciente es el manejo de datos en grupo —y los árboles de regresión— que pueden usarse para agrupar los datos con el fin de descubrir cómo es su estructura. Lo anterior, se hace al agrupar los datos en conjuntos homogéneos; luego, a cada conjunto se le asigna una función la cual se compara con la función general o de todos los datos.

Con el uso algoritmos —como el del vecino más cercano (K-NN)— también se han tratado de encontrar funciones de edafotransferencia. De este modo, con este algoritmo de funciones similares se puede procesar la información, cuando se desconocen las relaciones entre las variables analizadas. Como resultado, se han probado que tienen mucha mejor aproximación al comportamiento real de las variables hidrodinámicas del suelo, con respecto a las redes neuronales. Además, tienen otra ventaja: su fácil manejo y almacenamiento de datos para futuras comparaciones o complemento de los mismos (Nemes et al., 2006; Patil y Chaturvedi, 2012).

Con respecto a los desarrollos de las funciones de edafotransferencia, muchos se han realizado para colecciones de datos de suelos de diversas áreas, propiedades hidrodinámicas y numerosos tipos de suelos en diferentes latitudes. Luego, las diferentes funciones se comparan con algunas técnicas y se sigue la que mejor se ajuste, o con la cual se obtenga el menor error; sin embargo, esto representa la media de todos estos datos. Por lo anterior, muchas veces, es mejor tener un número reducido de datos colectados en una región determinada, que una gran cantidad de datos generales de grandes regiones (Nemes et al., 2002).

1.8 PROPIEDADES DEL SUELO USADOS COMO PREDICTORES

Desde los inicios del planteamiento de las funciones de edafotransferencia, siempre se ha utilizado la textura como variable predictora (arena, limo y arcilla) sin importar el sistema de clasificación. Esta se ha usado para predecir la conductividad hidráulica y otras propiedades hidrodinámicas del suelo, tales como los contenidos de humedad a diferentes presiones de succión (Jaynes y Tyler, 1984; Saxton et al., 1986).

A modo general, sin hacer una revisión rigurosa de las funciones desarrolladas por los investigadores, la gran mayoría usan las ecuaciones y procedimientos similares a los propuestos por Brooks y Corey (1966) y Van Genuchten (1980). En estos, la arcilla es una variable utilizada como variable de entrada en todas las funciones. A su vez, el contenido de arena y limo son usadas como variables predictivas, junto con la localización del área. En cuanto al contenido de carbono orgánico, este se usa poco debido a que no todos los suelos tienen altos contenidos de materia orgánica. Con relación a la densidad aparente, esta también se usa como variable predictiva, y se ha reportado que al incluirla —y comparar los resultados sin esta— hay mejora en la predicción (Patil y Singh, 2016).

Además de lo anterior, otras variables que se han utilizado como datos de entrada son las siguientes: i. la retención de agua, ii. la capacidad de campo, iii. el punto de marchitez permanente, iv. el coeficiente de extensión lineal, v. el contenido de carbonato de calcio, y vi. la capacidad de intercambio catiónico en suelos arcillosos. Sin embargo, es de observar que el uso excesivo de variables hace que las funciones no sean prácticas, pues en muchas ocasiones no se dispone de toda esta información. Es por lo ya mencionado que los investigadores han creado los *software* que permiten trabajar con un número reducido de variables, y así obtener algún resultado que sea útil para el usuario (Botula et al., 2012).

1.9 SOFTWARE DISPONIBLE E INVESTIGACIONES CON USO DE FUNCIONES DE EDAFOTRANSFERENCIA

El uso de un *software* está sujeto a las variables de entrada disponibles y a la respuesta que se espera obtener. Antes de ser utilizado en una zona específica, es necesario observar su precisión, pues estos han sido calibrados para zonas y suelos concretos, con características determinadas que pueden arrojar resultados erróneos o no esperados por el usuario. Algunos de los *software* más conocidos son SOILPAR, Rosetta y RETC.

A partir de investigaciones científicas, estos se han probado y son confiables siempre y cuando se usen dentro de sus límites y con los rangos especificados (Schaap et al., 2001; Acutis y Donatelli, 2003).

En lo que respecta a algunos de los programas informáticos propuestos para el cálculo de los parámetros hidrodinámicos del suelo, Acutis y Donatelli en el año 2003, lanzaron SOILPAR 2.0. Esta herramienta permite calcular, entre otras variables, la capacidad de campo, el punto de marchitez permanente, la densidad aparente, el contenido de agua en el suelo a diferentes succiones y la conductividad hidráulica saturada. Para ello, los autores tomaron las ecuaciones propuestas por otros investigadores; de este modo, con el ingreso de los datos básicos (la textura, el carbono orgánico y, en algunos casos, la densidad aparente), se obtienen las otras variables hidrodinámicas del suelo.

Si bien, este *software* es amigable y fácil de manejar, presenta el inconveniente de que las bases de datos fueron tomadas para latitudes templadas; por tanto, se observa que para una misma característica de suelo, según el autor, se ven diversos resultados. En consecuencia, sería necesario alimentar las características de los suelos que manejan —junto con los resultados de otros sitios— y, de esta forma, ajustar las ecuaciones. Por ejemplo, en los suelos ecuatoriales es necesario realizarlo con sus variables respectivas ajustadas, para así obtener resultados más precisos.

En este ámbito, Van Genuchten (1980) había propuesto otras ecuaciones mucho más elaboradas para el cálculo de la retención de agua en el suelo. Inicialmente, se usaba, para el cálculo del desplazamiento del agua en el suelo, un tubo recto y homogéneo. Posteriormente, con las ecuaciones de Darcy y Pouseouille, se hicieron una serie de mediciones de laboratorio, de las cuales se dedujeron las ecuaciones modernas para el tamaño de poros, y que resultan mucho más precisas para la determinación de la humedad del suelo.

A través del estudio de la retención de la humedad en varios suelos, se encontraron diferencias entre los de textura gruesa y fina, donde también se tienen en cuenta los

poros, y la entrada y saturación del aire, entre otras variables. A partir de lo anterior, se propuso una ecuación no lineal que depende de tres variables características del suelo. Asimismo, se describe una ecuación que muestra el comportamiento (en forma de S invertida) de la capacidad de retención de agua del suelo.

Sin embargo, al existir diferentes relaciones entre las variables de Van Genuchten, para diversos casos, este autor creó el programa RETC, el cual le permite al usuario calcular este comportamiento (Van Genuchten, 1991), cambiar la relación de las variables para observar cual se ajusta mejor a los suelos que está manejando (o si es a partir de los datos de laboratorio) y le permite calcular cuales son las variables para esas condiciones de suelo.

En síntesis, RETC es útil para predecir las propiedades hidráulicas del suelo no saturado, establecer la conductividad hidráulica o complementar los datos de la curva de retención a partir de datos ya obtenidos para diferentes estados de humedad.

En este contexto, han sido varios los investigadores que han desarrollado *software* con funciones de edafotransferencia incorporadas. Además de SOILPAR, se encuentran también Rosetta y Neuropack.

Con relación a SOILPAR, este fue desarrollado por Acutis y Donatelli (2003), donde los cálculos de las funciones de edafotransferencia que realiza dependen de las variables de entrada. Al poseer las ecuaciones de varios investigadores, este utiliza datos de acuerdo a la ecuación que se desee calcular. Algunas de estas variables que usa son la textura del suelo, la materia orgánica, el pH y la capacidad de intercambio catiónico. Para ello, se pueden usar datos internos o se alimentan con datos nuevos. Es un programa amigable con el usuario.

En lo que concierne a Rosetta, este fue creado por Schaap y Leij (1998) y está basado en una red neuronal artificial. Asimismo, utiliza los datos de entrada para calcular la conductividad hidráulica saturada y la retención de agua del suelo por las ecuaciones de

Van Genuchten (1980) con sus diferentes variantes. Cuenta con datos almacenados para calcular las nuevas variables o se le pueden cargar nuevos para generar información de sitios específicos si así lo quiere el usuario.

Con respecto a Neuropack, propuesto por Minasny y McBratney (2002), este utiliza una red neuronal, pero a diferencia del anterior, no tiene datos cargados previamente. Entonces, el usuario tiene que proveer los datos y con estos genera los pesos y los sesgos de la red neuronal para dichos suelos específicos. Este tiene que generar sus bases de calibración, validación y predicción. Además, requiere un manejo más cuidadoso que los programas anteriores; sin embargo, los datos básicos de entrada son la textura y la densidad aparente, y con estos predice el contenido de agua retenido en el suelo.

A partir de lo anterior, en el estudio donde se propuso a Neuropack, a su vez, se hizo una comparación de la incertidumbre de los modelos y los aciertos entre lo predictivo y los datos reales obtenidos en laboratorio o en campo. De igual forma, existe una recopilación de los estudios que se han hecho en algunos lugares del mundo (Suramérica, Europa, Estados Unidos y algunos países específicos). Como conclusión, en el documento se recomienda que las funciones derivadas en sitios específicos se deben aplicar ajustadas al lugar y probadas para esas condiciones; de esta forma, en lugares nuevos es necesario hacer las validaciones y ajustes correspondientes a los sitios estudiados (Pachepsky y Rawls, 2004).

En cuanto a Rosetta, este fue actualizado en su versión 3 por Zhang y Schaap (2017). En esta actualización, se comparó el desempeño de ambas versiones (Roseta I y Roseta III). Dado que se trabaja sobre redes neuronales, se mejoró su desempeño al cambiar las funciones de entrenamiento para que los pesos de entradas y los resultados fueran más precisos, de acuerdo con la base de datos actuales. Es de anotar que Rosetta emplea las ecuaciones de Van Genuchten para el cálculo de la curva de retención de humedad con sus respectivas variables. En esta nueva versión, se incluyó la estimación de la conductividad hidráulica que en la versión anterior no se tenía.

Otros programas informáticos creados para estimar la retención de agua en el suelo también han vuelto a ser retomados. Entre estos, Splintex, creado por Loyola y Prevedello en 2002 como un modelo de cálculo para estimar las propiedades hidráulicas de medios porosos, a partir de la curva granulométrica. Este modelo está basado en datos físicos calculados en un laboratorio de suelos de Brasil, el cual utiliza el acumulado de la granulometría tomada al suelo y lo relaciona con la densidad de estos, para obtener los parámetros propuestos por Van Genuchten.

Para un mejor desempeño en la predicción, estos se pueden alimentar con algunos puntos de retención de humedad obtenidos experimentalmente en el laboratorio, y con ellos calcular los otros puntos de la curva. A su vez, los autores relacionan la forma de la curva granulométrica bien gradada, con la curva de retención de humedad, las cuales tienen un desarrollo de una ecuación cubica. De este modo, con algunos puntos obtenidos en el laboratorio se pueden inferir los demás, para así construir toda la curva desde el punto de marchitez permanente a la capacidad de campo.

En cuanto a la comparación de modelos, Calegari et al. (2017) compararon Splintex con la versión 1 de Rosetta. Dado que ambos modelos utilizan los parámetros de Van Genuchten, y se pueden alimentar con algunos puntos de la curva de retención de humedad, dieron resultados similares. En algunos casos, Splintex presentó mejores resultados, lo cual permite recordar que es un modelo basado en aspectos físicos y que se puede usar para estimar las propiedades hidráulicas de los suelos.

Investigaciones realizadas al usar funciones de edafotransferencia

Sin duda, la predicción de las propiedades físicas del suelo es valiosa al permitir el ahorro, tanto en trabajo como en dinero. De esta forma, se han desarrollado métodos para inferirlas. Estos métodos básicamente se dividen en dos grupos: los mecanicistas y los experimentales.

El primero relaciona las características de textura y densidad aparente con un modelo de distribución de tamaño de poro. Este modelo tiene relación con el potencial matricial

del suelo o las alturas matriciales del agua. A partir de la distribución de las partículas del suelo, estas se comparan en un modelo de textura que determina el tamaño de los poros, junto con la ecuación de capilaridad, y da como resultado el volumen de agua que puede contener este suelo. De este modo, da buenos resultados para los suelos arenosos, pero presenta problemas para las otras texturas predominantes, limosas y arcillosas (Patil y Singh, 2016).

Dentro de los modelos mecanicistas, uno muy conocido y ampliamente aceptado es el de Mualem (1976). A partir de la curva de retención de humedad, este predice la conductividad hidráulica en un suelo no saturado, pero también se enfoca en otros modelos.

En cuanto a los modelos experimentales, estos son los preferidos por los investigadores, pues la gran mayoría de funciones de edafotransferencia presentadas en la literatura científica emplean esta técnica. Para ello, se toman una serie de datos observados y, de acuerdo con su comportamiento, se plantea una o varias ecuaciones predictivas de las variables analizadas.

Para ello, se puede hacer una regresión lineal con los datos obtenidos en campo, —que generalmente son la textura y la densidad aparente— y que se relacionan con la capacidad de retención de humedad por el suelo, a partir de los cuales se establecen las ecuaciones con buena precisión (Patil y Singh, 2016).

Otros autores han desarrollado algunas ecuaciones que relacionan las variables del suelo, tales como la textura, la densidad aparente, la densidad real y la porosidad, entre otras, con el fin de determinar otros parámetros hidráulicos. Tal es el caso de Brooks y Corey (1966), quienes propusieron una ecuación potencial, donde para calcular el contenido de agua en el suelo utilizan el índice de distribución de poros, la presión de entrada de aire y la presión del agua.

En relación con otros investigadores que han propuesto ecuaciones potenciales para la retención de la humedad, Campbell (1974) propuso una ecuación con algunas variables como el volumen de agua, el volumen de agua saturado y otras constantes que dependen del tipo de suelo al cual se le esté analizando o prediciendo su retención de humedad. Posteriormente, Hutson y Cass en 1987 modificaron las ecuaciones de Campbell e introdujeron nuevas variables, tales como los contenidos de agua en los puntos de inflexión donde se unen las curvas parabólicas y exponenciales. Además, para encontrar los valores reales de las constantes, se utilizaron suelos donde las principales variables son la arcilla, el limo y la densidad aparente. Todas estas ecuaciones han ayudado a encontrar o extrapolar datos de retención de humedad de los suelos; no obstante, se necesita la realización de investigaciones en la región donde se vaya a realizar el estudio, pues siempre es necesario calibrar el modelo, o encontrar las variables y constantes que intervienen en un área determinada.

Con respecto a las ecuaciones lineales, Rawls y Saxton en 1986 encontraron relaciones lineales entre la textura y la densidad aparente. Para lo anterior, lograron plantear ecuaciones para el cálculo del contenido de humedad a diferentes succiones basados en la textura y la densidad aparente. Estas ecuaciones tienen su rango de aplicabilidad de acuerdo con las clases texturales tenidas en cuenta por los investigadores. Con base en las ecuaciones propuestas, también se puede calcular la conductividad hidráulica para los suelos estudiados.

En este contexto, Minasny, McBratney y Bristow tomaron datos de suelos en Australia, aproximadamente 850 muestras hacia el año 1999. Ellos utilizaron parte de los datos como predicción (85 %) y el resto como validación. A su vez, compararon tres métodos para evaluar las funciones de edafotransferencia: regresión múltiple lineal, regresión extendida no lineal y redes neuronales. Así, el mejor desempeño lo obtuvo la regresión extendida no lineal, pero con resultados similares para las redes neuronales; sin embargo, explican que la primera es la que más se usa debido a que presenta las funciones basadas en datos físicos, mientras que las redes neuronales se consideran una caja negra.

Además, estos investigadores observaron que los parámetros usados por Van Genuchten tienen dificultades al linealizarlos, pero al tratarlos de forma no lineal, presentan resultados que reflejan la curva que se genera de la presión de succión y el contenido de humedad en el suelo. Es de anotar que estos utilizaron básicamente la textura y la densidad aparente.

Estudios realizados en suelos amazónicos en Brasil por Tomasella et al. (2000 y 2003), predijeron una mejor retención del agua con respecto al uso de las ecuaciones que han sido derivadas de otras latitudes. Para ello, primero se calculó el resultado de la retención de agua con las ecuaciones de Van Genuchten, las cuales dieron ajustes pobres con respecto a los datos obtenidos en los laboratorios con rangos de presión entre -10 kPa y -1500 kPa. Con estos datos se derivaron las variables de los tipos de suelos para las ecuaciones de Van Genuchten, con resultados sustancialmente mejores. Lo anterior, puede significar que estas metodologías pueden ser usadas, pero si se modifican los valores para los suelos de una región específica. Sin embargo, Tomasella especifica que son necesarias mayores investigaciones sobre los suelos para los cuales no se tengan datos específicos.

Así, Tomasella (2003) comparó dos técnicas para desarrollar funciones de edafotransferencia. En la primera usó los datos que tenía disponibles para obtener ecuaciones que expresaran el contenido de la humedad del suelo bajo diferentes cargas de succión. En el segundo método utilizó la información de los suelos para estimar las variables que se requieren para la utilización de ecuaciones ya establecidas, como las de Van Genuchten.

Estas ecuaciones, fueron mejoradas para los parámetros de Van Genuchten por Medrado y Lima (2014) para suelos brasileños. De esta forma, los investigadores tomaron datos de los suelos de sabana, realizaron una regresión no lineal y le agregaron una función de optimización. Así, lograron mejorar la predicción del contenido de humedad del suelo en un 70 % comparado con las ecuaciones propuestas por Tomasella.

A su vez, se encontró que el planteamiento de las ecuaciones específicas para los suelos de Brasil predicen mejor los parámetros de retención de agua con los datos obtenidos o analizados de estos suelos, en contraste con su estimación a partir de las ecuaciones ya establecidas para otras latitudes. Esto se debe a las características particulares que presentan los suelos en cada región del mundo, puesto que están influenciados por su entorno (el clima, las estaciones y las plantas, entre otras variables); por lo tanto, es necesario adelantar otros estudios para corroborar o desvirtuar estas afirmaciones.

En este ámbito de Brasil, al sur del país, Reis Dos Santos et al. (2013) tomaron cerca de 1100 muestras a diferentes profundidades. A estas se les determinó la retención de humedad a capacidad de campo y el punto de marchitez permanente, así como su densidad aparente y el contenido de materia orgánica. Con estos resultados se realizaron las regresiones lineales para cada tipo de suelo y profundidad. Con tal fin, se utilizaron el 70 % de los datos para probar las ecuaciones de regresión, y el 30 % para la validación de estos. Al realizar los ajustes del coeficiente de determinación, que varía entre el 0,5 y 0,7, se concluyó que esta es una información valiosa que aún no se tenía para esta región.

En otras latitudes, como el continente asiático, Givi et al. (2004) realizaron el análisis de la predicción de la capacidad de campo y el punto de marchitez permanente para suelos iraníes. Compararon las ecuaciones propuestas por Rosetta PTF, Brakensiek, Rawls, British Soil Survey Topsoil, British Soil Survey Subsoil, Mayr-Jarvis, Campbell, EPIC, Manrique, Baumer, Rawls–Brakensiek, Vereecken, y Hutson, las cuales dieron resultados poco halagadores para la mayoría de los autores. Se especula que esto puede ser debido a que la mayoría de las ecuaciones han sido desarrolladas para suelos con características y rangos de texturas diferentes. De acuerdo con sus resultados, se observó que las ecuaciones que toman en cuenta el carbono orgánico tienen un desempeño mejor. Fue así como *British Soil Survey* y Brakensiek presentaron los mejores resultados debido a que los rangos en los cuales fueron propuestos son parecidos a los encontrados en las montañas de Irán.

Al utilizar las ecuaciones usadas por varios autores, Nguyen y otros colaboradores en el año 2017 compararon estas con los datos de la retención de la humedad obtenidos en campo. Las ecuaciones evaluadas fueron las de Aina y Periaswamy (1985), Dijkerman (1988), Adhikary et al. (2008), van den Berg et al. (1997), Minasny y Hartemink (2011), Botula (2013), Gupta y Larson (1979), Rawls y Brakensiek (1982), Salchow et al. (1996), y Saxton y Rawls (2006). De estas, los mejores resultados se obtuvieron cuando se consideraron los suelos tropicales dentro de sus bases de datos. Así, los autores estiman que aquellas investigaciones sobre suelos tropicales donde se desarrollan cultivos, son un gran aporte al desarrollo de estas regiones y a la ciencia al proporcionar datos que antes no se tenían.

Con el fin de determinar la curva de retención de humedad y la conductividad hidráulica, Ghanbarian et al. (2015) tomaron varias muestras de suelo en columnas para comparar sus resultados de laboratorio con las ecuaciones propuestas por Van Genuchten (1980), y propusieron dos metodologías: la primera es hallar los parámetros de Van Genuchten por regresión asistida a través de los patrones de contraste, y la segunda por regresión simple. A su vez, además de las variables típicas (textura, densidad aparente y materia orgánica) se adicionaron variables como la longitud de la muestra y el diámetro del tubo experimental. Para todos los casos analizados, el modelo que dio la mejor respuesta fue a partir del cual derivaron los parámetros de la regresión asistida por patrones de contraste.

En cuanto a la bibliografía que recopila información sobre las funciones de edafotransferencia y la relación con la hidrología, Pachepsky y Rawls (2004) editaron un libro donde en un inicio se presentan las formas que los investigadores han usado para el desarrollo de las funciones de edafotransferencia. Posteriormente, se refieren a los cálculos del agua retenida en el suelo y la conductividad hidráulica, junto con la erosión, los mecanismos y el *software* con los cuales se pueden calcular estos parámetros. Al final de este escrito, los autores muestran diversos ejemplos de aplicabilidad en el mundo.

Asimismo, en los primeros capítulos de ese texto se hace un recuento de las técnicas que se han utilizado para encontrar las ecuaciones de las funciones de edafotransferencia. Para esto, se utilizan regresiones simples y multivariantes, y las pautas para la construcción de modelos y su validación. Luego, se expone la cantidad de datos mínimos que se requieren para generar las funciones, lo cual se puede hacer a través de redes neuronales, árboles de regresión y validación cruzada. Es cuanto a las funciones derivadas, estiman que es necesario aplicar criterios de optimización y tratar de evaluar la incertidumbre de los datos y los procedimientos empleados.

En la segunda parte se analizan las propiedades hidráulicas, la retención de agua y la conductividad hidráulica. Se discute cómo la distribución de las partículas minerales del suelo tienen un papel muy importante en las funciones de edafotransferencia. De igual forma, la retención de agua por el suelo como la conductividad hidráulica, se puede predecir al utilizar la textura y la cantidad de poros, lo cual involucra la densidad aparente y real de suelo. Más adelante, se presenta como variable adicional el carbono orgánico que contiene el suelo. Con este elemento adicional se enuncia que las predicciones de la retención de humedad por el suelo se hacen mucho más precisas comparadas con los datos obtenidos en el laboratorio.

En el libro mencionado, los parámetros hidrológicos y físicos son estudiados, entre estos, la erosión y su relación con la retención de agua en el suelo y los modelos planteados de las funciones de edafotransferencia. También se hace referencia a otros elementos que se han tenido en cuenta para el desarrollo de las funciones, entre otras, la morfología de una zona, los agregados gruesos, la composición mineralógica y la información química como complementos para las funciones de edafotransferencia. A su vez, la contracción del suelo, la absorción y el transporte de solutos, su comportamiento al incluirlos en las funciones predictivas, así como la escala que se utiliza.

En cuanto al componente espacial, este se toma como otra variable en el desarrollo de las funciones predictivas, pues no es lo mismo un análisis a escala local (las condiciones locales de un terreno) o regional (toda una región o un país). Con respecto a las

características fisiográficas de un terreno, estas también influyen en la predicción de las funciones de edafotransferencia. Dentro estas, variables como la pendiente, y la curvatura longitudinal o lateral influyen en el resultado final de las predicciones; si bien, entre más elementos se consideren de acuerdo con los investigadores, mejores resultados de predicción se tienen, pero se vuelve complejo el proceso. También se pueden usar funciones ya desarrolladas y probadas para predecir el comportamiento o los valores de otras variables, tendencia que ha tomado fuerza entre los investigadores; no obstante, hay que hacer mayor trabajo de campo para corroborar o corregir los resultados de estas funciones derivadas de otros lugares.

Con relación a los modelos que usa Van Genuchten para el cálculo de la conductividad hidráulica y el agua retenida en el suelo, Vereecken y otros en el año 2010 hicieron una revisión y comparación. Ellos encontraron que los resultados hallados con los valores iniciales o propuestos por Van Genuchten presentan mayor error que aquellos hallados para lugares específicos.

Sin embargo, Vereecken et al. (2010) involucraron otras variables, pues además de la textura y la densidad aparente incluyeron la materia orgánica al presentar mejores resultados. En cuanto a la textura, los autores infirieron que la mayoría de los suelos estudiados corresponde a la clase gruesa; por lo tanto, se hace necesario el estudio de suelos de textura media y fina, además de que se universalicen los métodos y ecuaciones para calcular tanto la conductividad hidráulica como la retención de humedad.

Posterior a los trabajos realizados por Tomasella en suelos brasileros, han surgido otros investigadores en la misma línea de investigación. Entre estos, Barros et al. (2013) quienes reunieron información de más de 700 muestras de suelos de todo el territorio de este país, con el fin de comparar los resultados obtenidos en laboratorio con las ecuaciones de Van Genuchten. A su vez, determinaron en laboratorio, la textura, la densidad aparente, el contenido de materia orgánica y la retención de agua para diferentes succiones. Estos autores compararon la retención de humedad para

diferentes succiones con las ecuaciones de Van Genuchten, y obtuvieron resultados pobres. Al realizar las pruebas, tuvieron en cuenta solo la textura de los suelos en comparación con la adición de otras variables (la densidad aparente y la materia orgánica), y obtuvieron resultados similares. Solamente, ellos reportan que se mejoró el resultado en la determinación de los coeficientes de la ecuación cuando se tiene en cuenta la materia orgánica. De igual modo, no se presenta diferencia en el análisis de todos los suelos en conjunto o al separarlos por grupos homogéneos.

En otros países como Italia, Wassar et al. (2016) tomaron muestras de suelo en el norte de este país y las analizaron tanto en campo como en laboratorio. Su objetivo era comparar la retención de la humedad en el laboratorio, en el sitio de estudio y con las funciones de edafotransferencia ya establecidas. Los investigadores llegaron a la conclusión que la determinación de la humedad en el suelo es mejor representada en el laboratorio debido a las condiciones controladas que se tienen. De los métodos ya establecidos, Rosetta, propuesto por Schaap (2001), fue el que mejor resultados dio — con una buena aproximación— con respecto los datos de laboratorio.

1.10 TÉCNICAS DE APRENDIZAJE DE MÁQUINA APLICADOS AL DESARROLLO DE FUNCIONES DE EDAFOTRANSFERENCIA

1.10.1 Redes Neuronales Artificiales. En cuanto a las redes neuronales artificiales, estas tratan de seguir el modelo de la función humana del cerebro, el cual procesa la información que le llega y donde se tienen unas entradas, un proceso interno y unas respuestas. Se ha propuesto que las redes neuronales son un procedimiento matemático que interpreta a las funciones del razonamiento humano, al construirse modelos que tratan de simular el camino que sigue los razonamientos del cerebro (Minasny y McBratney, 2002; Calegari Da Silva, 2015).

Según Schaap (2001), la gran ventaja de las redes neuronales frente a los otros métodos, es que no está sujeta a unas ecuaciones ya establecidas, sino que establece una relación entre las entradas y salidas al sacarles el mayor provecho. Así, la red tiene

una fase de entrenamiento, donde aprende cómo es el comportamiento de los datos. Con las respuestas que obtiene, va sumando o restando a los pesos, para ajustar la diferencia mínima entre los datos medidos y los calculados.

En este contexto, para determinar las funciones de edafotransferencia, se han realizado varias investigaciones. Entre estas, Pachepsky (1996) las utilizó debido al gran volumen de datos que tenía y, en consecuencia, los modelos de regresión no ajustaban muy bien; por lo tanto, recurrió a este método para determinar las funciones hidráulicas de los suelos. Sin embargo, la relación entre las capas ocultas y la capa de salida debe estar bien relacionada para obtener el mejor desempeño de la red.

Varios trabajos se han realizado utilizando las redes neuronales artificiales, algunos han creado sus propias redes y otros han aplicado las ya creadas, como es el caso del modelo Rosetta, que utiliza esta técnica para calcular los parámetros de Van Genuchten. En China, Wan et al. (2012) hicieron un estudio en suelos arenosos y compararon los resultados de Rosetta con una regresión no lineal extendida. Para algunas succiones y en la parte superficial de los perfiles de suelo, la regresión no lineal presentó mejores resultados; sin embargo, la red neuronal tuvo buenos desempeños en las otras profundidades. Los autores destacan que para la región de China donde se realizó la investigación, no se tenían estudios de este tipo, lo cual le da un valor agregado a esta región para el cálculo de la retención de agua por el suelo.

Red Neuronal:

Las redes neuronales fueron creadas para ofrecer solución a problemas no lineales, donde se tengan muchas variables y su solución se torne dificultosa. Una red neuronal artificial trata de imitar al cerebro al tener neuronas, y al estar interconectadas con otras hacen diversas tareas.

Estas son redes interconectadas masivamente en paralelo con elementos simples y en una jerarquía, e interactúan en casos reales con objetos reales, tal como lo hace el sistema nervioso central. En esta interacción, aprende de la experiencia, encuentran

relación con acciones realizadas anteriormente, y obtienen características de los datos iniciales para ofrecer una respuesta a partir de estos; por lo anterior, las redes neuronales presentan varias ventajas.

Entre las ventajas se puede mencionar las siguientes: i. el aprendizaje de tareas con un entrenamiento previo o experiencias iniciales; ii. una red neuronal puede organizarse a sí misma al crear su propia organización; iii. se pueden presentar fallos durante la ejecución de la red neuronal con degradación de su estructura, pero por su bondad, puede retener algunas capacidades de la red; iv. se pueden usar en tiempo real con las tareas que se presentan y tomar decisiones de ejecución inmediata (Matich, 2001).

Componentes básicos de una red neuronal:

Una red neuronal artificial puede estar compuesta básicamente por tres partes: una capa inicial, que son las entradas o datos iniciales, una capa intermedia donde se realizan los procesos de cálculo y una salida o respuesta.

Así, el grupo de neuronas en un mismo nivel forman una capa, las cuales se conectan con las capas adyacentes que pueden tener igual o diferente número de neuronas. La conexión de dos neuronas adyacentes en diferentes capas tiene una fuerza de conexión o peso (Schaap et al., 1998).

De acuerdo con lo anterior, los datos ingresan por una capa de entrada, pasan a una zona intermedia llamada capa oculta, que puede estar constituida por una o varias capas, y finalmente salen por la capa de salida.

La capa de entrada está controlada por una función de entrada, donde las neuronas reciben los datos como si fueran homogéneos. La función posee un operador apropiado que, junto a los pesos, puede combinar estos datos. Los valores de entrada se multiplican por los pesos y estos cambian de acuerdo con las influencias que estos ejercen; entonces, un valor grande, puede no tener gran influencia en el proceso debido a que el peso es pequeño.

Las funciones de entrada más comunes son las siguientes:

- a. Sumatoria de las entradas. Consiste en sumar todos los valores de entrada y multiplicarlos por sus correspondientes pesos.
- b. Producto de las entradas. Es la multiplicación de todos los valores de entrada en la neurona; este producto es multiplicado por los pesos correspondientes.
- c. Máximos de las entradas. Aquí se analiza el mayor valor o más fuerte y se multiplica con su peso adecuado.

En cuanto a los tipos de redes neuronales:

- a. Redes unidireccionales (*feedforward*). Estas se caracterizan por la información que circula en un único sentido, y comienza en las neuronas de entradas y sigue los caminos en la red hasta alcanzar la salida.
- b. Redes recurrentes (*feedback*). Es este tipo de redes la información puede fluir en cualquier dirección entre las capas que posee la red, incluso desde la salida hacia la entrada.
- c. Redes autoasociativas. Cuando se presenta cierto estímulo o información de entrada, la red hace una interpretación con relación al mismo patrón.
- d. Redes heteroasociativas. Aquí la red se entrena para que ante un estímulo, la respuesta de salida sea opuesta o diferente ante el patrón que se le presenta (Socha y Ortiz, 2005).

Redes neuronales como aproximación estadística:

Las redes neuronales reproducen mediante un esquema computacional, muchas de las funciones clásicas de la estadística. Para alcanzar lo anterior, simplemente se varían el número de nodos ocultos y las funciones de activación. Frente a los modelos estadísticos clásicos, presenta algunas ventajas significativas tales como que la implementación es mucho más flexible, y la extensión más sencilla en casos multivariados (Bonet-Cruz et al., 2007) sobre la configuración de dos capas que contengan suficientes neuronas, a partir de las cuales se puede llegar a una función continua con un grado de precisión arbitrario (Cybenko, 1989; Vásquez, 2014). También, se sabe que cada día se buscan soluciones a problemas complejos de predicción e identificación de patrones. De esta

forma, tanto las redes multicapa como las *feedforward* presentan similitud en el análisis generalizado de las regresiones (Warner y Misra, 1996; Vásquez, 2014).

1.10.2 Bosques aleatorios. Los bosques aleatorios o *Random Forest* es una técnica de clasificación de datos a través de árboles de decisión. Estos modelos estadísticos sirven para trabajar con una gran cantidad de datos y muchas variables. Del total de datos que se tienen se pueden crear árboles que tratan conjuntos de datos o submuestras más homogéneas que se procesan en cada árbol.

Esta técnica hace una clasificación supervisada de los datos, y tienen una organización que se asemeja a la de un árbol con raíz, ramas y hojas. Cada una de sus partes, que generalmente son representadas por un círculo, son los nodos, los cuales se conectan con otros nodos. El nodo inicial es la raíz desde la cual se extienden las ramas hasta llegar a los extremos de la cadena donde se encuentran las hojas (Medina-Merino y Ñique-Chacón, 2017).

Cuando se tienen árboles predictivos pero con clasificadores débiles, se trabaja en conjunto con los árboles interconectados; de este modo, sus resultados se promedian para dar una respuesta a su clasificación.

Algunas ventajas de los árboles es que se asemejan a la forma intuitiva en la que los humanos clasifican y predicen el comportamiento de un sistema; además, su forma es relativamente fácil de interpretar. Como se comporta sin parámetros establecidos no tiene que cumplir ninguna distribución específica. La preparación de los datos es mucho menos exigente que otros métodos de aprendizaje estadístico debido a que no se ve muy influenciado por datos atípicos. Para la exploración de datos, este permite una identificación rápida de las variables influyentes en una predicción. Si la predicción no llega hasta el nodo final, la información obtenida hasta el nivel que llega se puede interpretar (Rodrigo, 2017).

Algunas desventajas que tiene esta técnica de predicción, se presenta cuando se tiene un solo árbol de decisión, pues su capacidad predictiva se ve disminuida frente a otros modelos; también, cuando se trabaja con variables continuas es posible que se pierda parte de la precisión, porque trata de agrupar los datos en conjuntos (Rodrigo, 2017).

1.10.3 Árboles de decisión. Los árboles de decisión son una herramienta poderosa y sencilla que se implementa fácilmente. Se puede tomar como un modelo de predicción, tarea que hace al aprender a partir de las observaciones de la realidad. Este parte de una serie de objetos que tienen a su vez una serie de atributos. Los atributos caracterizan al objeto y toma una serie de valores que se pueden excluir unos a otros; si se excluyen en este punto, la decisión sigue un único camino.

Como los árboles principalmente lo que hacen es clasificaciones de grupos, esto inicia en el nodo principal, desde allí se va extendiendo a nodos secundarios donde se responden preguntas del atributo, que pueden ser valores o características. Al final del proceso se llega a una decisión que corresponde a una variable del problema planteado (Barraientos et al., 2009).

Si el árbol es creado para tomar una decisión, esta puede ser positiva o negativa. El árbol puede ser entrenado para la toma de decisiones; con una serie de atributos de los objetos, este puede tomar varias rutas, y con suficiente información, llegar a una respuesta correcta. Sin embargo, en la medida en que se incrementan los atributos y sus características, su tamaño puede crecer exponencialmente y hacerse un poco más difícil de comprender.

Con varios conjuntos de datos, se puede usar una parte para entrenamiento y otra para validar las salidas que está calculando el árbol. Con lo anterior, se pueden hacer pruebas estadísticas y determinar qué tan buen desempeño tiene el árbol en las decisiones o clasificaciones que arroja.

Cuando los atributos se van haciendo grandes, se puede partir las tareas para hacer el árbol más comprensible. Al final, este clasificará los objetos de acuerdo con los atributos propuestos en subsecciones para unirlos al gran árbol (Barraientos et al., 2009; Quinlan, 1986, 1993).

Los árboles de decisión se construyen por intermedio de algoritmos, los cuales están divididos en dos partes. La primera se llama inducción y se hace con datos de entrenamiento, que generalmente corresponde a una buena proporción de los datos observados en la realidad. Como se parte del nodo raíz, el árbol crece de acuerdo con las necesidades, pues depende de las características que tiene en cada nodo, si estas pertenecen a más de dos clases de clasificación, se genera un nuevo nodo, pero si es simple, allí termina y se tiene una respuesta.

En la etapa de clasificación o validación de los datos, los datos nuevos son clasificados de acuerdo con la red del árbol que se construyó previamente al seguir los caminos y asignándole alguna clase, o al generar una respuesta a las variables de entrada.

Algunos algoritmos que se utilizan usualmente en los árboles de decisión son ID3, J48, y Naive Bayes. Estos son sencillos, de rápida ejecución con bajo consumo de máquina y son precisos. El ID3 (Quinlan, 1993) utiliza el total de los datos inicialmente, y posteriormente los va dividiendo hasta encontrar homogeneidad en ellos. Con esto se logra obtener el mejor atributo que agrupe los datos en clases parecidas. El J48 (Quinlan, 1996) hace un proceso iterativo al agregar nodos o ramas y determinar la menor diferencia entre los datos; de este modo, entre ensayo y error va encontrando un camino que tenga el menor error entre los datos observados y los calculados o clasificados por el árbol. El algoritmo Naive Bayes tiene previamente un clasificado bayesiano que ordena cada clase y hace que los atributos de esta sean independientes de otras: solo se usan esos atributos para determinada clase. Lo anterior, hace que los caminos sean fijos y solo se aprendan los parámetros (Dunham, 2003).

1.10.4 *Extra-(randomized)-Trees o Extra Trees* – Árboles Altamente Aleatorizados. Es una variante de los árboles de decisión, pues lleva mucho más allá la decorrelación en cada nodo, y permite que no se presente dependencia entre los datos que se están analizando. En cada nodo, evalúa solo un subconjunto de los predictores y, de estos, elige un grupo de puntos que corte el eje. Lo anterior hace que el valor de la varianza se haga más pequeño (Rodrigo, 2017).

Este método se desempeña bien con valores que presentan una tendencia no lineal, además de ser flexibles y de escalabilidad a comparación de otras metodologías como las redes neuronales que no lo expresan bien. El proceso es progresivo entre los diferentes modelos que se van evaluando, pero esto es apoyado en la validación cruzada, donde se escogen grupos de datos para el entrenamiento y se comparan con el resto en la validación; estos grupos seleccionados se rotan hasta copar todo el grupo de muestras que se tengan.

El proceso de los arboles aleatorios se hace con tres pasos básicos. El primero consiste en hacer una clasificación de los datos de entrada al utilizar alguna medida estadística. De estos datos de entrada se tienen unas respuestas, de las cuales se reservan de mejor resultado. En un segundo paso, los datos obtenidos anteriormente se comparan con los observados y se dejan los de mejor desempeño. En el paso final, se identifica el modelo que mejor representa los datos calculados con respecto a los observados, el proceso se repite hasta que una medida estadística evalúe que la diferencia sea la menor (Galelli et al., 2013).

1.10.5 Método de regresión asistida por patrón de contraste (CPXR). Este método ha sido difundido por Taslimitehrani y Dong (2014) y Dong y Taslimitehrani (2015) presentándose como una alternativa para derivar funciones de edafotransferencia con robustez para modelos de predicción. Se presenta como un método alternativo donde otros modelos no presentan una respuesta aceptada de predicción. De acuerdo con Ghanbarian et al. (2015), los modelos desarrollados por este método son más sencillos y comprensibles comparados con los modelos de regresión lineal y las redes neuronales. Las variables utilizadas en los diferentes patrones no están restringidas a un solo camino y por mínimo que sean los datos que se tienen, siempre trata de ponderar los resultados.

Este método busca tener un conjunto de datos que se ajusten a ciertos rangos que tengan un patrón conocido. Con este grupo se puede hacer modelos de regresión local para los grupos de datos coincidentes.

De esta forma, cuando una muestra de datos se ajusta a un patrón determinado, a esta se le aplica la función lineal local para dicho grupo. Cuando los datos muestran coincidencia con varios grupos de datos, entonces se aplican las funciones lineales y se ponderan para dar un solo valor de respuesta; no obstante, cuando algunos datos no se ajustan a ningún patrón, se tiene una función auxiliar que se les puede aplicar.

En este contexto, Ghanbarian et al. (2015) presenta 5 pasos para calcular los patrones y llevar el error de predicción al mínimo:

- 1) Del total del conjunto de datos que se poseen, se puede hacer una regresión lineal múltiple con los datos de entrenamiento, el cual lo llama "f0".

- 2) Del total de los datos de entrenamiento, estos se dividen en dos grupos, el primero llamado de grandes errores y el segundo de pequeños errores. Para lograr lo anterior se toma un valor "c", de tal manera que los valores del error de predicción "f0" que superen a "c", son los grandes errores. Autores como Ghanbarian et al. (2015) afirman que la suma del error de predicción absoluto alcanza el 45 % del total de la suma de los errores

absolutos. Esto indica que el resto son los errores pequeños de los datos del entrenamiento.

3) Para definir los grupos en los cuales van a estar los límites de aplicabilidad de las variables, así como hacer discretas las variables de entrada, se utiliza un modelo de entropía propuesto por Fayyad e Irani (1993). Luego, el modelo de regresión por contraste de patrones clasifica las variables de acuerdo con el patrón al cual se ajustan. Dado que es posible que algunos subgrupos sean bastante parecidos, es posible utilizar filtros para que se asignen a un solo grupo de ajuste.

4) Con los datos agrupados, se procede a realizar una regresión múltiple local para cada grupo. Los modelos de regresión local que no mejoren la predicción de todo el modelo se pueden eliminar.

5) Al final, se aplica un doble proceso de optimización con el fin de hallar los mejores patrones, funciones y pesos que mejor representan el modelo de predicción. Así se van aplicando los patrones a los conjuntos de datos clasificados anteriormente; el proceso termina cuando, al probar las funciones en los conjuntos la precisión del modelo, este no mejora (Ghanbarian et al. 2017).

2. METODOLOGÍA

2.1 ÁREA DE ESTUDIO

En Colombia, el departamento del Quindío se encuentra ubicado en la parte centro-occidental del país, delimitado por los departamentos de Risaralda, Tolima y Valle del Cauca. Sus paisajes están catalogados como de montaña, lomerío, piedemonte y valle. Cuenta con los pisos térmicos subnival, extremadamente frío, muy frío, frío y templado, en las provincias de humedad clasificadas como húmeda, muy húmeda y pluvial (IGAC, 2013).

El departamento del Quindío y la zona norte del departamento del Tolima pertenecen a la región central del país, donde sobre la cordillera central se presentan extensas ondulaciones y montañas con pendiente variada. La zona montañosa, con pendientes abruptas, tienen relación con la litología de rocas metamórficas y la acción volcánica. Las partes onduladas han sido formadas por el flujo de lodos volcánicos, el transporte de sedimentos por las diversas corrientes y sus depósitos de materiales.

De igual forma, en el flanco oriental de la cordillera central, en el Tolima —con la influencia del volcán nevado del mismo nombre— las pendientes son fuertes con cañones profundos y suelos de origen volcánico. En esta zona, las elevaciones se presentan desde los 900 m s.n.m. hasta los 4000 m s.n.m., y hacen parte del parque natural Los Nevados. En cuanto al comportamiento de las lluvias, este es bimodal (entre marzo a mayo, y septiembre a noviembre), donde hay un aumento de la precipitación; en el resto de los meses esta es menor y alterna con periodos de sequía.

En cuanto a los estudios sobre los suelos de Colombia, estos han sido en su mayoría de forma general. En los departamentos de Tolima y Quindío se han realizado algunos en forma semidetallada, lo que ha permitido una mejor comprensión de sus procesos de

formación y aptitud con fines agrícolas, forestales, y de protección, entre otros temas de interés.

En este ámbito, todas las identificaciones que se hagan a los suelos son relevantes, pues aportan conocimientos que llevan a impulsar el progreso en beneficio de las comunidades. Si las personas conocen el entorno que las rodea con sus ventajas y debilidades, puede organizar su territorio y aprovecharlo de manera más racional.

Con relación a las características generales de los territorios del Quindío y Tolima, estos son de tipo quebrado, en general, cubiertos con cultivos de café y con algunas especies forestales; pero también se presentan otras topografías y variados ambientes donde se tienen diversas actividades de uso.

En lo que respecta a la historia geológica de la zona, esta data del precámbrico, donde se depositaron una gran cantidad de sedimentos. Ya durante el paleozoico, los sedimentos se plegaron y metamorfizaron, lo cual generó nuevas clases de rocas. En el periodo cretáceo y paleoceno comienza el levantamiento de las cordilleras, y a partir del plioceno, se desarrolla gran actividad volcánica que contribuyó, en gran medida, a la formación de los suelos como se encuentran hoy.

Las rocas existentes en la zona son de una gran variedad: se encuentran depósitos no consolidados y glaciares que datan del cuaternario, rocas volcánicas de gran magnitud del terciario, al igual que andesitas. Asimismo, rocas juntas de origen ígneo, sedimentario y metamórfico del precámbrico, donde la mayoría están cubiertas con capas de cenizas originadas por la actividad volcánica, en diferentes espesores.

Todos los procesos geológicos, tectónicos y movimientos de la tierra han modelado el paisaje en el transcurso del tiempo, lo cual se ha visto favorecido por la intensa actividad volcánica que ha dado origen a los diferentes paisajes que se tienen hoy en día. De igual forma, se presentan un sinnúmero de montañas, lomeríos, piedemontes, valles, laderas, cimas, taludes y escarpas, con pendientes pronunciadas, pedregosidad y erosión

aumentada por la intervención humana, remociones en masa, inundaciones y encharcamientos.

Los suelos se distribuyen de acuerdo con el clima y las formas del relieve, y con gran cantidad de materiales. Con estas características particulares, se han generado gran variedad de suelos con rasgos distintivos de morfología, físicos, químicos, biológicos y constitución mineralógica distinta.

En esta zona, en su mayoría los suelos se han originado de cenizas volcánicas mezclados con tobas, arenas volcánicas y pumitas, como los Andisoles. Estos suelos presentan buen drenaje, sus superficies son de colores oscuros o grises con texturas medias a gruesas, con predominancia de arenas; a su vez, tienden a ser arenosos franco o franco arenosos. Sus horizontes adyacentes tienen colores pardos amarillentos, blancos o grises con texturas similares a la parte superficial.

Generalmente, poseen baja densidad aparente, buena permeabilidad, buena retención de humedad, alta porosidad, alto contenido de materia orgánica y estructura subangular. Se ubican en climas fríos a templados, lo que les da una amplia área de ocupación en toda la región andina.

En menor área y proporción se encuentran los Inceptisoles. Estos suelos son originados de depósitos torrenciales, sedimentos volcánicos, anfíboles y esquistos de laderas, lomas y colinas. Tienen texturas franco arenosas, son suelos profundos y bien drenados. Se encuentran en cimas y laderas, lomas y colinas así como en planos de abanicos. A su vez, se puede encontrar los Alfisoles en zonas de lomas y colinas, en climas templados y húmedos, con su horizonte característico argílico. Son relativamente profundos con buen drenaje y texturas de finas a medias, con algún buen grado de fertilidad, pero ocupan una baja extensión.

Los Entisoles tienen alguna frecuencia en el área y presentan una buena presencia de arena mezclada con fragmentos de roca, lo cual le da una textura gruesa y con buen

drenaje. Su fertilidad es media y poseen algún grado de materia orgánica que le ayuda a retener la humedad.

Todos los suelos anteriores tienen diferentes grados de limitaciones, entre estas, la pendiente, la erosión, la fertilidad del suelo, el drenaje y el clima. Algunas de estas o su combinación hace que se presenten limitantes de explotación de los suelos, desde una limitación ligera hasta severa, al ocupar los suelos con grandes limitaciones una gran área (IGAC, 2013; CORTOLIMA, 2006).

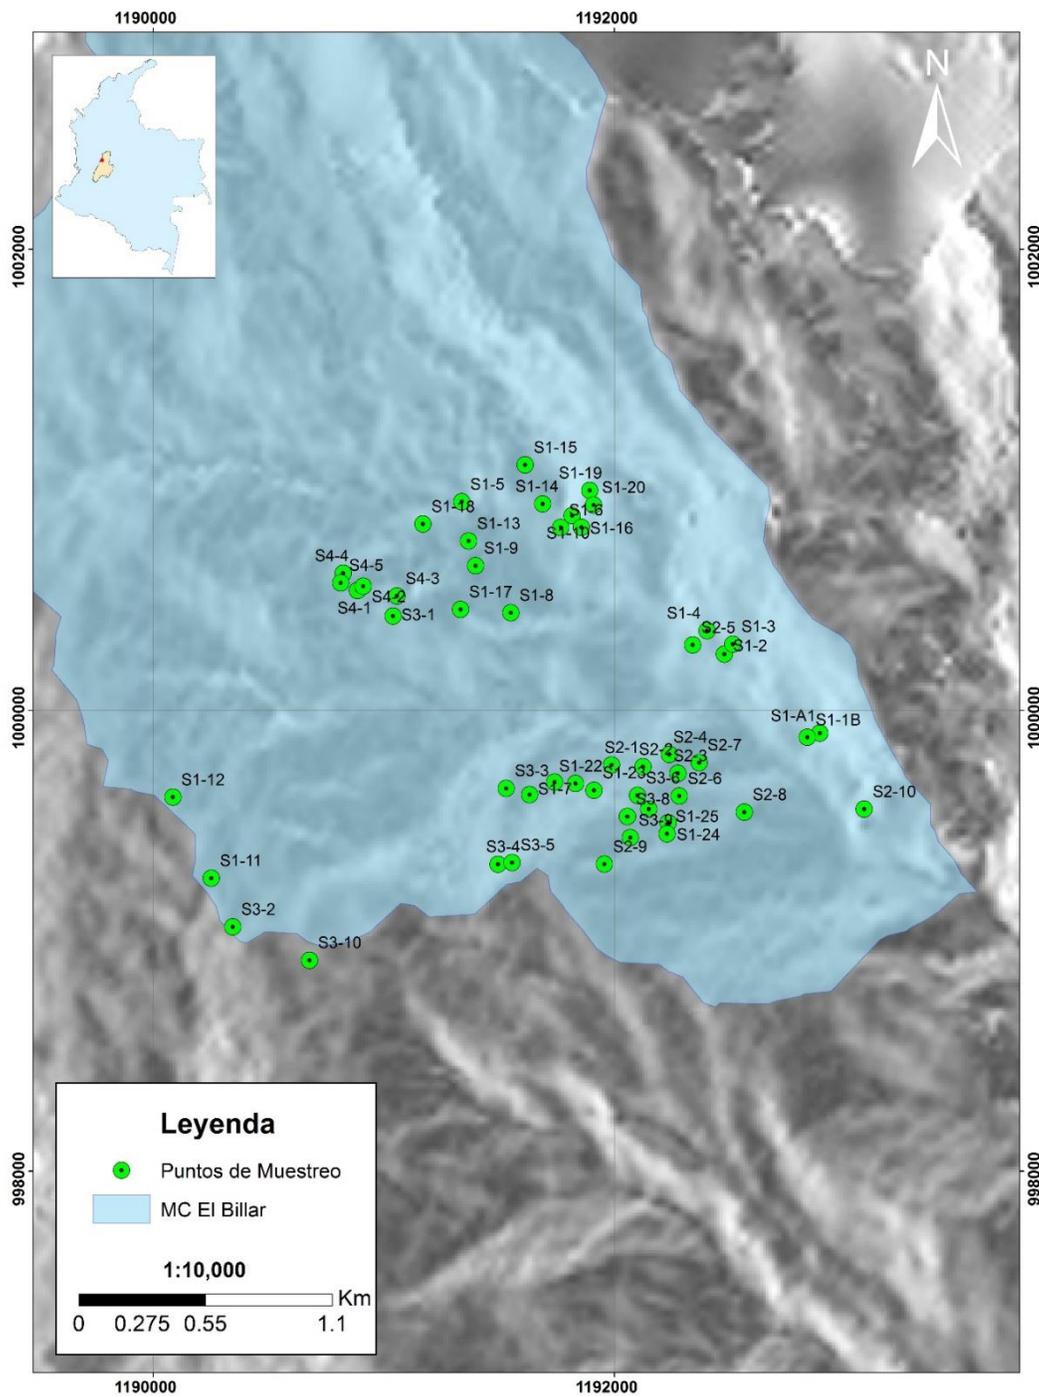
Con respecto a esta investigación, el análisis de las propiedades hidrofísicas se realizó para los suelos de la parte alta de las cuencas del río La Vieja en el departamento del Quindío y la microcuenca El Billar (cuenca del río Combeima) en el Tolima. Estas zonas son de especial valor al ser las productoras del agua que se utiliza para el consumo humano, así como para el riego de cultivos.

2.2 TOMA DE MUESTRAS Y ANÁLISIS DE LABORATORIO

Los puntos de muestreo se seleccionaron según la heterogeneidad de los tipos de suelo presentes en la zona y las características del relieve, para así garantizar su representatividad. En total, se analizaron y muestrearon 94 perfiles de suelo, se establecieron 51 puntos de muestreo en la parte alta de la cuenca del Río Combeima (Microcuenca El Billar) en el Tolima (Figura 1), y 43 puntos de muestreo en la parte alta del Río La Vieja en el departamento del Quindío, según se observa en la Figura 2.

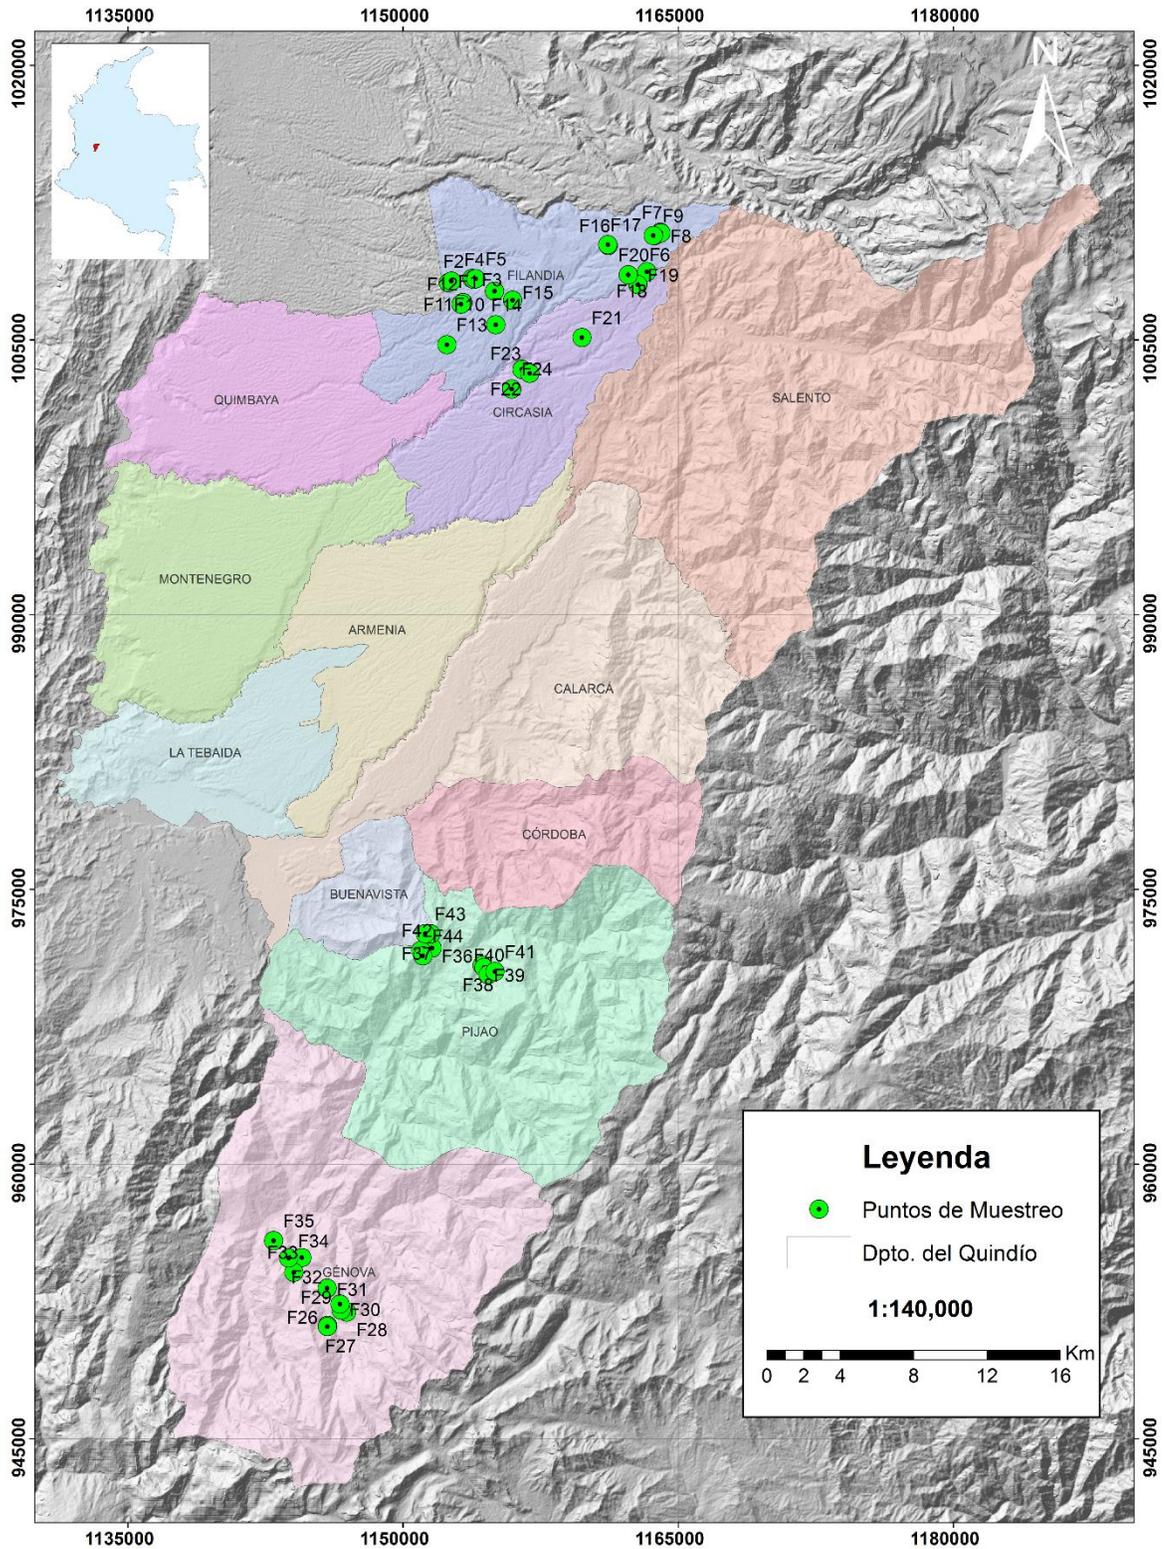
Para este muestreo, se hicieron calicatas de 1 m de profundidad, se identificaron los horizontes que se presentaron en cada perfil, y se tomaron las muestras de suelo disturbadas e indisturbadas en cada horizonte identificado para los análisis de laboratorio.

Figura 1: Localización de los puntos de muestreo de la cuenca El Billar, Combeima, departamento del Tolima.



Fuente: Adoptado de imagen satelital ALOS PALSAR 2011. <https://vertex.daac.asf.alaska.edu>.

Figura 2: Localización de los puntos de muestreo en el departamento del Quindío.



Fuente: Adoptado de imagen satelital ALOS PALSAR 2011. <https://vertex.daac.asf.alaska.edu>.

Posteriormente, en campo, se ubicaron estos puntos y se tomaron tanto muestras indisturbadas como disturbadas. Para esto, se realizó en cada punto de muestreo una calicata de 1 m por 1m de área superficial con 1 m de profundidad. Se fotografiaron y se identificaron los horizontes principales, y se realizó la toma de las muestras de suelo en cada uno.

Para las muestras disturbadas, se tomó aproximadamente un kilogramo de suelo y se empacó en una bolsa plástica sellada y debidamente identificada. Siempre se tuvo cuidado de remover rocas, raíces gruesas, lombrices, insectos del suelo y cualquier elemento extraño. En el laboratorio, cada muestra se expuso al aire para un secado natural; posteriormente, se trituró y se tamizó en tamiz de abertura de 2 mm.

En cuanto a la toma de las muestras indisturbadas, esta se realizó sin modificar la estructura interna del suelo. Para este muestreo, se requirió un equipo especial como son los anillos biselados, un barreno y un martillo de caucho, con el fin de no causar daños ni a la herramienta ni al suelo.

Para la toma de la muestra, primero se buscó una zona nivelada, la cual se limpió de hojas, raíces y rocas. El anillo con el barreno debe siempre ir con el bisel hacia el suelo para que cumpla con la función de cortar el suelo y que la muestra salga limpia.

Una vez puesto en el sitio de la toma de muestra, se golpeó suavemente con el martillo de caucho y se verificó que el anillo penetrara el suelo. Cuando el cilindro haya llegado a su tope final, es decir, a ras con el suelo, se extrae, ya sea con el barreno o se procede a excavar alrededor y, con cuidado, con una navaja se corta el suelo en la base del anillo y se enrasa por ambas caras. Estas muestras se tomaron con anillos metálicos de 5 cm de diámetro y 5 cm de altura para determinar la densidad aparente; en anillos de 5 cm de diámetro y 2,5 cm de altura se colectaron las muestras para determinar la curva de retención de humedad.

Una vez se ha extraído la muestra, se envuelve con una película plástica para preservar alimentos; esto permite un buen ajuste para evitar que el contenido se salga del anillo. Posteriormente, se aseguran las caras del anillo con tapas plásticas rígidas, las cuales se refuerzan con cinta de enmascarar; posteriormente se rotula o identifica correctamente y se envía al laboratorio (SENA, 2013).

En el laboratorio, se realizaron varios análisis físicos como la densidad aparente, la textura, la humedad gravimétrica, la curva de retención de humedad, la conductividad hidráulica y el contenido de materia orgánica.

Con las muestras disturbadas de aproximadamente un kilogramo de suelo, se determinó la textura y la cantidad de carbono orgánico. En total, se recolectaron 95 muestras en el Quindío y 80 muestras en la cuenca El Billar. En la primera zona, esta corresponde a 43 puntos geográficos y en la última, a 51 lugares donde se tomaron muestras en diferentes horizontes identificados en campo, donde se pudo acceder para la toma de estos. En promedio, se tomaron dos muestras por sitio, por calicata, que corresponde a los horizontes identificados. En la zona del Quindío, donde se identificaron más horizontes en algunos puntos, se presentaron suelos más desarrollados, en contraste con el lado del Tolima, donde la topografía presentó mayor pendiente, y los horizontes eran mucho menos diferenciados (Figuras 3 y 4). Las calicatas y sus características se observan en el Anexo 3.

Figura 3: Calicata típica muestreada en el departamento del Quindío



Figura 4: Calicata muestreada en la cuenca El Billar, Combeima, departamento del Tolima.



Los parámetros físicos del suelo determinados fueron los siguientes: i. la textura, mediante el método del hidrómetro por Bouyoucos (1963); ii. el carbono orgánico a partir del método de Walkley-Black (1947, Gelman et al, 2011); iii. el contenido de agua a diferentes presiones de succión calculado con las ollas y platos de presión (Cassel y Nielsen, 1986); y iv. la densidad aparente hallada mediante la desecación en horno por 24 horas a 105 grados centígrados (IGAC, 2006). A continuación, se presenta el procedimiento detallado para cada determinación.

Determinación de la textura

Para dicha determinación se utilizó el método de Bouyoucos y se emplearon muestras disturbadas, las cuales previamente se habían secado a temperatura ambiente, se trituraron con un rodillo y se pasaron por un tamiz de 10 mm. Después, se pesaron 100 g de suelo (en suelos arcillosos solo 50 g), se depositó cada muestra en un frasco donde se adicionó agua destilada hasta 2/3 partes de su volumen y se agregó 10 ml de agente dispersante (hexametáfosfato de sodio). Luego, se dejó reposar esta mezcla por 5 minutos, para posteriormente ponerla en el agitador mecánico por dos horas.

Por último, se pasó toda la mezcla a una probeta hidrométrica, y se tuvo cuidado de trasladar todo el contenido; esto se puede hacer con ayuda de un frasco lavador, al adicionar agua destilada hasta completar el volumen de un litro. Se agitó la solución con el agitador manual en forma generosa por un tiempo de 30 segundos, enseguida se introdujo el hidrómetro y se dejó que flotara libre por 40 segundos; luego, se tomó la lectura de este y la temperatura de la mezcla. Después de dos horas, se hizo la segunda lectura del hidrómetro y del termómetro para proceder a hacer los cálculos de textura (IGAC, 2006; ASA, 2002).

Determinación de la densidad aparente

Para su determinación, se utilizaron las muestras indisturbadas extraídas con anillos de acero. Dado que las dimensiones del anillo son conocidas, así se obtuvo el volumen total para cada muestra, según las dimensiones reales del cilindro.

Se tuvo cuidado en garantizar que el cilindro estuviese completamente lleno de suelo. Luego, se llevó al horno a 105 °C por 24 horas; después de ese tiempo, se dejó reposar y se obtuvo el peso final. A partir de la relación de la masa y el volumen, se obtuvo la densidad aparente, tanto de los sólidos como los vacíos, que en este caso son los poros totales del suelo. Las densidades aparentes de valor bajo indicaron los suelos con una condición porosa; dicho valor hace referencia a los menores de 1 g/cm³. Por el contrario, aquellos valores de densidad aparente alta pueden indicar un ambiente difícil para el desarrollo de las raíces, aireación baja y cambios indeseables en la función hidrológica, lo cual reduce la velocidad de infiltración del agua. Este puede ser un indicador de la calidad del suelo y el funcionamiento del ecosistema que hubiese sido alterado (USDA, 1999; SENA, 2013).

Determinación de la retención de humedad

La retención de humedad del suelo se determinó con las ollas y platos de presión ideadas por L. A. Richards en 1930. En esta se llevó una muestra a un potencial hídrico específico mediante la aplicación de presión; a su vez, se dejó que el exceso de agua fluyera hacia afuera a través de un plato de cerámica con poros de un diámetro determinado. Cuando se llega al equilibrio, ya no hay agua que drenar y su potencial hídrico es igual a la presión aplicada.

Para determinar cada uno de los puntos de la curva de retención de humedad en las ollas de presión, primero se pusieron las muestras indisturbadas sobre los platos porosos. Es necesario aclarar que para cada punto de presión de succión se dispone de un plato poroso específico. Con las muestras puestas en los platos, se saturaron con agua por 24 horas y se cuidó que el agua no superara la parte superior de los anillos (para este caso, 2,5 cm de alto).

Después que el plato poroso y las muestras de suelo están completamente saturados de agua, es tiempo de introducir las en la olla, la cual se sella herméticamente y se procede a nivelar la presión interna de acuerdo con el punto de succión que se esté

analizando. Una vez alcanzado el equilibrio de la presión, se deja de 48 a 72 horas y se vigila constantemente el drenaje de la olla.

Como al interior de la olla, la presión es mayor que la atmosférica, el agua es forzada a salir al exterior por los microporos de la placa de cerámica y por el tubo capilar de la olla a presión.

Cuando la presión dentro de la olla ha alcanzado todos los poros de las muestras de suelo, la humedad del suelo es drenada desde cada partícula y sale a través de la placa hasta que toda la película de agua que envuelve el suelo sea la misma o alcance la misma presión. Cuando esto ocurre, se tiene un equilibrio y el flujo de agua se detiene; entonces, se observa que la salida del drenaje en el exterior ya no arroja más agua. En ese momento se destapó la olla para extraer las muestras y se pesaron, luego se llevaron al horno por 24 horas a 105 °C; ya secas, se volvieron a pesar. Con estas mediciones del peso en estos dos momentos, se obtiene el contenido de agua gravimétrico a la presión que se hizo el análisis (Martínez, 2008).

Cálculo del carbono orgánico

En cuanto al método utilizado específico para este cálculo, es el de digestión vía húmeda desarrollado por Walkley y Black en 1934. Para este análisis se requirió de suelo seco, triturado y tamizado por el cedazo de 2 mm de apertura. Dado que hay que pesar una muestra pequeña (0,1 g), se utilizó una balanza de precisión analítica con sensibilidad de 0,01 g. Una vez pesado el suelo, se depositó en un Erlenmeyer de 250 ml donde se le agregó una solución de dicromato de potasio 1 N (cerca de 20 ml), se agitó, y seguidamente se adicionó ácido sulfúrico concentrado (alrededor de 40 ml). Todo este procedimiento se hizo bajo una campana extractora y con los equipos de seguridad necesarios, tales como gafas de seguridad y respirador para gases orgánicos.

Luego, con los reactivos incorporados, se agitó vigorosamente por 30 segundos; se dejó en reposo y se adicionó agua destilada (100 ml), con el fin de clarificar la muestra para

su posterior titulación; después, se puso en reposo por 30 minutos, siempre bajo una campana extractora de gases volátiles orgánicos.

Transcurridos los treinta minutos de reposo, con una pipeta se agregó 1 ml de ácido fosfórico, se agitó la solución y se adicionó cinco gotas de indicador ortofenantrolina, y se procedió a realizar la titulación. Esta titulación se hizo con una bureta de 25 ml llena con sulfato ferroso de amonio a 0,5 N. Se contabilizó el volumen gastado hasta que se observó el viraje de color, de verde a marrón. Lo anterior, también se realizó con una muestra de control blanco que no contenía suelo, con el fin de comparar la reacción de las sustancias en presencia del carbono orgánico.

Calculo del porcentaje de carbono orgánico (%CO):

$$\%CO = \frac{(V1N1) - (V2N2)}{pm}$$

Ecuación 2: Porcentaje de carbono orgánico.

Donde:

V1 = Volumen de dicromato de potasio (ml)

N1 = Normalidad del dicromato de potasio (eq.l⁻¹)

V2 = Volumen del sulfato ferroso gastado en la titulación (ml)

N2 = Normalidad del sulfato ferroso (eq.l⁻¹)

Pm = Peso de la muestra en gramos

0,399 = Factor de conversión

(IGAC, 2006; Soil Survey, 2002; Arrieché y Pacheco, 1998; Walkley, 1947).

2.3 DESCRIPCIÓN DE LA BASE DE DATOS

2.3.1 Variables hidráulicas del suelo a modelar. El trabajo de campo y laboratorio arrojó un total de 225 horizontes examinados, a los cuales se les realizó los análisis de laboratorio de todos los parámetros físicos e hidrodinámicos propuestos. De estas observaciones se seleccionaron 175, por ser las más consistentes, para ser utilizadas en el desarrollo y comparación de los modelos de edafotransferencia; el criterio para realizar esta depuración de la base de datos fue a partir de la realización de gráficas simples de las diferentes variables obtenidas en laboratorio y eliminar los resultados que se mostraron fuera de la nube de puntos. El anterior criterio es sustentado como una técnica válida para la detección de datos atípicos de un universo de muestras (Hodge y Astin, 2004; Uribe, 2010).

Además de los datos obtenidos en el laboratorio, se consideraron otras variables que están relacionadas con características ambientales del sitio de recolección de la muestra; estos datos son relativamente fáciles de obtener a partir de información cartográfica de la zona. Los datos obtenidos se observan en la Tabla 7, donde se tabularon los valores máximo, mínimo, desviación estándar y el promedio.

2.3.2 Variables potencialmente predicativas. En cuanto al tamaño de las partículas del suelo como variable predictiva, la textura del suelo es una propiedad muy importante; sin embargo, existen muchas clasificaciones en todo el mundo sobre los límites del tamaño de las fracciones de arenas, limos y arcillas.

La más aceptada y difundida es la establecida por el Departamento de Agricultura de los Estados Unidos (USDA, por sus siglas en inglés) desde el año de 1951, donde se considera que las arcillas son las partículas menores de 2 micras, los limos están entre los límites de dos a cincuenta micras y el resto hasta dos milímetros son arenas.

Desde inicios del siglo XX, varios investigadores se dieron cuenta de la importancia de la distribución de las partículas del suelo y su relación con la capacidad de retención de agua en el suelo (Briggs y McLane, 1907; Briggs y Shantz, 1912).

Así, la textura del suelo se usa como principal fuente de información para funciones de edafotransferencia. Por tanto, los investigadores han usado los promedios de los tamaños de las partículas de los tipos o clases de suelo; de este modo, ya hacia el año de 1977, Hall (junto a otros investigadores, en Inglaterra) establecieron la relación de la textura con algunos puntos de la curva de retención de humedad. Sin embargo, hay que asociar la clase textural con la clasificación del suelo, pues existen diferencias entre los investigadores que han propuesto algunos límites en los tamaños de las partículas.

En este ámbito, según la clasificación de los suelos, proponer una función de edafotransferencia con varias clases de estos da una aproximación de las propiedades hidráulicas, pero si los suelos se agrupan en clases homogéneas, la aproximación es mucho mejor. Por lo anterior, es valioso que se tengan funciones derivadas para suelos de regiones en particular, pues las propuestas de otras zonas pueden generar inexactitudes en la estimación de las propiedades (Pachpsky y Rawls, 1999; Zhuang et al., 2001).

Según lo anterior, utilizar el tamaño de las partículas como único parámetro de entrada para encontrar otras propiedades del suelo ha sido una preferencia de los investigadores (Cosby et al., 1984; Campbell, 1985; Saxton et al., 1986). Igualmente, estas funciones se han usado en otras investigaciones para estimar las variables hidrodinámicas del suelo, en particular, en lo concerniente a la retención de agua. Fue así como Kern (1995) encontró que las funciones propuestas por Saxton tienen buena respuesta y reflejan — con buen grado de precisión— la predicción de la retención de humedad en el suelo.

A su vez, Nemes et al. (2006) encontraron que el tamaño de las partículas constitutivas del suelo es una fuente de información para determinar otras propiedades. Sin embargo, al existir diferentes clasificaciones de estas partículas, ellos realizaron varias comparaciones y encontraron que no hay diferencias significativas en el uso de diferentes límites de arcillas y limos.

Las curvas de retención de humedad como variable predictiva:

En relación con la cantidad de agua que retiene el suelo, esta está directamente relacionada con su textura, su capacidad de transmitirla, la cantidad que puede retener el suelo y que está disponible para las plantas. Esta última, está determinada por el intervalo entre el punto de marchitez permanente y la capacidad de campo. Como en todas las zonas que se estudian, existe una variabilidad espacial de las propiedades del suelo; de esta forma, por diferentes motivos, es posible que los datos no sean muy acertados; además, se presentan diferencias según sean los datos medidos en campo y en laboratorio (Vanderlinden et al., 2003; Kutilek y Nielsen, 1994).

En este contexto, con la ayuda de otras variables que son fácilmente medibles (la textura, la densidad aparente y el contenido de materia orgánica), se han creado las funciones de edafotransferencia para determinar el valor de la retención de agua; por ejemplo, como variable predictiva (Wosten et al., 2001).

En cuanto a los puntos de la curva de retención de humedad, los análisis son largos, costosos y tediosos. Así, estos se han tomado a partir de muestras de suelo y se han analizado en el laboratorio en diversas partes del planeta. A partir de estos, se han determinado unos valores medios de estas propiedades y, con estos, se ha podido estimar las características del agua en el suelo a diferentes tensiones de succión (Timlin et al., 2004).

El contenido de materia orgánica como variable predictiva:

Dentro de las propiedades físicas y químicas del suelo que se pueden medir en el laboratorio, el contenido de carbono orgánico es una de ellas. Es una variable que permite establecer el contenido de agua y la densidad aparente —junto con la textura— y su predicción mejora notablemente (Adams, 1973; Rawls, 1983; Rawls et al., 2004).

Algunos efectos que tiene la materia orgánica en el suelo son el aumento de la porosidad, la retención de humedad y la conductividad hidráulica. A su vez, existen diferencias entre las clases texturales, pues en los suelos livianos aumenta la retención de agua, pero en los pesados es más significativo el aumento de la conductividad hidráulica (Nelson y Sommer, 1982; Rawls et al., 1991; Hudson, 1994; Rawls et al., 2004).

Rawls et al. (2004) demostró que en todas las clases texturales, el contenido de agua se incrementa al adicionar el carbono orgánico. Si bien, las arcillas fueron las que menor respuesta mostraron (niveles de 5 %), su retención aumentó comparado con la ausencia de este. Tanto para arcillas y limos, estas presentan mayor retención a mayor cantidad de carbono orgánico; por lo tanto, esta variable es muy importante en la predicción del contenido de agua del suelo, debido al comportamiento que se presenta en presencia de este.

La densidad aparente como variable predictiva:

La densidad aparente del suelo se ha considerado una variable relevante en la cuantificación de la retención de agua. Desde los años sesenta, los investigadores han relacionado esta propiedad junto a la textura, la conductividad hidráulica y la estructura; sin embargo, esta última es más difícil de determinar (Diebold, 1954; Barron y Peterson, 1968; León, 2001; Salamanca y Sadeghian, 2005).

Algunos autores han planteado funciones de edafotransferencia basados en la densidad aparente como única variable. En Francia, Bruand et al. (1996) presentó una función donde considera, como fuente predictora, la densidad aparente de los suelos considerados arcillosos con contenidos que superaban el 30 % de esta fracción mineral del suelo. Posteriormente, estos investigadores compararon varias formas de determinar la densidad aparente; donde, con el terrón, esta fue superior que la determinada en los sitios de campo debido a que se incluyeron macroporos que no intervienen en la retención de agua; además, esta propiedad del suelo puede variar con el manejo que se le da al suelo o al uso al que esté sometido.

Bruand et al. (2003) demostraron con las funciones para texturas medias, que para densidades bajas (del orden de $1,45 \text{ g/cm}^3$), se observa mayor retención de agua para bajas tensiones de succión; sin embargo, para las tensiones más negativas de succión, los contenidos de agua en el suelo son más homogéneos, inclusive para densidades promedio de $1,82 \text{ g/cm}^3$.

Asimismo, hay que considerar que el contenido de materia orgánica está relacionada con la densidad aparente. Adams (1973) ya presentaba ecuaciones para establecer una relación entre los contenidos de materia orgánica, como carbono orgánico y la densidad aparente, las cuales eran inversamente proporcionales, dado que a mayor contenido de materia orgánica menor era la densidad del suelo. Más adelante, Rawls y otros investigadores, presentaron un triángulo textural con curvas donde se puede inferir la densidad aparente.

Datos obtenidos en laboratorio

En lo concerniente a estos datos, se obtuvieron dos tipos de variables, las primeras halladas en laboratorio fueron básicamente variables físicas: i. retención de humedad a 0,33, 1, 5, 10 y 15 atmosferas; ii. la densidad aparente; iii. la textura como porcentaje de la fracción mineral de arenas limos y arcillas; y iv. el contenido de carbono orgánico.

Datos obtenidos de la información cartográfica:

Según los sitios identificados para la toma de las muestras, se determinaron las variables de los atributos ambientales y de relieve del terreno, las cuales fueron calculadas a partir de la información cartográfica. Estas son latitud (y), longitud (x), elevación del terreno (*demfill*), pendiente (*slope*), curvatura, curvatura del perfil (*curv_profi*), curvatura del plano (*curv_plan*), acumulación del flujo (*Accum*), espesor del estrato, profundidad desde la superficie como centro del estrato, cuenca y cobertura.

Para la ubicación espacial cartográfica, la longitud y la latitud son las coordenadas de los mapas y esta ubicación hace que se tenga una grilla de puntos, la cual depende también de la resolución; no obstante, para el caso de este estudio, los puntos se encuentran separados con suficiente distancia, lo que permite que su grado de precisión sea bueno.

En cuanto a la elevación, como otra variable, es posible extraerla del modelo de elevación digital que, con la resolución que se tiene y la separación entre puntos, es un dato representativo de cada punto estudiado.

Con respecto a la pendiente del terreno, esta se determina como la hipotenusa del cambio de pendiente de las celdas vecinas, tanto en el eje X como en Y; por lo tanto, se puede expresar como la tasa de cambio o los grados de inclinación que presenta en el punto analizado.

En relación con la curvatura, esta ayuda a entender las características físicas de un terreno. Con estos datos se puede inferir los procesos de erosión y escorrentía, al igual que el modo como está directamente relacionada con la pendiente. Por lo tanto, la curvatura puede representar la aceleración o desaceleración de un flujo en el terreno, lo que puede contribuir en mayor o menor grado al transporte de sedimentos.

Así, la curvatura del perfil del terreno (*curv_profi*) está en dirección de la pendiente máxima, según su forma, cóncava, convexa o neutra, donde el flujo sobre el terreno puede acelerarse o hacerse más lento, lo cual al final puede afectar la escorrentía superficial en una cuenca.

Con respecto a la curvatura del plano (*curv_plan*) es perpendicular a la pendiente máxima en el punto estudiado. Si la pendiente converge o diverge hacia el centro de la celda estudiada, esta tiene un valor que finalmente indica la dirección del flujo de drenaje de la cuenca.

En cuanto a la variable *Accum*, esta representa la acumulación de flujo donde las celdas adyacentes descargan el caudal en las contiguas; de esta manera, los flujos pasan de una celda a otra. Así, el flujo acumulado va aumentando en la medida que más celdas ceden su flujo a las consiguientes. Este flujo acumulado está dado por el peso del drenaje de las celdas que confluyen hacia una celda común. Esta propiedad depende de la pendiente a favor, donde a las celdas iniciales se les asignan un valor de uno y esta descarga a la siguiente; de esta forma, según las celdas de drenaje que confluyan a ella, el peso va aumentando. Si bien, estos valores sirven para determinar los flujos concentrados, las celdas con valores bajos pueden representar puntos altos.

Otra variable a resaltar es el espesor del estrato debido a que la textura y el contenido de la materia orgánica varían en los espesores de los estratos. Es de anotar que la profundidad de los perfiles estudiados se estableció en un metro.

Con relación a la profundidad o distancia desde la superficie al centro de cada horizonte, esta tiene relación con la anterior y, asimismo, se infiere que la textura y el contenido de materia orgánica sufren cambios. Por tanto, la materia orgánica tiene mayor contenido en la superficie y su contenido disminuye en la medida que se profundiza en los horizontes.

En lo que concierne a la cuenca, esta es una variable que se estableció, dado que unas muestras se tomaron en el departamento del Quindío (95) y otras en el Tolima (80). Por último, se considera la variable de la cobertura, la cual tiene cuatro niveles: uno, donde se presentan los pastos; dos, en rastrojos; tres, con cultivos, y cuatro, en bosques.

2.4 TRATAMIENTO DE LA COLINEALIDAD DE LAS VARIABLES PREDICTIVAS

Para eliminar la colinealidad se utilizaron las correlaciones cruzadas de Pearson y de Spearman, con la finalidad de detectarla entre las variables predictivas. Por ende, si las correlaciones en los modelos eran mayores a 0,5 se eliminaba por ser redundante. Los resultados se pueden observar en el Anexo 1.

Con respecto a las 19 variables consideradas inicialmente para identificar las redundantes, cuando el índice de correlación era mayor a 0,85 se eliminaban aquellas que sobrepasaran este límite. Como resultado, se observó que hay una alta correlación entre las variables longitud (coordenada geográfica angular) (x) y cuenca (Quindío o Tolima) con la elevación (*demfill*); curvatura con curva longitudinal (*curv_profi*) y curva transversal (*curv_plan*). Según lo anterior, se extrajeron siete (7) variables de la base de datos, y para la generación de modelos se utilizaron doce.

A continuación se explica de forma más detallada las dos correlaciones mencionadas:

Correlación de Pearson: esta conexión entre dos variables se usa para determinar su relación lineal e indica si pueden estar fuertemente ligadas o no. Su representación está entre 0 y 1, donde cero es no tener ninguna relación y uno es cuando están completamente relacionadas.

Esta correlación es de fácil ejecución y de fácil interpretación. Sin embargo, solo en casos dependientes se encuentra una correlación perfecta. De este modo, para la gran mayoría de los análisis existe alguna dispersión de los datos con respecto a la linealidad. Su análisis es sencillo porque representa el producto de las puntuaciones estandarizadas de las dos variables; sin embargo, al ser puntuaciones estandarizadas, no se ajustan a una escala y el valor oscila entre 0 y 1.

En términos generales, si la relación lineal entre las dos variables es diferente de cero, esto significa que las variables están relacionadas. No obstante, según sea el caso que se esté estudiando, con valores cercanos a uno, esta relación es más directa o tiene mayor importancia.

Para explicar mejor el coeficiente de Pearson se puede calcular su coeficiente de determinación, que es el cuadrado del coeficiente de correlación. Este da una idea de qué tan explicada es la relación entre las variables o qué porcentaje de los datos no están relacionados entre sí (Higgins, 2006; Yashuang et al., 2018; Bugna et al., 2020).
Correlación de Spearman: el coeficiente de correlación de Spearman se utiliza cuando se tienen datos extremos, pues estos pueden afectar el análisis con los de otras correlaciones o, ante distribuciones no normales, al no verse afectada por los cambios en las unidades de medida.

El coeficiente de Spearman mide la asociación lineal de rangos de los grupos de muestras y compara dichos rangos. Los rangos se asumen dando una secuencia ordinal de los valores de menor a mayor, así el valor más pequeño es el número uno y el mayor será el último ordinal. Luego, se halla la diferencia entre las variables así transformadas

para ser calculada la correlación, la cual varía entre cero y uno, donde cero indica ninguna correlación y uno la correlación perfecta.

El coeficiente de Spearman corrobora la relación entre las variables sin tener en cuenta su magnitud, sino asignándole un orden numérico a los rangos de las muestras (Santander, 2004).

Con todas las variables se hicieron correlaciones de Pearson y Spearman, a partir de las cuales se observaron cuáles de estas presentaron una correlación por encima de 0,85 y se procedió a eliminarlas (Anexo 1). Estas cuatro variables fueron *x* (elevación), *curv_profi* (curvatura longitudinal), *curv_plan* (pendiente transversal de la celda), y cuenca (departamento del Quindío o Tolima); así, se obtuvieron 12 variables no redundantes. Anteriormente, se habían eliminado la conductividad hidráulica (*Ks*), dado que no se pudo obtener valores consistentes en sus mediciones, así como la capacidad de campo (*FC*) y el punto de marchitez permanente (*WP*), que son variables predictoras.

2.5 FUNCIONES DE EDAFOTRANSFERENCIA COMPARADAS

Se realizó la comparación de las estimaciones de la densidad aparente, el agua disponible en el suelo, el contenido de humedad a 15 bares (*WP*) y a 0,3 bares (*FC*) mediante 12 modelos de edafotransferencia existentes; para ello, se utilizó el programa informático SOILPAR (Acutis y Donatelli, 2003), que relaciona o resume los principales modelos de edafotransferencia creados para diferentes regiones del mundo. Este *software* fue desarrollado por los autores anteriormente mencionados en el Instituto para Investigaciones de Cultivos Industriales en Bologna, Italia. El programa tiene implementados diez modelos de funciones de edafotransferencias, con cuatro funciones paramétricas. De esta forma, según sean los datos de entrada y del modelo usado, se estima la respectiva propiedad física o hidrodinámica del suelo (densidad aparente, capacidad de campo, o punto de marchitez permanente, como humedad volumétrica) (Acutis y Donatelli, 2003) y, según la configuración seleccionada por el usuario, las

variables predictivas son la textura del suelo, el contenido de carbono orgánico, el pH del suelo y la capacidad de intercambio catiónico (Pachepsky y Rawls, 2004).

Según lo anterior, en la Tabla 1 se resumen los métodos utilizados, las variables tomadas en campo y las propiedades físicas o hidrodinámicas del suelo simuladas por cada modelo. A continuación, se describe cada uno de los modelos de edafotransferencia existentes y que fueron comparados en esta investigación.

Tabla 1: Modelos de edafotransferencia comparados

Método	Variables requeridas	Parámetro estimado
Baumer	TP, CO	DA, CC, MP
Brakensiek/Rawls	TP, CO, DA	DA
<i>British Soil Survey Subsoil</i>	TP, CO, DA	DA
<i>British Soil Survey Topsoil</i>	TP, CO, DA	DA
EPIC	TP, DA	CC, MP
Hutson	TP, DA	DA
Manrique	TP, DA	CC, MP
Rawls	TP	CC, MP, DA
Jabro	TP, DA	Ks
Jaynes-Tyler	TP, DA	Ks
Puckett	TP	Ks
Cambell	TP, DA	Ks

TP: tamaño de la partícula; DA: densidad aparente; CO: carbono orgánico; CC: capacidad de campo; MP: punto de marchitez permanente; Ks: conductividad hidráulica. Adaptado de Martínez (2008) y Acutis y Donatelli (2003).

2.5.1 Modelo de edafotransferencia de Baumer. En sus investigaciones, este autor recopiló una gran cantidad de datos. De estos dedujo las ecuaciones lineales para predecir las propiedades del suelo, tales como la densidad aparente, el contenido de agua a capacidad de campo y el punto de marchitez permanente.

Su fuente de información predictiva es el tamaño de las partículas y el carbono orgánico contenido en las muestras. Cuando no se tiene el carbono orgánico como dato, utiliza la cantidad de arcilla para estimar los datos (Pachepsky y Rawls, 2004).

2.5.2 Modelo de edafotransferencia Brakensiek/Rawls. Estos investigadores tomaron los datos de 1323 muestras de suelos de diferentes estados de los Estados Unidos. A estas muestras les fueron realizados análisis de laboratorio, entre otros: la textura, la retención de agua a diferentes presiones de succión, la porosidad total y la conductividad hidráulica saturada. Con estos datos es posible predecir tanto el volumen del agua retenida para cierta tensión de succión, como la conductividad hidráulica saturada (Brakensiek y Rawls, 1986; Hutson, 1989; Pachepsky y Rawls, 2004).

Con relación a la textura, como principal dato del modelo, esta se clasificó de acuerdo con el procedimiento propuesto por USDA con los tres tamaños simples (arena, limo y arcilla); sin embargo, en algunos casos, se llega hasta 8 o 10 tamaños de partículas. A su vez, se midieron algunas características químicas, el contenido de materia orgánica, y la densidad aparente (además de lo mencionado anteriormente).

Con los datos colectados, se realizaron regresiones lineales y, a partir de éstas, se propusieron ecuaciones para el cálculo de algunos puntos de la curva de retención de humedad.

Las ecuaciones planteadas como predictoras del contenido de humedad a capacidad de campo (CC) y punto de marchitez permanente (PMP) son las siguientes:

$$CC = 0.3486 - 0.0018A + 0.0039AR + 0.0228MO - 0.0738DA$$

Ecuación 3: Capacidad de campo propuesta por Brakensiek y Rawls.

$$PMP = 0.0854 - 0.0004A + 0.0044Ar + 0.0122MO - 0.0182DA$$

Ecuación 4: Punto de marchitez permanente propuesto por Brakensiek y Rawls.

Donde:

A= arena

Ar = arcilla

MO= materia orgánica

DA= densidad aparente

2.5.3 Modelo de edafotransferencia *British Soil Survey Subsoil (BSS)*. Estas ecuaciones derivadas del trabajo realizado por Thomasson y Carter en 1989 —y expresadas por Hutson en 1992— estiman el contenido de agua en el suelo para diferentes succiones; sin embargo, para 33 kPa de succión, esta no lo hace explícitamente. Así, los autores expresan ecuaciones para 5, 10, 40, 200 y 1500 kPa de succión.

Debido a lo anterior, es necesario hacer una interpolación entre los puntos cercanos a capacidad de campo para determinar su cálculo aproximado. De esta forma, las ecuaciones están expresadas en forma lineal, derivadas de regresiones de diferentes suelos, y los resultados son para ciertos rangos de las características de estos y del lugar donde hayan sido tomados.

Contenido de agua volumétrico

$$CH - 5 = -0.4216 + 0.0034Ar + 0.0018L + 0.0022CO - 0.1697DA$$

$$CH - 10 = 0.3086 + 0.004Ar + 0.0021L + 0.0126CO - 0.124DA$$

$$CH - 40 = -0.2205 + 0.0047Ar + 0.002L + 0.0093CO - 0.0956DA$$

$$CH - 200 = -0.0431 + 0.0108Ar - 0.000079Ar^2$$

$$CH - 1500 = -0.0125 + 0.0092Ar - 0.000062Ar^2$$

Ecuación 5: Contenido de agua volumétrico para diferentes succiones propuesto por BSS.

Donde:

CH = contenido de humedad a la succión especificada

Ar = arcilla

L = limo

CO = carbono orgánico

DA = densidad aparente

2.5.4 Modelo de edafotransferencia *British Soil Survey Topsoil (BST)*. Este modelo derivado del análisis de suelos europeos no hace la relación de la cantidad de agua retenida por el suelo a capacidad de campo, y sus ecuaciones lineales fueron calculadas para succiones de 20, 40 y 200 kPa.

En este contexto, para hallar el valor del contenido de agua a capacidad de campo, se debe estimar el contenido en la succiones de 20, 40 y 200 kPa; luego, dibujar la curva de segundo grado con estos puntos para interpolar y hallar la capacidad de campo.

En el caso del punto de marchitez permanente se propuso una ecuación lineal con la succión de 1500 kPa; esta involucra el contenido de arcilla (Ar), limo (L) y el carbono orgánico (CO) (Thomasson y Carter, 1989; Hutson, 1987, 1991, 1992).

$$PMP = 0.0611 + 0.004Ar + 0.0005L + 0.005CO$$

Ecuación 6: Punto de marchitez permanente propuesto por BST.

2.5.5 Modelo de edafotransferencia EPIC. EPIC (*Erosion-Productivity Impact Calculator*) es una sigla de un calculador de impactos de prácticas ambientales, el cual predice los efectos de la erosión del suelo y la productividad. Dado que se realizan actividades sobre el suelo que afectan el agua, los nutrientes y —en los casos agrícolas— los insumos que se utilizan, este predice el comportamiento de estos y su relación, entre ellos: la pérdida de suelo, la calidad del agua y el desarrollo de los cultivos en áreas que tengan ciertas características comunes.

Este modelo fue creado bajo el lenguaje UTIL (*Universal Text Integration Language*), el cual permite el manejo de archivos de datos grandes que EPIC tiene de las diferentes variables que maneja; así como su relación entre ellas para predecir el comportamiento bajo ciertas condiciones —con unos rangos de aplicabilidad— de acuerdo con los datos de los cuales han sido derivadas las funciones.

Con los datos de los tamaños de las partículas de suelo (arcilla, limo y arena) junto a la densidad aparente, este arroja datos sobre el contenido de agua a capacidad de campo y punto de marchitez permanente (Pachepsky y Rawls, 2004; William et al., 2006).

2.5.6 Modelo de edafotransferencia de Hutson. Con los datos obtenidos de sus investigaciones, el doctor Jhon Hutson propuso dos ecuaciones para predecir el contenido de agua a capacidad de campo y punto de marchitez permanente. Estas ecuaciones son de carácter exponencial, diferentes de las derivadas de regresiones lineales (Hutson, 1987, 1989; Pachepsky y Rawls, 2004).

$$CC = Exp(-3.43 + 0.419(Ar + L)^{0.5} - 1.83 \times 0.001(Ar + L)^{1.5})$$

$$PMP = Exp(-4.384 + 0.404(Ar + L)^{0.5} - 9.84 \times 0.0000001(Ar + L)^3)$$

Ecuación 7: Capacidad de campo y punto de marchitez permanente propuesto por Hutson.

2.5.7 Modelo de edafotransferencia de Manrique. Manrique junto a Jones usaron datos de más de 12 000 muestras colectadas en Estados Unidos, tanto en la parte continental como en la insular, y en algunas de otros países. De esta forma, derivar algunas ecuaciones lineales para la estimación de la capacidad de campo, el punto de marchitez permanente y la densidad aparente de los suelos analizados.

Así, se presentan las ecuaciones generales; sin embargo, la investigación arrojó una mejor predicción de las variables cuando el análisis se hace sobre suelos homogéneos con algunas características comunes; no obstante, hay algunos suelos que no se comportan de esta manera (Pachepsky y Rawls, 2004; Manrique, 1991).

$$CC = 0.73426 - 0.00145A - 0.29176DA \quad \text{Cuando } A \geq 75 \%$$

$$CC = 0.5784 + 0.00227Ar - 0.28438DA \quad \text{Cuando } A < 75 \%$$

$$PMP = 0.02413 + 0.00373Ar$$

$$DA = 1.51 - 0.113CO$$

Ecuación 8: Capacidad de campo, punto de marchitez y densidad aparente propuesto por Manrique.

Donde:

CC= capacidad de campo

A= % arena

DA= densidad aparente

Ar= % arcillas

PMP= punto de marchitez permanente

CO = % de carbono orgánico

2.5.8 Modelo de edafotransferencia de Rawls. Con base en la recolección de información de diferentes tipos de suelos de Estados Unidos, Rawls (1982) propuso las ecuaciones para calcular la capacidad de campo y el punto de marchitez permanente. Así, en 2721 horizontes de suelos fueron medidos en laboratorio las siguientes variables: la materia orgánica, la densidad aparente y la distribución del tamaño de partículas (variables físicas) y algunas propiedades químicas como la capacidad de intercambio catiónico (Pachepsky y Rawls, 2004; Rawls, 1983).

$$CC = 0.2756 + 0.64PMP - 0.0016A + 0.00217DA \times Ar - 0.00196DA^2 \times Ar$$

$$PMP = -0.0208 + 0.007Ar - 0.00003Ar^2 + 0.0224DA^2 \times \frac{CIC}{Ar}$$

Ecuación 9: Capacidad de campo y punto de marchitez propuesto por Rawls.

Donde:

CC= capacidad de campo

A= arena

Ar= arcillas

PMP= punto de marchitez permanente

DA= densidad aparente

CIC= capacidad de intercambio catiónico

2.5.9 Modelo de edafotransferencia de Saxton y Rawls. Desde el año de 1982, estos autores recopilaron los datos de 2541 horizontes de suelo con un amplio rango de texturas. Para ello, utilizaron diferentes regresiones lineales donde relacionaron una serie de coeficientes con los contenidos de arenas, limos y arcillas, así como la materia orgánica y la densidad aparente.

Al seguir el planteamiento que propusieron Brooks y Corey (1964, 1966), ellos realizaron los análisis para diferentes presiones de succión y llegaron a las siguientes ecuaciones de capacidad de campo y punto de marchitez permanente, con relaciones no lineales.

Potencial del agua (γ) $A\theta^B$ donde θ es la tensión del agua

$$A = \text{Exp}(-4.396 - 0.0715 \%Ar - 0.000488 \%A^2 - 0.00004285 \%A\%Ar)100$$

$$B = -3.14 - 0.0022 \%Ar^2 - 0.00003484 \%A^2 + 0.00003484 \%A^2\%Ar$$

Ecuación 10: Capacidad de campo y punto de marchitez propuesto por Saxton y Rawls.

2.5.10 Modelo de edafotransferencia de Tomasella. Este investigador brasileño había observado el error notorio que existía en la estimación de los parámetros hidráulicos de los suelos, a partir del uso de ecuaciones derivadas de otras latitudes, en particular, en zonas templadas. Con la recolección de muestras de suelo de más de 500 horizontes, él determinó los coeficientes de Van Genuchten.

Con estos datos, derivó las funciones de edafotransferencia para suelos tropicales, del este y norte del Brasil, al utilizar 113 horizontes de suelo totalmente validados para esta región. De esta forma, escogió una serie de suelos para determinar las ecuaciones de simulación del contenido de agua en el suelo; luego, con otros datos diferentes, validó

las ecuaciones y encontró mejores resultados de predicción con respecto a los evaluados por las ecuaciones de Van Genuchten. (Van Genuchten, 1980, 1989; Tomasella, Hodnett y Rossato, 2000).

$$\begin{aligned}
 CC &= 0.28951 + 0.103815Z_{11} \\
 Z_{11} &= 0.191452 + 1.25652X_{17} - 0.079098X_{17}^2 + 0.393814X_{16} + 0.152095X_{17}X_{16} \\
 X_{16} &= -6.03402 + 4.80572DA \\
 X_{17} &= -2.18409 + 8.84963HE
 \end{aligned}$$

HE = humedad equivalente en porcentaje.

$$\begin{aligned}
 PMP &= 0.214008 + 0.0862945Z_{13} \\
 Z_{13} &= 0.235084 + 0.33033X_{15} - 0.191838X_{15}^2 + 0.0543679X_{15}^3 + 0.977685X_{17} \\
 &\quad + 0.304174X_{15}X_{17} - 0.218857X_{17}^2 - 0.164373X_{15}X_{17}^2 \\
 &\quad + 0.0415057X_{17}^3 + 0.373361X_{16} + 0.0811861X_{17}X_{16} \\
 &\quad - 0.0768087X_{15}X_{16}X_{17} \\
 X_{15} &= -2.07588 + 0.0423954Ar
 \end{aligned}$$

Ecuación 11: Capacidad de campo y punto de marchitez propuesto por Tomasella.

2.6 CRITERIOS DE EVALUACIÓN DEL AJUSTE DE LOS MODELOS

Para determinar si los resultados calculados por las metodologías propuestas por los investigadores se ajustan a los resultados encontrados en campo, y en laboratorio, se verifica su ajuste calculando el error medio (EM), el error cuadrático medio (MSE), la raíz del error cuadrático medio (RMSE) y el coeficiente de determinación (R^2).

Así, con el error cuadrático medio (MSE), se puede identificar los errores que se producen en la estimación, y se le da un mayor peso a los errores grandes que a los pequeños; esto permite medir la incertidumbre con respecto al valor estimado.

En este ámbito, el error medio (ME) es un indicador de la sobreestimación o subestimación de los valores medios de cada variable calculada. Su ecuación se expresa de la siguiente manera:

$$ME = \frac{1}{n} \sum_{i=1}^n (Y_{estimado} - Y_{observado})$$

Ecuación 12: Error medio.

En cuanto al error cuadrático medio, este indica el ajuste de los datos calculados con los esperados. Es así que lo ideal sería que fuera cero, pero en estos casos con valores cercanos a cero indica un buen desempeño del modelo.

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_{observado} - Y_{calculado})^2$$

Ecuación 13: Error cuadrático medio.

Donde $Y_{observado}$ representa los datos observados o medidos, y $Y_{calculado}$ los datos calculados por el modelo; n representa las parejas de datos comparados o diferenciados. De esta forma, la raíz del error cuadrático medio indica la dispersión de los datos, entre los encontrados de modo directo en laboratorio o campo y los calculados de los modelos propuestos por los investigadores.

$$RMSE = \left[\frac{1}{n} \sum_{i=1}^n (Z_0 - Z_p)^2 \right]^{1/2}$$

Ecuación 14: Raíz del error cuadrático medio.

El coeficiente de determinación (R^2) que representa una relación entre la covarianza de las variables y las desviaciones típicas de cada variable, tiende a uno, para un ajuste lineal perfecto; así, entre más cercano a la unidad, este representa un ajuste mucho mejor y da una explicación mejor entre las variables independientes y dependientes.

$$R^2 = \frac{\sum_{i=1}^n (Y_{estimado} - Y_{medio})^2}{\sum_{i=1}^n (Y - Y_{medio})^2}$$

Ecuación 15: Coeficiente de determinación.

2.7 DESARROLLO DE NUEVAS FUNCIONES DE EDAFOTRANSFERENCIA

Red neuronal artificial:

En este caso, esta red neuronal (*Feedforward*) tiene una capa oculta con neuronas de tipo sigmoideas, seguida por una capa de salida lineal. Esto, junto con un análisis de correlación de Pearson, permite ser usada con variables de cualquier unidad y relacionarlas entre sí, para de ese modo determinar las correlaciones más altas entre las variables (Ortiz y Socha, 2005).

La red neuronal consiste en tres capas: una de entrada, una capa oculta y una de salida. A la capa de entrada ingresan los datos de las variables independientes y más relevantes escogidas para cada variable estimada (Tabla 2). Una de las variables principales es la textura del suelo (Figura 5), donde según los resultados, son principalmente suelos arenosos y arenosos francos. Con respecto a la densidad aparente y a la capacidad retención de agua del suelo se determinaron siete variables. Para el caso del punto de marchitez permanente y la capacidad de campo, se escogieron seis variables, lo cual representa los nodos en la capa de entrada. Para la capa oculta, se hizo una reducción del 75 % de los nodos y dio como resultado cinco nodos para las variables densidad aparente y capacidad de retención de agua, y cuatro nodos para las otras dos variables. En cuanto al nodo de salida, este está representado por la variable respuesta en cada caso.

Como función de activación entre la capa de entrada y la oculta, se usó la tangente hiperbólica, y entre la capa oculta y la salida, una función lineal. Esto le da un buen desempeño a la red neuronal, según lo han usado e indicado varios autores (Sarmadian y Keshavarzi, 2010; Bayat et al., 2011; Olaya-Marin, 2012).

Con respecto a los resultados de este análisis, estos se observan junto con los valores obtenidos y las variables elegidas, para ser las iniciales en el proceso del modelo predictivo de las variables dependientes (Tabla 2).

En este caso, la red neuronal escogida es la *feedforward*, la cual presenta bastantes ventajas, pero requiere mayor memoria de trabajo. Varios investigadores han demostrado que con configuraciones sencillas —y con un número suficiente de neuronas— se encuentran buenas aproximaciones a funciones continuas (Cybenko, 1989; Vásquez, 2014).

A su vez, se ha identificado que existe una buena similitud entre el análisis generalizado de regresión y la respuesta de las redes neuronales multicapa *feedforward*, tal como lo demostraron Warner y Misra en 1996. Así mismo, al buscar otros caminos de análisis en las redes, se llegó a la conclusión que estos son muy similares a los resultados comunes de regresión en ejemplos ya probados.

De este modo, en la entrada, todas las neuronas están conectadas con las neuronas de la capa oculta, sin dejar ningún camino por explorar, lo cual hace que la información fluya de forma unidireccional y permite que solo pase una vez —a través de una neurona— antes de dar una respuesta de salida.

Al ingresar los datos en la capa de entrada, estas pasan la información a la capa oculta; de este modo, reciben la suma ponderada de todas las entradas que las enlazan, pues previamente ya se ha diseñado para que todo esté interconectado y cada conexión tenga su propio peso (Vásquez, 2014).

Una vez efectuada la función de entrada, viene la función de activación. Esta función calcula el estado de actividad de una neurona (activa o inactiva) y puede tomar valores de 1 (si esta activa) o de 0 o -1 (para la inactividad).

En cuanto a las funciones principales de activación, y más comúnmente usadas, son las siguientes:

Función lineal, la cual tiene una respuesta lineal y la salida será dependiente de la pendiente; esto la hace más fuerte, más débil o igual.

Función tangente hiperbólica, con valores entre uno y menos uno. La función se hace brusca, suave o tendiente a lineal al pasar por el origen.

La función sigmoidea, toma valores entre cero y uno. Esta se comporta como una “S”; a su vez, se hace más fuerte, suave o como una línea, pero restringida a los valores de cero a uno.

Esta última fue la utilizada en esta investigación.

$$F(\text{sigmoides}) = \frac{1}{1 + e^{-\text{entrada}}}$$

Ecuación 16: Función sigmoidea.

Para el aprendizaje de la neurona, se le hace un entrenamiento supervisado, y como se tienen los resultados obtenidos en laboratorio de las diferentes variables (densidad aparente, punto de marchitez permanente, cantidad de agua retenida a capacidad de campo —y la diferencia entre estas dos—, como la cantidad de agua que puede contener el suelo), se compara con las salidas que presenta la red. Así, la diferencia entre el resultado de la red y el valor obtenido es utilizada para modificar, en la siguiente iteración, los valores de los pesos de las interconexiones de las neuronas. De este modo, se busca que la diferencia sea la menor posible.

La función de salida: después de pasar por la función de activación, se tiene la respuesta final, la cual se puede transmitir a las neuronas adyacentes. Al tenerse un umbral determinado, si el valor obtenido está por debajo de este, no se pasa ninguna salida.

Mecanismos de aprendizaje

Con los datos iniciales o de entrada se espera tener una respuesta. Si la forma de la red y las funciones de las neuronas no cambian durante el aprendizaje, pero los pesos de cada una de las conexiones si lo hace, entonces la red está en el proceso de adaptación de los pesos. En el proceso de aprendizaje, los pesos sufren modificaciones, pero una vez que estos se tornan estables, se puede afirmar que la red ha terminado su etapa de aprendizaje.

El aprendizaje se puede hacer en tiempo real, con los datos constantemente alimentados, o tener una parte de los datos para realizar el aprendizaje. En este último caso se hace una fase de entrenamiento y otra fase de operación, por lo que deben existir unos datos para el entrenamiento y otros para la prueba. Lo anterior asegura que el sistema sea estático y no se presentarán problemas de estabilidad en el funcionamiento.

Durante el proceso de aprendizaje se producen errores, los cuales ayudan a determinar los valores de los pesos finales. Una forma muy usual es la regla de propagación hacia atrás. Para esto, se usa el error cuadrático mínimo junto con la desviación estándar, los cuales se evalúan con la respuesta de salida; luego, se determina el error y se reparte este entre las neuronas involucradas. Esto se hace hasta tener cambios en los pesos menores a un error establecido o se hayan cumplido un número de ciclos de entrenamientos previamente designados.

Entrenamiento y validación de los modelos de la red neuronal desarrollada

Proceso de validación: con el proceso de entrenamiento refinado, los pesos están definidos y ahora no cambian. Para este nuevo paso, se tiene un conjunto de datos que no han sido usados en los proceso de entrenamiento y funcionamiento o test. Al entrar los datos, estos producen una respuesta la cual puede compararse con las respuestas de los datos entrenados.

Si bien, las redes neuronales se pueden usar en diversos campos, un uso especial es el de su aprendizaje. Con una serie de datos obtenidos en experimentos, laboratorios o a campo abierto, se puede entrenar la red para que observe el comportamiento de los datos colectados, según su fuerza de conexión.

2.7.1 Selección de las variables por redes neuronales. Luego de la depuración de las variables por correlación entre ellas, la red neuronal se seleccionó para trabajar con el método paso a paso, el cual se alimentó con las variables predictivas.

Para el análisis de la red neuronal, la inclusión de nuevas variables genera un mejor ajuste con estos valores que están disponibles. Algunas de estas variables ya han sido utilizadas por algunos autores, pero no es generalizado su uso, tal como lo hizo Romano y Palladino en 2006.

La red trabaja bajo ciertos mecanismos que le permiten minimizar el error, estos procesos pueden ser los siguientes: el gradiente descendente, Levenberg Marquard y el gradiente conjugado. Como algunos mecanismos de este tipo son estables, pero lentos, se pueden usar variables de tasa de aprendizaje o de convergencia. En este estudio, se utilizó Levenberg Marquard, el cual trabaja con bastante rapidez y es bueno cuando se tiene un solo nodo de salida; si bien, este requiere gran cantidad de memoria, debido a que este requerimiento es proporcional al cuadrado del número de pesos —aquí funciona bastante bien— puesto que las variables de entradas son siete en algunos casos y cinco en otros (García et al., 2005).

Este algoritmo se utiliza para linealizar, al asumirse que la función multivariada del proceso de la red es lineal. Como siempre, se busca que los procesos de la red pasen una vez por cada nodo y el mínimo se encuentre en una sola iteración de cálculo, al compararlo para observar si ha disminuido con el fin de modificar los pesos.

Durante el entrenamiento, en el comportamiento del algoritmo Levenberg Marquardt, se presentan oscilaciones; esto es debido a los pasos de cálculo con la hipótesis lineal que

al presentarse se eliminan, o corrigen, al hacer los pasos menores y al tener en cuenta la pendiente.

Para las funciones de transferencia, siempre está el dilema de cual usar, una de las más populares es la sigmoidea. Sin embargo, se han probado varias relaciones entre las funciones, como la tangente hiperbólica con la lineal y la logística con la logística. Estas dan resultados similares en el desempeño y en las aplicaciones estadísticas (Maier y Dandy, 2000; Olden y Jackson, 2002; Bishop, 1996).

En cuanto al desempeño de los datos obtenidos de la red neuronal, este fue analizado por medio del error medio (ME), el error cuadrático medio (MSE) y el coeficiente de determinación (R^2) —entre los valores observados y los calculados— al aplicarse el modelo en las tres instancias: entrenamiento, validación y prueba o test.

2.7.2 Escogencia de las variables iniciales. Con relación a la arquitectura de la red neuronal artificial, esta se planteó en una capa de entrada, donde ingresan las variables independientes, una función de activación sigmoidea en la capa oculta, una función de activación lineal en la capa de salida y el algoritmo levenberg marquard —para entrenar las redes— debido a la eficiencia, simplicidad y alta velocidad. Los datos que se usaron en grupos fueron el 70 % para entrenamiento, el 15 % para la validación y el resto para el test final. Estos valores vienen por defecto en el modelo; sin embargo, los resultados no difieren en gran medida y presentan proporciones similares (p. ej., 60, 20 y 20) (sarmadian et al., 2010).

Para que el modelo sea estadísticamente estable, las redes generaron muchas redes, pero solo almacena el que esté por encima del 80 % del promedio del entrenamiento, la validación y el test. En lo que respecta a la generación de modelos, esta continuó hasta alcanzar los 50 000, donde se detuvo el proceso para escoger el modelo que presentó el mejor desempeño. De esta forma, los datos de los modelos se compararon con el MSE y el R^2 , tanto de los generados por la red neuronal como los determinados por las ecuaciones planteada por otros autores. Así, en la Tabla 2, se observan las variables

finamente seleccionadas, para generar los modelos en las redes neuronales de cada variable predicha.

Tabla 2: Variables seleccionadas (las casillas sombreadas) para alimentar el modelo de red neuronal mediante la aplicación del método paso a paso

Variables	BD		AW		FC		WP	
1 y	1	0,728	2	0,665	12	0,8061	12	0,7716
2 demfill	10	0,805	1	0,755	1	0,8383	1	0,8298
3 slope	2	0,822	12	0,825	3	0,8487	2	0,8535
4 curvatura	8	0,841	6	0,848	2	0,8526	3	0,8715
5 Accum	3	0,852	10	0,873	11	0,8799	9	0,8788
6 Espesor (cm) Profundidad	9	0,869	11	0,869	4	0,8765	11	0,8671
7 centroide	11	0,874	8	0,895	6	0,8676	6	0,8677
8 %ARENAS	6	0,858	7	0,837	8	0,8791	10	0,8537
9 %ARCILLAS	4	0,882	5	0,848	9	0,8860	8	0,8801
10 % CO	5	0,858	4	0,819	5	0,8621	7	0,8519
11 cover	7	0,857	9	0,826	10	0,8503	5	0,8552
12 BD			3	0,783	7	0,8393	4	0,8234

Latitud (*y*), altura sobre el nivel del mar (*demfill*), pendiente (*slope*), curvatura del terreno (curvatura), acumulación del drenaje (*accum*), profundidad del horizonte desde la superficie (*espesor*), medida en metros del horizonte (*centroide*), contenido en porcentaje de arenas (*%arenas*), contenido en porcentaje de las arcillas (*%arcillas*), contenido en porcentaje del carbono orgánico (*% CO*), tipo de cobertura que presenta el terreno (*cover*), BD: densidad aparente, AW: contenido de humedad del suelo, FC: capacidad de campo, WP: punto de marchitez permanente.

En lo que concierne a las variables iniciales (12), estas fueron seleccionadas a partir de las correlaciones de Pearson y Spearman. Para ello se buscó que no hubiese redundancia en las variables, pues si una está relacionada con otra, no es necesario poner las dos, tan solo con una es suficiente.

Es así como la correlación de Pearson se ha usado en varias investigaciones y en diversos campos. Entre estos, Yashuang et al. (2018) plantearon la correlación de Pearson como un colaborador en los procesos de los árboles de decisión, al dar una medida de la calidad de las características, para confirmar los atributos de división óptimos en el crecimiento de los árboles. Por otro lado, Bugna et al. (2020), en el estudio de trazadores para el estudio de humedales aislados en Florida, utilizaron este coeficiente para relacionar las diferentes variables que estudiaron, entre estas: la humedad, la precipitación, la temperatura y la estacionalidad, y encontraron relación de estas con los isotopos.

Por último, los números indican cuál es la variable elegida en cada grupo, de acuerdo con su numeración en la columna izquierda de la Tabla 2.

2.7.3 Árboles altamente aleatorizados (*Extra Trees*). El procedimiento consiste en generar los arboles como lo hace los árboles de regresión, sin ninguna restricción (de arriba hacia abajo), al seguirse un camino que hace clasificaciones de acuerdo con sus valores o características; así, un nodo tiene la característica seleccionada, la cual usa para dividir los datos que ingresan, y las ramas son los valores en que se ha dividido dicho nodo.

En cuanto a los árboles altamente aleatorizados, estos van un paso más adelante del total de los datos que genera para la predicción. De este modo, solo se evalúa una parte aleatoriamente y de estos puntos se escogen algunos, para agilizar el proceso de predicción y —en algunos casos— reducen la varianza. La diferencia se observa en los nodos, donde el modelo hace cortes completamente aleatorios y utiliza todo el conjunto de datos disponibles para generar los árboles (Mao y Wang, 2012; Rodrigo, 2017).

Para explicar los árboles altamente aleatorizados, hay que referirse inicialmente a los bosques aleatorios y a los árboles aleatorios. Los árboles aleatorios utilizan la división de los espacios de predicción al generar varias subregiones: en este punto esto se ha

llamado nodo. En cada nodo, se tienen una cantidad de datos del conjunto total que se usan para el entrenamiento; así, la clasificación mayor o más frecuente es la que se utilizará para la validación de los datos.

Con la finalidad de saber cuál es el grupo de datos predominantes, se aplica el índice de Gini. Este índice hace una sumatoria de las clases en cada nodo a través de división binaria (en síntesis, dos conjuntos), con las observaciones de cada grupo.

$$G = \sum_{k=1}^k P_{mk} (1 - P_{mk})$$

Ecuación 17: Índice de Gini.

Donde G es el índice de Gini, k es la cantidad de clases presentes en una región de la división binaria y P_{mk} es el número de observaciones de la clase k en la región m . De este forma, lo que se busca es que el valor del índice de Gini se acerque a cero; en otras palabras, se habla de la pureza de los datos de cada grupo, y de la división que se hace en el nodo.

Así, el árbol comienza con todo el conjunto de datos y hace particiones de arriba hacia abajo. De esta manera, las divisiones se van haciendo en la búsqueda del mejor índice de Gini; no obstante, es posible que en divisiones posteriores, al no minimizar el índice, se consigan mejores clasificaciones (Geurts et al., 2006).

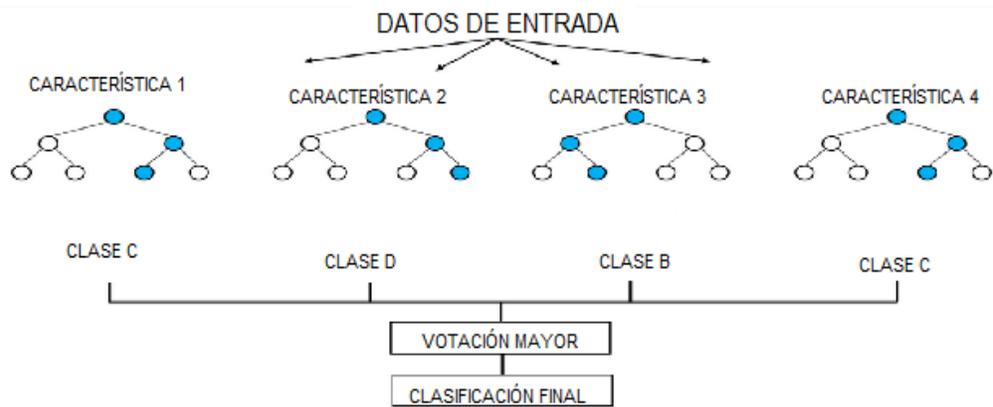
Debido a que un solo árbol no es un buen predictor, se hace necesario crear varios modelos, de los cuales, posteriormente, se promedian las predicciones y se llega a un consenso. Para ello, se deben tomar varias muestras del conjunto de datos, se observa la varianza y se trata de minimizar esta, debido a que se hace con el conjunto de datos de entrenamiento con el cual se está trabajando en ese momento. Lo anterior puede generar muchos conjuntos de entrenamiento; sin embargo, con el *Bootstrap* se logra lo anterior y se le pone coto al llegar solo al conjunto de predictores que se desee.

Por lo tanto, el número de modelos generados son árboles y la predicción se hace por consenso. En este contexto, este número de árboles a entrenar es uno de los parámetros a tener en cuenta; en general, se escoge un valor elevado con el fin de minimizar el error de clasificación.

Con relación a la construcción de los bosques aleatorizados, se le adiciona una condición en el nodo. De esta forma, cada vez que haya que hacer una división se saca una muestra m de predictores, esto se hace aleatoriamente y no con todo el conjunto de estos. Como se toman diferentes m predictores, generalmente se hace $m = \sqrt{p}$. Lo anterior, hace que los árboles sean diferentes, que no estén relacionados, lo cual reduce más la varianza. Esto hace que el clasificador final se asemeje más al modelo real, al tener m número de predictores en vez de p (Geurts et al., 2006).

En lo que concierne a los árboles altamente aleatorizados (*Extra Trees*) estos crecen; sin embargo, se proponen dos diferencias: la primera es que divide los nodos con puntos de corte completamente de manera aleatoria, y la segunda es que usa todo el conjunto de datos de aprendizaje para que los árboles se desarrollen. De esta forma, se tienen en cuenta dos parámetros, k que es el número de atributos seleccionados aleatoriamente en cada nodo y n_{min} que son los datos mínimos de muestra para dividir el nodo. Debido a que se generan varios árboles con la muestra completa, se llega a un modelo de conjunto, y la cantidad de árboles se registra con M .

Al final, con todo el conjunto de árboles, se hace un promedio aritmético para valores y por mayoría en el caso de la clasificación. Desde el punto de vista de la varianza y el sesgo, el corte en los nodos aleatorio, junto con el uso de todos los datos de la muestra de entrenamiento —a diferencia del método *Bootstrap*— conlleva a una minimización de estos indicadores (Geurts et al., 2006).



Representación de los árboles altamente aleatorizados en clasificación.

En lo que concierne al orden que sigue el algoritmo de los árboles altamente aleatorizados, este se muestra a continuación.

Construye un conjunto de árboles extremadamente aleatorizados (S).

Entrada: un conjunto de entrenamiento S.

Salida: un conjunto de árbol $T = \{t_1, \dots, t_M\}$.

Para $i = 1$ a M

- Generar un árbol: $t_i =$ Construir un árbol adicional (S);
- Devuelve T.

Construye árboles extremadamente aleatorizados (S).

Entrada: un conjunto de entrenamiento S.

Salida: un árbol t.

- Devuelva una hoja etiquetada por frecuencias de clase (o salida promedio, en regresión) en S, si:

- (i) $|S| < n_{\min}$, o
- (ii) todos los atributos candidatos son constantes en S, o
- (iii) la variable de salida es constante en S

- De otra parte:

1. Seleccione aleatoriamente K atributos, $\{a_1, \dots, a_K\}$, sin reemplazo, entre todos (no constante en S) atributos del candidato;

2. Genera K divisiones $\{s_1, \dots, s_K\}$, donde $s_i = \text{Elija una división aleatoria } (S, a_i), \forall i = 1, \dots, K$;
3. Seleccione una división s^* tal que $\text{Score}(s^*, S) = \max_{i=1, \dots, K} \text{Score}(s_i, S)$;
4. Divida S en los subconjuntos S_l y S_r de acuerdo con la prueba s^* ;
5. Genere $t_l = \text{Construya un árbol extra } (S_l)$ y $t_r = \text{Genere un árbol extra } (S_r)$ a partir de estos subconjuntos;
6. Cree un nodo con la división s^* , adjunte t_l y t_r como subárboles izquierdo y derecho de este nodo y devuelva el árbol resultante t .

Elije una división aleatoria (S, a)

Entrada: un conjunto de entrenamiento S y un atributo a .

Salida: una división.

- Si el atributo a es numérico:

- Calcular el valor máximo y mínimo de a en S , denotados respectivamente por a_{Smin} y a_{Smax} ;
- Dibuja un punto de corte ac uniformemente en $[a_{Smin}, a_{Smax}]$;
- Devuelve la división $[a < ac]$.

- Si el atributo a es categórico (denota por A su conjunto de valores posibles):

- Calcular como el subconjunto de A de los valores de a que aparecen en S ;
- Dibuje aleatoriamente un subconjunto A_1 no vacío adecuado de AS y un subconjunto A_2 de $A \setminus AS$;
- Devuelva la división $[a \in A_1 \cup A_2]$.

(Adaptado de Geurts et al., 2006)

De este modo, se escogieron las redes neuronales y los árboles altamente aleatorizados para el análisis de los datos colectados por las siguientes razones:

Existen varias técnicas de aprendizaje con datos, donde se utilizan estos para el entrenamiento y la validación de modelos que no son paramétricos; sin embargo, las redes neuronales son una técnica que se ha utilizado por varios investigadores, con el fin de plantear funciones de edafotransferencia; a su vez, es una metodología probada

y que arroja buenos resultados en este tipo de datos y análisis (Bayat et al., 2011; Sarmadian y Keshavarzi, 2010; Pachepsky et al., 1996).

Dichas redes neuronales han sido utilizadas para resolver problemas similares, dada su capacidad para tratar relaciones no lineales entre los datos.

En cuanto a los árboles altamente aleatorizados, estos reúnen tres técnicas desarrolladas para la clasificación y cálculo de variables. Lo anterior se recoge en la construcción de los árboles, los bosques aleatorios y los árboles altamente aleatorizados; de esta forma, estos han sido avances en este tipo de técnicas de aprendizaje.

Con relación a las dos técnicas, estas tienen arquitecturas y conceptualizaciones matemáticas diferentes; por lo tanto, es interesante evaluar el desempeño de estas en el caso que nos ocupa: los suelos andinos neotropicales.

En cuanto a las técnicas de aprendizaje, existen otras para el tratamiento de los datos; mas, el tiempo es limitado para aprender e implementar su uso; sin embargo, en un futuro se pueden explorar esas técnicas.

En cuanto al grupo de investigación “Cuencas Hidrográficas de la Facultad de Ingeniería Forestal de la Universidad del Tolima”, este tiene experiencia en la implementación y evaluación de este tipo de modelos, los cuales han arrojado buenos resultados con las modelaciones que se han logrado con ellos.

3. RESULTADOS

Descripción de las propiedades hidrodinámicas obtenidas en este estudio.

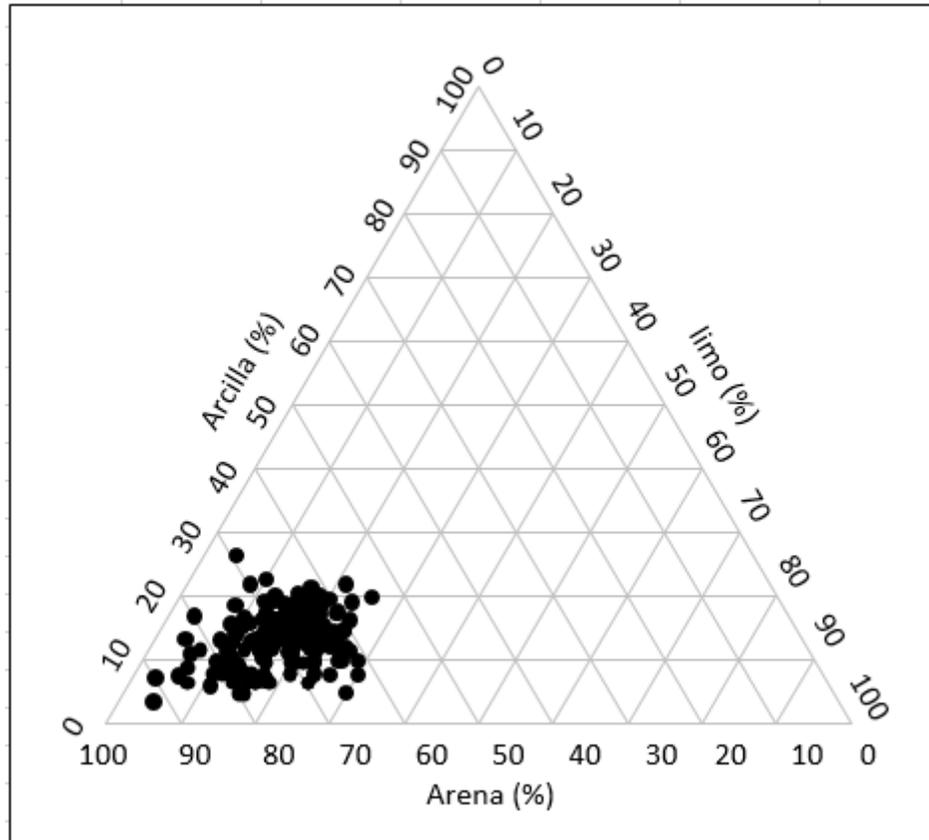
3.1 TEXTURA

Para la determinación de la textura es necesario calcular las fracciones del tamaño de las partículas —básicamente las arenas, los limos y las arcillas— las cuales están determinadas por unos límites de diámetro. Para ello, al suelo en solución donde está con todos los componentes, sales y materia orgánica, se le adiciona un dispersante químico con el fin de separar los tamaños de las partículas, y así se procede a determinar su proporción (USDA, 2014).

En cuanto a las texturas encontradas en las diversas muestras colectadas, estas presentan una tendencia arenosa franca y franca arenosa, con predominio de arenas (58 % - 92 %) con rangos de diámetros entre los 0,05 mm y los 2,0 mm. (Figura 5). Con respecto a las arcillas, estas presentan un rango más amplio de contenidos (3,2 % - 23,7 %) y un tamaño de partículas con diámetros menores a las 2 micras.

Con relación a los limos, estos están comprendidos entre los 0,002 mm a los 0,05 mm. Su recurrencia mínima está por el orden del 1,8 % y alcanza un máximo del 29 %. En lo que concierne al rango del tamaño de las partículas, este indica una alta influencia de las texturas gruesas al considerarse que las otras fracciones sirven de aglutinantes para la textura predominante.

Figura 5: Triángulo textural de las muestras analizadas en laboratorio por el método de Bouyucos.



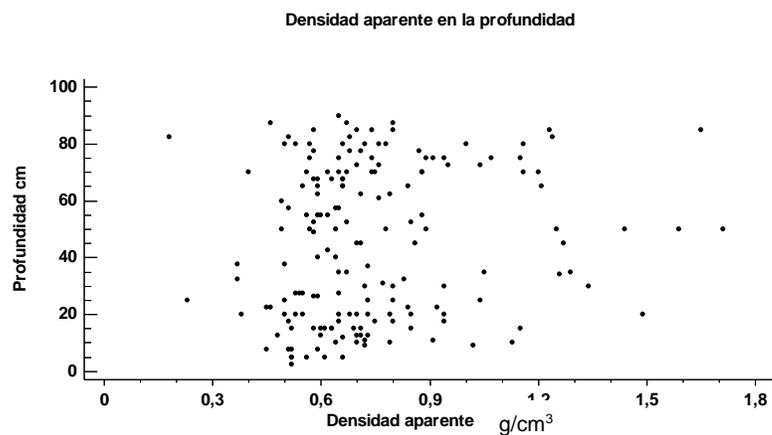
3.2 DENSIDAD APARENTE

En lo que respecta al promedio del valor de la densidad aparente (alrededor de los $0,74 \text{ g/cm}^3$), esta varía entre las diferentes muestras, desde los $0,18 \text{ g/cm}^3$ hasta los $1,71 \text{ g/cm}^3$; dicha variación tan amplia se debe a los contenidos de materia orgánica en la superficie.

Como se observa en la Figura 6, existe una amplia variabilidad en los datos —con densidades entre los $0,6 \text{ g/cm}^3$ y los $0,9 \text{ g/cm}^3$ — donde se ubica la mayoría de los datos analizados y se presentan en todas las profundidades. Quizás, se puede deber a los contenidos de materia orgánica en estas zonas, donde no hay una gran o rápida

transformación de este compuesto, el cual proviene en gran medida del material vegetal, y se acumula e influye en el valor de la densidad aparente. En la Tabla 2, se muestran las variables seleccionadas para alimentar los modelos de las redes neuronales y los árboles altamente aleatorizados. A su vez, se observa que el contenido de la materia orgánica es un componente principal para la determinación de la densidad aparente y el agua disponible, lo cual indica que es una variable influyente en las funciones de edafotransferencia.

Figura 6: Dispersión de los datos de la densidad aparente con respecto a la profundidad.



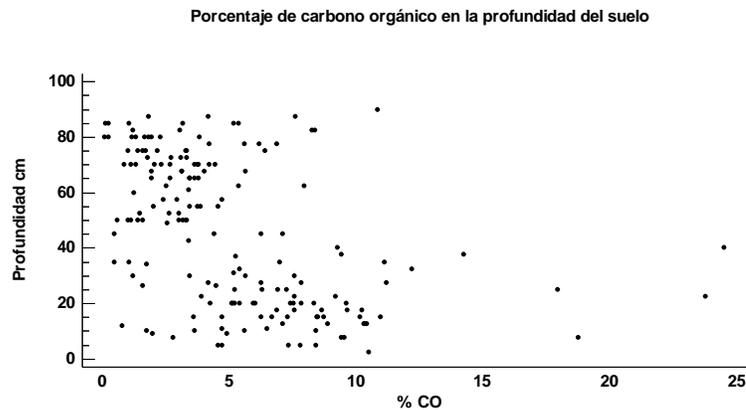
3.3 CARBONO ORGÁNICO Y MATERIA ORGÁNICA

En cuanto a esta variable oscila entre el 0,14 % y el 24,48 %, con un promedio del 5,14 %. Este rango de valores disminuye con la profundidad, pues los valores más altos siempre se encuentran en la superficie del suelo, donde se acumula y descompone la materia orgánica.

De este modo, cuanto mayor es la profundidad más reducido es este valor (Figura 7). Si bien, la tendencia generalizada es que el contenido de la materia orgánica disminuye con la profundidad, en las cuencas por encima de los 1500 metros de altura, el proceso

de descomposición de la materia orgánica es lento y en algunos lugares el valor es significativo a profundidades mayores a los 50 centímetros.

Figura 7: Dispersión de los datos de la relación del porcentaje de carbono orgánico y la profundidad a la que se obtuvieron las muestras.



3.4 RETENCIÓN DE HUMEDAD

En cuanto a la capacidad del suelo para retener el agua, esta está relacionada con la capacidad de campo y el punto de marchitez permanente, donde se observa que tiene relación con la profundidad y el porcentaje de carbono orgánico.

En forma general, la capacidad de retención de agua disminuye con la profundidad; sin embargo, aquí no se presentan grandes cambios y la media de esta retención es de $0,15 \text{ cm}^3/\text{cm}^3$ (relación suelo-agua) (Figura 8).

Con respecto a la relación con el contenido de carbono orgánico, este se presenta en todas las zonas y su media es de 5,2 %; por lo tanto, no se observan tendencias, sino un área de dispersión de los datos. Con relación a los valores en todos los perfiles, estos varían entre los $0,05 \text{ cm}^3/\text{cm}^3$ a $0,20 \text{ cm}^3/\text{cm}^3$ de contenido de humedad, así, los diferentes contenidos de carbono orgánico no superan en gran medida el 10% (Figura 9).

Figura 8: Dispersión de los datos de la retención de agua con respecto a la profundidad.

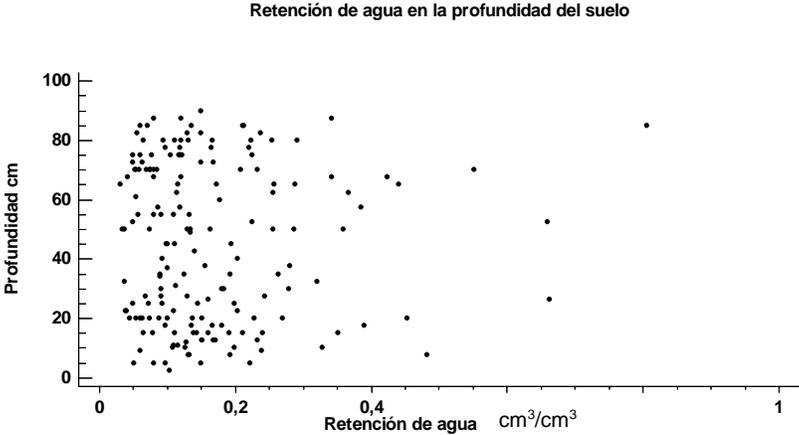
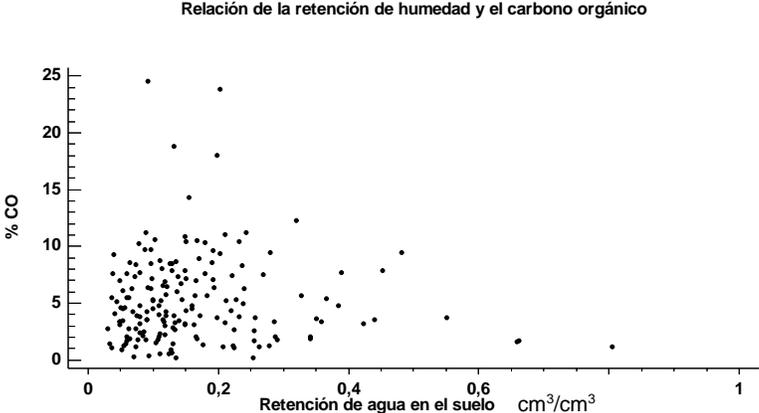


Figura 9: Dispersión de los datos de la retención de agua y el contenido de carbono orgánico encontrado en las muestras.



3.5 ANÁLISIS DE LAS VARIABLES PREDICTIVAS, CON LOS MODELOS EXISTENTES

En este ámbito, con los datos obtenidos se procedió a alimentar los modelos relacionados en SOILPAR 2.0 (Acutis y Donatelli, 2003), Tomasella et al. (2003), Rosetta (Schaap et al, 2001) y RETC (Van Genuchten, 1987). En la Tabla 1, se presentan las

variables independientes que necesitan cada modelo y los resultados que ofrece. En las Figuras 10 y 11 se muestran los datos predichos para la densidad aparente, donde se observan los diversos comportamientos con los mismos datos de entrada a las diferentes respuestas de los investigadores.

3.5.1 Densidad aparente. En cuanto a los planteamientos de Rawls (1982) y Baumer (1994), estos presentan resultados similares (Figura 10 y 11). Su ajuste a una ecuación lineal, comparada con los datos obtenidos en laboratorio, solo explica el comportamiento del 18,4 % en el mejor de los casos, con Baumer; en el caso de Rawls, esta relación es muy baja y se observa que no es adecuado para el cálculo de la densidad aparente en el caso de estas muestras de suelo.

Con relación al error cuadrático medio y su raíz cuadrada, se muestra también que estos datos son altos y se confirma que no presentan una buena aproximación de los datos reales (Tabla 3).

Tabla 3: Evaluación de ajuste de los modelos para la densidad aparente (BD).

		R ²	MSE	RMSE	ME
BD					
	Baumer	0,1837	0,890	0,943	-0,9061
BD	BD Rawls	0,0142	1,024	1,012	-0,9761

R²: coeficiente de determinación, MSE: error cuadrático medio, RMSE: raíz del error cuadrático medio, ME: error medio

Figura 10: Densidad aparente (DA) observada y comparada con el modelo de Baumer.

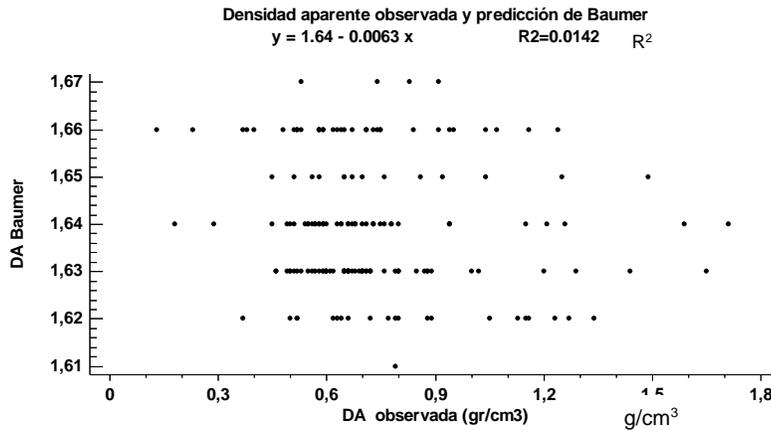
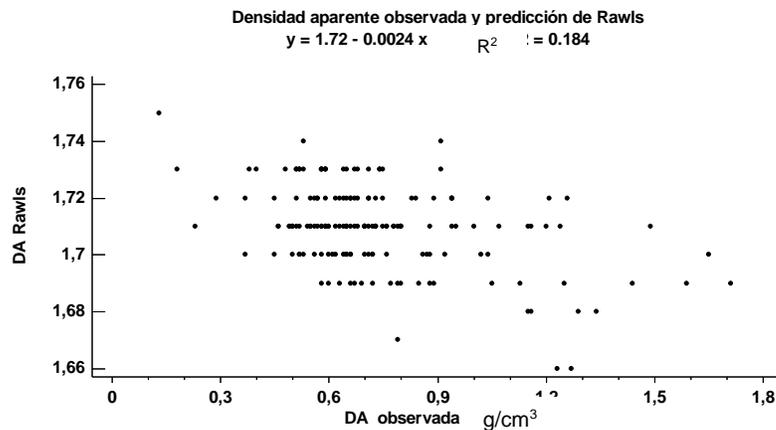


Figura 11: Densidad aparente observada y comparada con el modelo de Rawls



3.5.2 Punto de marchitez permanente. Para todos los casos la predicción de los modelos no está muy bien representada. El coeficiente de determinación no sobrepasa el seis por ciento en el mejor de los casos (Tabla, 4) (Figuras 12 - 22), donde la predicción de Brakensiek llega al 5,6 % y Rosetta al 5,7 %; los demás autores reflejan datos mucho menores.

En cuanto a *British Top Soil* y *Tomasella* (Figuras 15 y 19), estos presentan coeficientes de determinación menores a uno, lo cual refleja la poca predicción para este tipo de suelos.

Con respecto al contenido de humedad para el punto de marchitez permanente de los datos tomados en campo, estos llegan hasta el 90 %. Así, los puntos predichos por los autores llegan al 60 %, como en el caso de Brakensiek (Figura 13); y Saxton y Rawls con valores máximos de 52% (Figura 20); para los demás autores, esta oscila entre el 10 % y el 30 %, la cual consideran ellos, es la capacidad de retención de agua —en el punto de marchitez permanente— de estos suelos con sus características.

En lo concerniente a los errores calculados, para todos los casos son altos. Estos varían entre el 0,2 cm³/cm³ (para Saxton y Rawls) y 0,42 cm³/cm³ (para Rawls), lo cual refleja la gran dispersión en los datos de los modelos propuestos por los investigadores (Tabla 4).

Tabla 4: Evaluación de ajuste de los modelos para el punto de marchitez (WP) en el suelo.

		R ²	MSE	RMSE	ME
	WP Baumer	0,03230	0,15739	0,39673	0,34723
	WP Brakiensek	0,05610	0,09002	0,30003	0,23740
	WP BSS	0,03733	0,14761	0,38420	0,33312
	WP BTS	0,00960	0,11608	0,34071	0,28654
	WP Hutson	0,04030	0,14457	0,38022	0,32900
WP	WP Manrique	0,04280	0,16181	0,40226	0,35443
	WP Rawls	0,01030	0,17742	0,42121	0,37517
	WP Tomasella	0,00210	0,06344	0,25187	0,17125
	WP Saxton	0,03330	0,04093	0,20231	-0,01089
	WP RETC	0,01830	0,12139	0,34841	0,29579
	WP Rosetta	0,05770	0,10266	0,32040	0,25412

R²: coeficiente de determinación, MSE: error cuadrático medio, RMSE: raíz del error cuadrático medio, ME: error medio

Figura 12: Punto de marchitez (WP) observado y comparado con el modelo de Baumer.

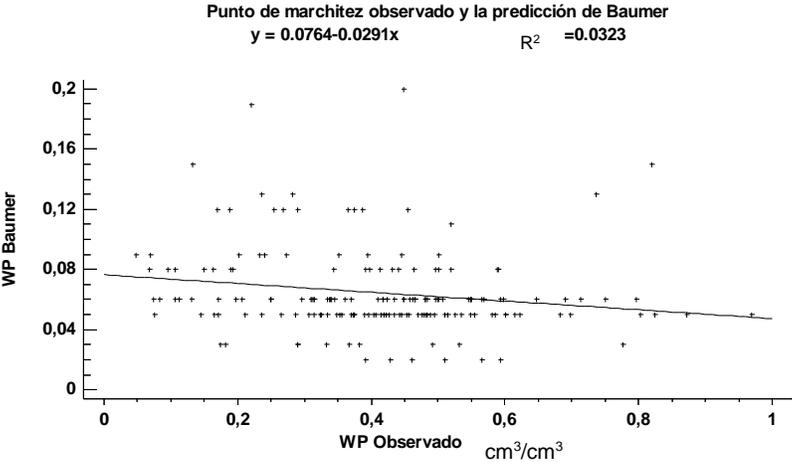


Figura 13: Punto de marchitez (WP) observado y comparado con el modelo de Brakensiek

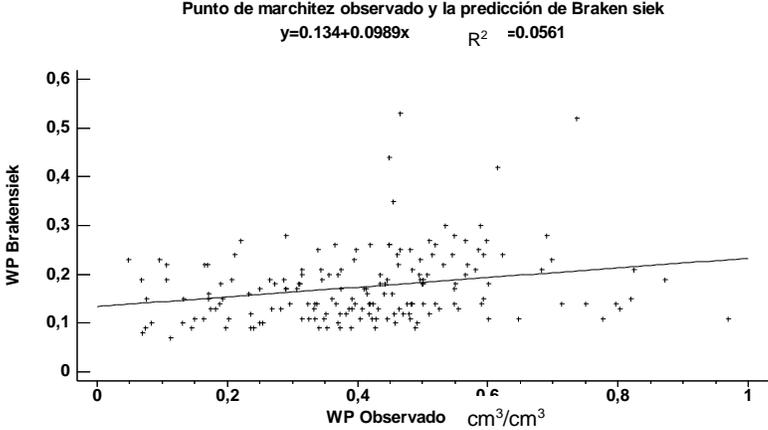


Figura 14: Punto de marchitez (WP) observado y comparado con el modelo de British Soil Survey Subsoil (BSS).

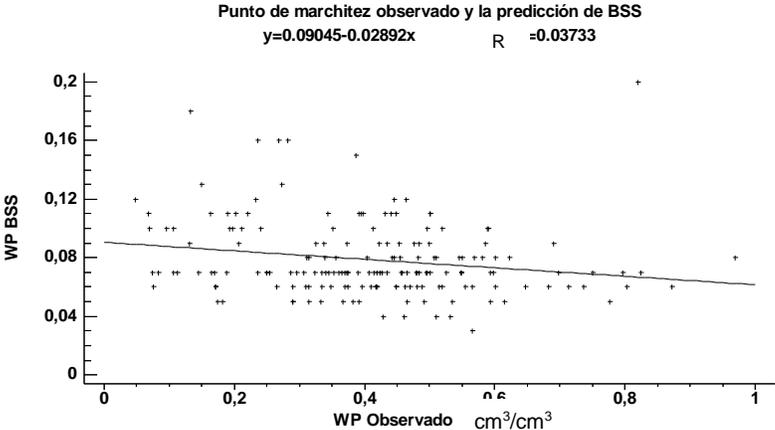


Figura 15: Punto de marchitez (WP) observado y comparado con el modelo de British Soil Survey Topsoil (BST).

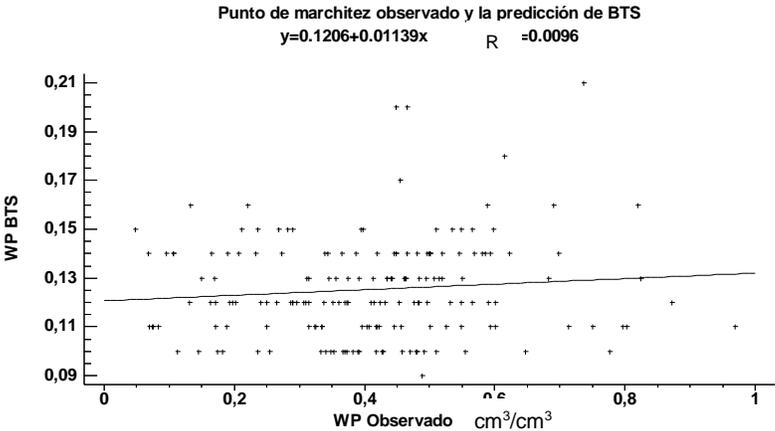


Figura 16: Punto de marchitez (WP) observado y comparado con el modelo de Hutson.

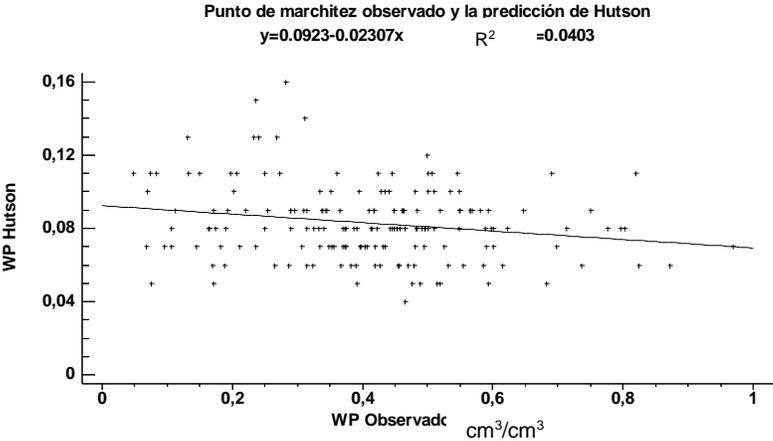


Figura 17: Punto de marchitez (WP) observado y comparado con el modelo de Manrique

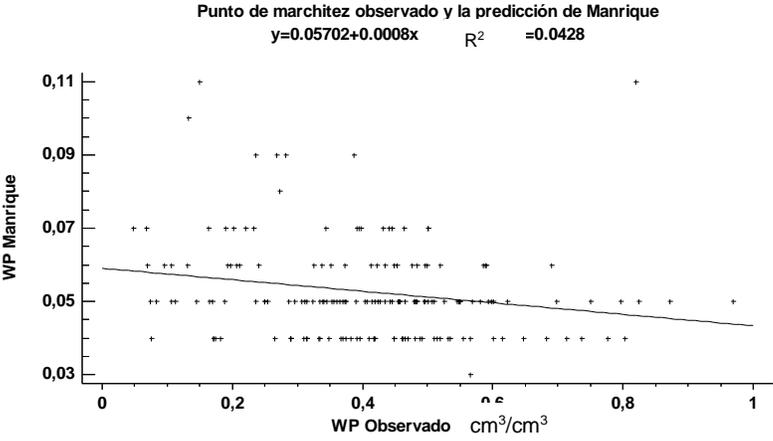


Figura 18: Punto de marchitez (WP) observado y comparado con el modelo de Rawls.

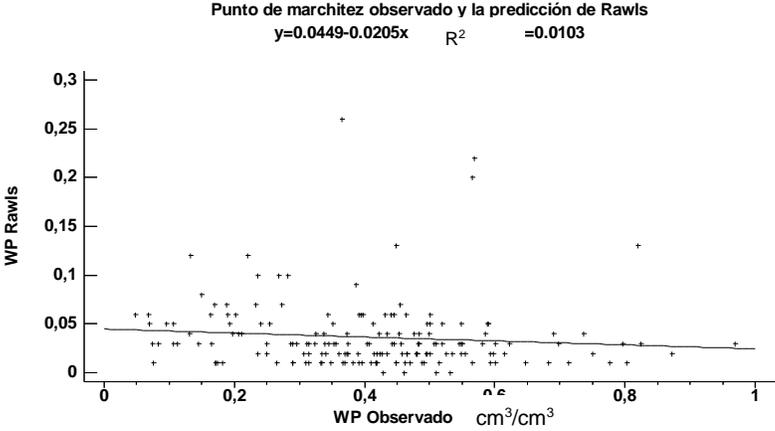


Figura 19: Punto de marchitez (WP) observado y comparado con el modelo de Tomasella.

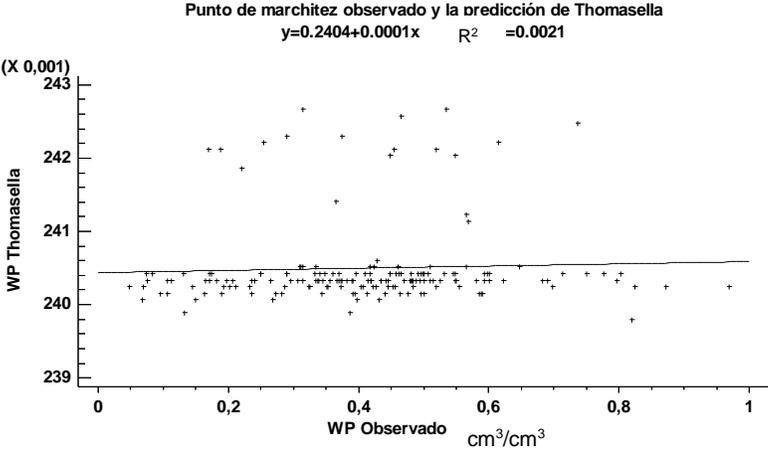


Figura 20: Punto de marchitez (WP) observado y comparado con el modelo de Saxton y Rawls.

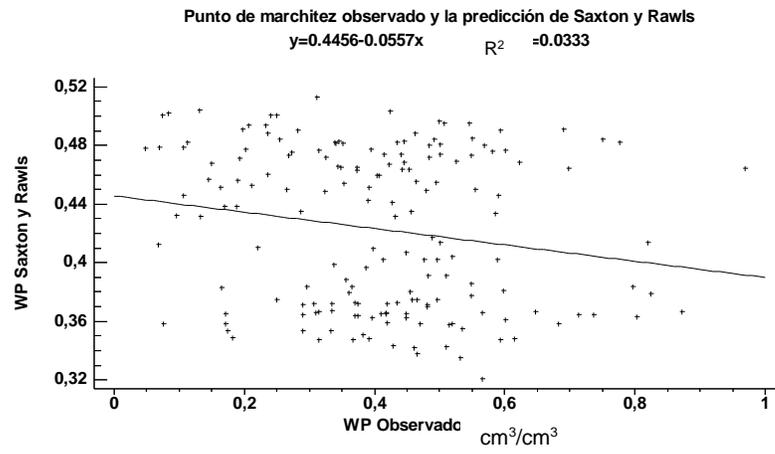


Figura 21: Punto de marchitez (WP) observado y comparado con el modelo RETC.

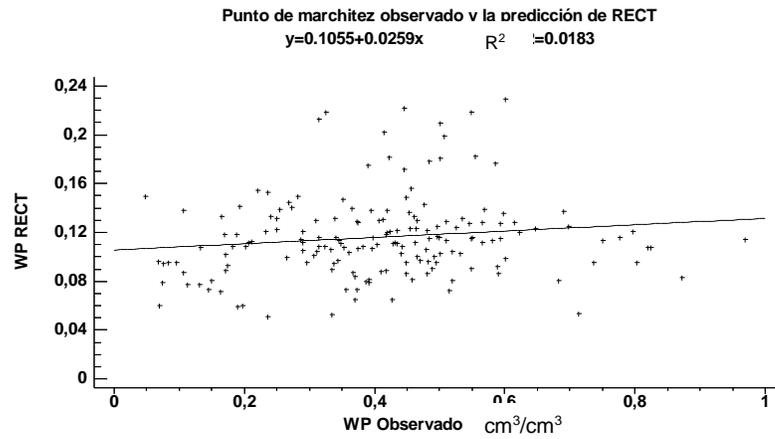
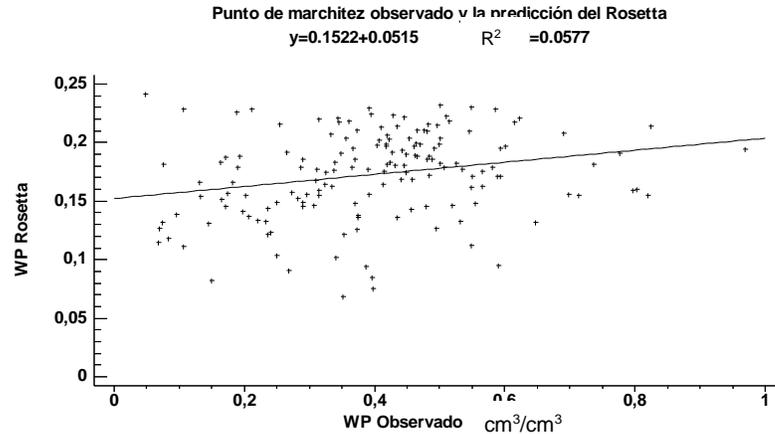


Figura 22: Punto de marchitez observado y comparado con el modelo Rosetta.



3.5.3 Capacidad de campo. Si bien, la capacidad de campo muestra coeficientes de determinación bajos en todos los casos, el modelo Rosetta (Figura 33) presenta el mejor desempeño con una explicación de los datos del 6,6 %. En contraste, Tomasella y Saxton presentan valores por debajo de uno (Figuras 30 y 31). Lo anterior indica que los modelos de los investigadores citados no tienen buena predicción para la capacidad de campo en los suelos andinos.

Con respecto a los valores de predicción, estos se presentan en todos los rangos desde 0 hasta $1 \text{ cm}^3/\text{cm}^3$. Brakensiek (Figura 24), *British Sub Soil* (Figura 25), Rosetta (Figura 33), y Saxton y Rawls (Figura 31) presentan los valores más altos y algunos cercanos a los valores obtenidos en laboratorio. Es de anotar que, si bien, se tiene este buen comportamiento de predicción de la capacidad de campo, la dispersión es alta.

En relación con el modelo RETC, el cual alcanza los valores máximos a los $0,4 \text{ cm}^3/\text{cm}^3$ (Figura 32); Tomasella a los $0,34 \text{ cm}^3/\text{cm}^3$ (Figura 30); Hutson a los $0,25 \text{ cm}^3/\text{cm}^3$ (Figura 27) y *British Top Soil* a los $0,38 \text{ cm}^3/\text{cm}^3$ (Figura 26), estos presentan los valores más bajos de predicción de la capacidad de campo y están lejos de los datos observados en campo.

En este ámbito, los errores se presentan altos en todos los casos (Tabla 5). Así, Rosetta muestra el menor error medio y la mejor explicación de los datos predichos; para el resto de los casos, los valores son elevados y llegan hasta los 0,43 cm³/cm³ en el modelo de Hutson (Figura 27).

Tabla 5: Evaluación de ajuste de los modelos para la capacidad de campo (FC) en el suelo

		R ²	MSE	RMSE	ME
	FC Baumer	0,0255	0,17641	0,42001	0,36269
	FC Brakiensek	0,0391	0,07634	0,27629	0,16051
	FC BSS	0,0367	0,10209	0,31951	0,24623
	FC BTS	0,0198	0,09905	0,31472	0,24589
	FC Hutson	0,0144	0,19153	0,43764	0,38714
FC	FC Manrique	0,0240	0,05859	0,24206	0,13080
	FC Rawls	0,0233	0,14915	0,38620	0,32137
	FC Tomasella	0,0014	0,08656	0,29422	0,21904
	FC Saxton	0,0011	0,04094	0,20233	-0,03740
	FC RETC	0,0203	0,10792	0,32851	0,26279
	FC Rosetta	0,0665	0,06938	0,26341	0,08516

R²: coeficiente de determinación, MSE: error cuadrático medio, RMSE: raíz del error cuadrático medio, ME: error medio

Figura 23: Capacidad de campo (FC) observada y comparada con el modelo de Baumer.

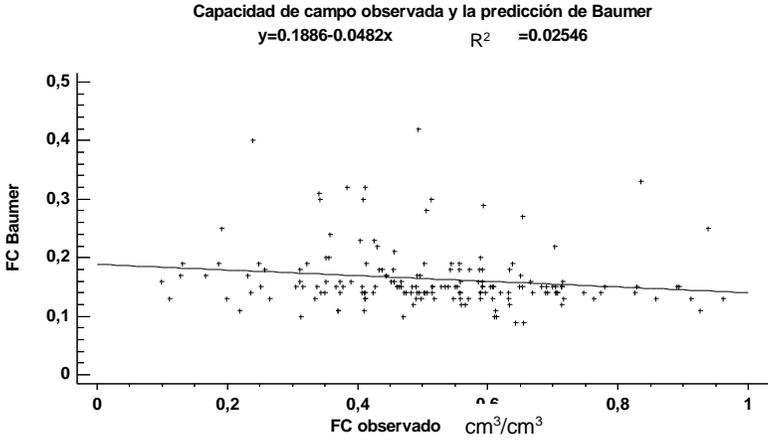


Figura 24: Capacidad de campo (FC) observada y comparada con el modelo de Brakensiek.

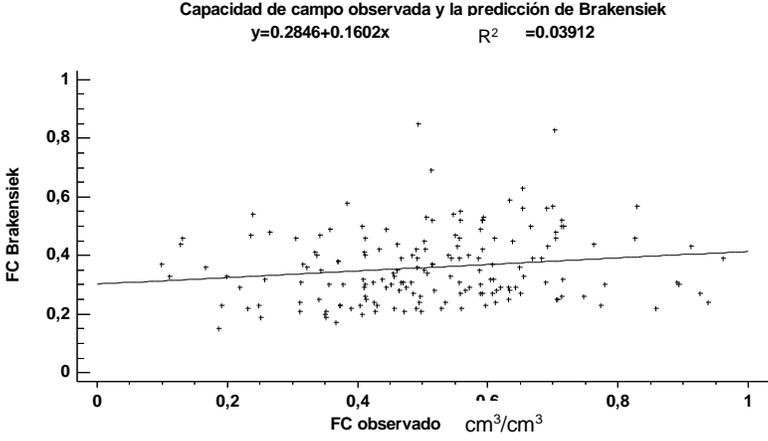


Figura 25: Capacidad de campo (FC) observada y comparada con el modelo de British Soil Survey Subsoil (BSS).

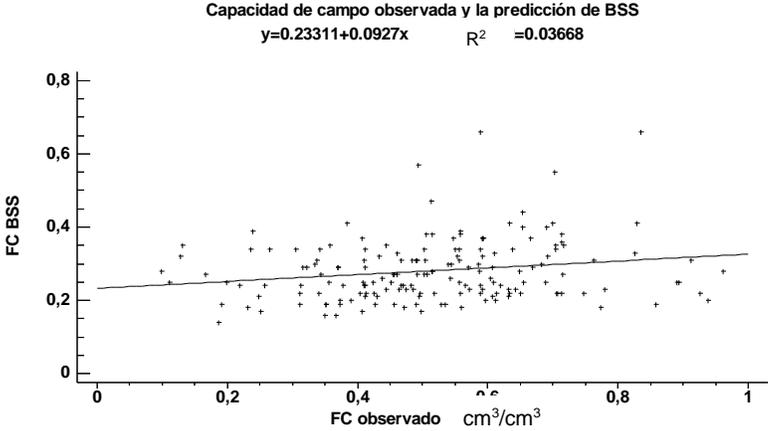


Figura 26: Capacidad de campo (FC) observada y comparada con el modelo de British Soil Survey Topsoil (BTS).

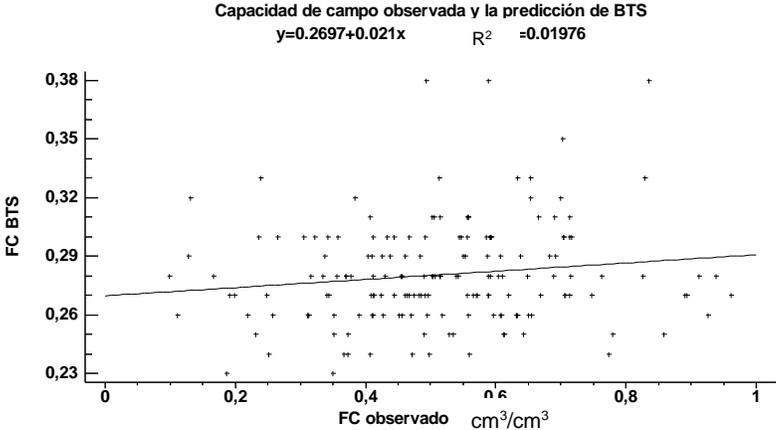


Figura 27: Capacidad de campo (FC) observada y comparada con el modelo de Hutson.

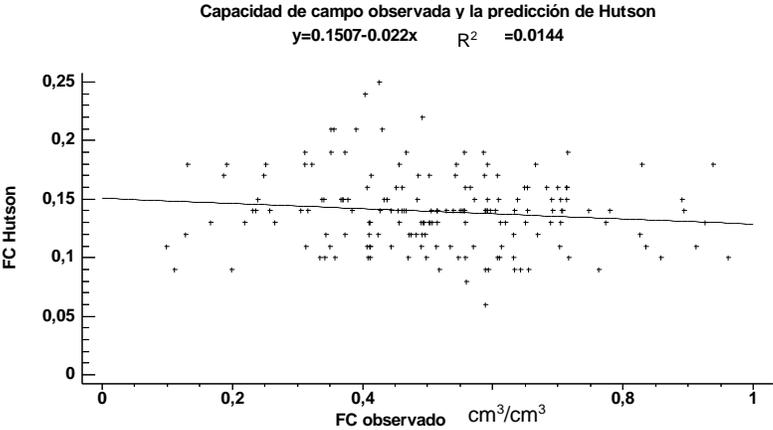


Figura 28: Capacidad de campo (FC) observada y comparada con el modelo de Manrique.

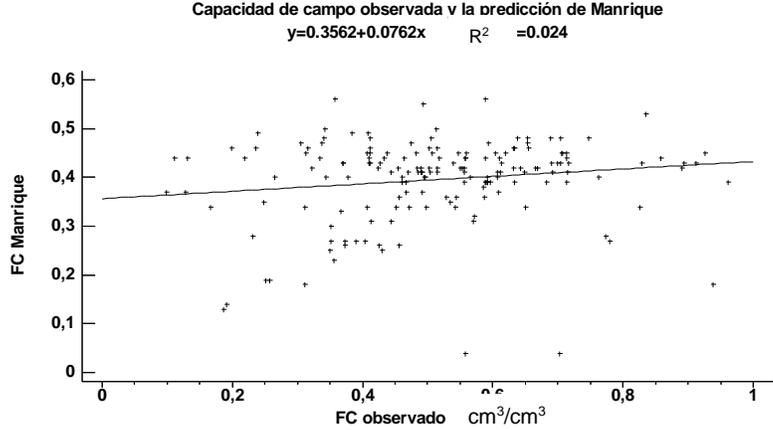


Figura 29: Capacidad de campo (FC) observada y comparada con el modelo de Rawls.

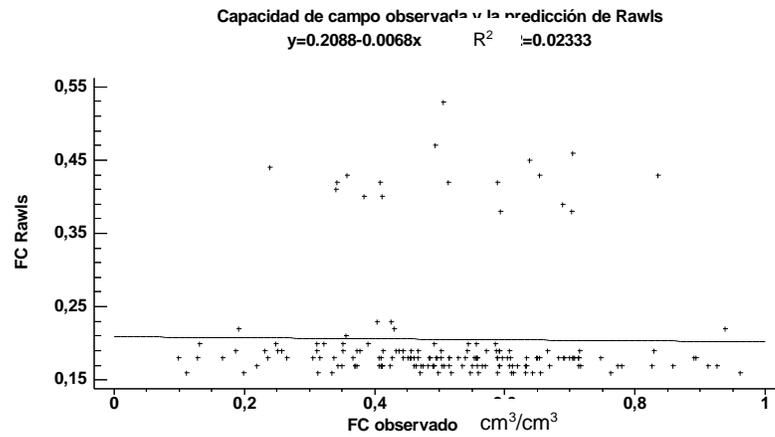


Figura 30: Capacidad de campo (FC) observada y comparada con el modelo de Tomasella.

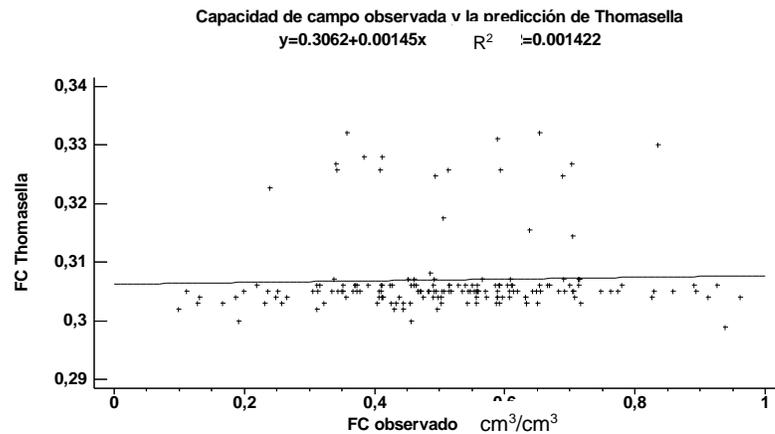


Figura 31: Capacidad de campo (FC) observada y comparada con el modelo de Saxton y Rawls.

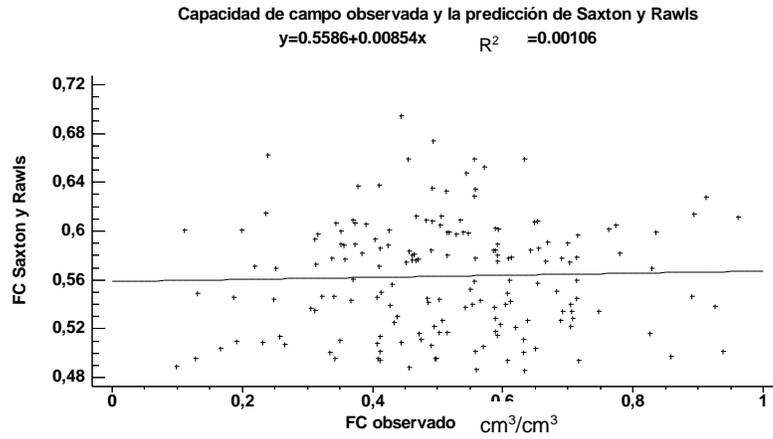


Figura 32: Capacidad de campo (FC) observada y comparada con el modelo RETC

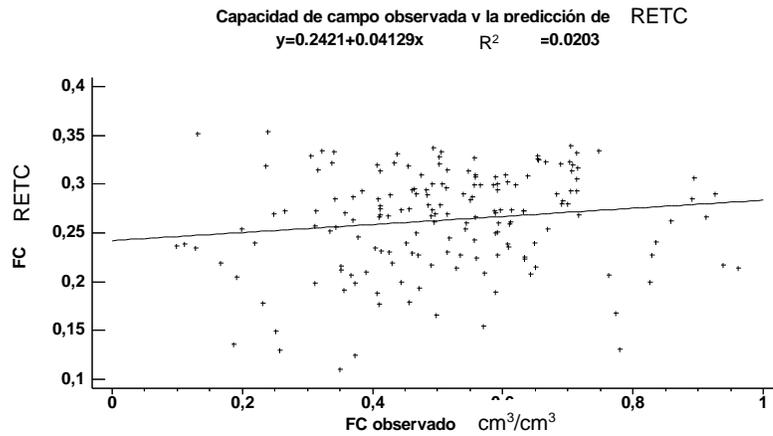
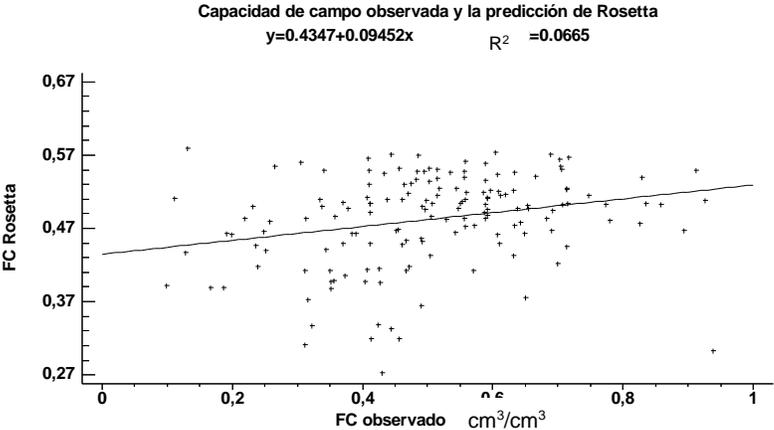


Figura 33: Capacidad de campo (FC) observada y comparada con el modelo Rosetta.



3.5.4 Retención de agua por el suelo. En relación con la diferencia entre el agua retenida a capacidad de campo y el punto de marchitez permanente, esta refleja el agua retenida disponible en el suelo. Dado que los resultados de las gráficas anteriores no son similares para los mismos autores, se comparó esta diferencia con la obtenida en laboratorio, y se observó el desempeño (Figuras 34 - 44).

Figura 34: Capacidad de retención de agua (AW) observada y comparada con el modelo de Baumer.

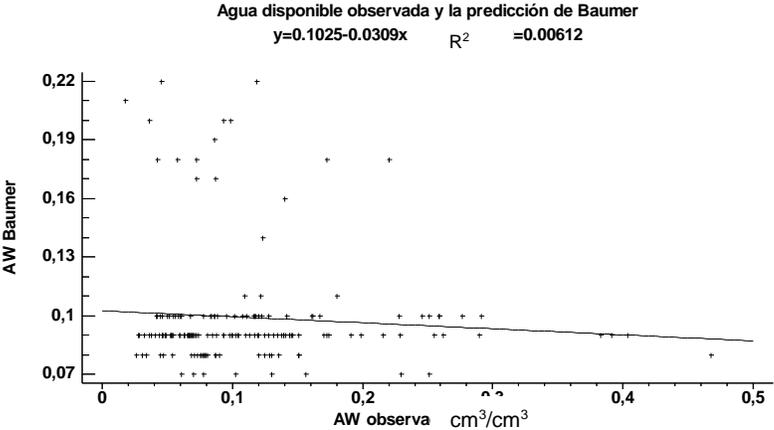


Figura 35: Capacidad de retención de agua (AW) observada y comparada con el modelo de Brakensiek.

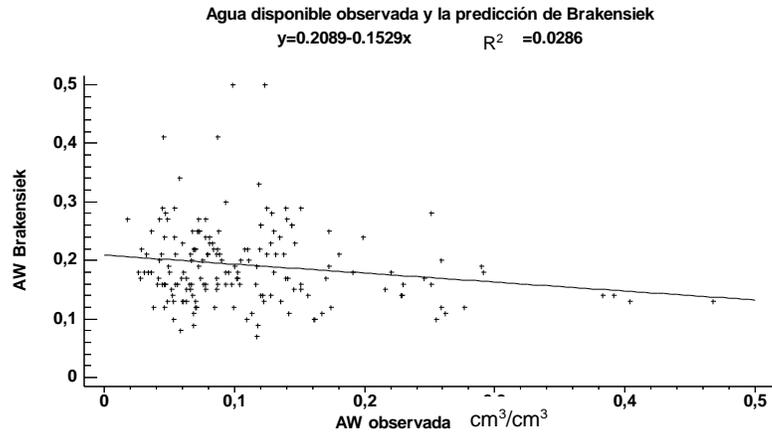


Figura 36: Capacidad de retención de agua (AW) observada y comparada con el modelo de British Soil Survey Subsoil (BSS).

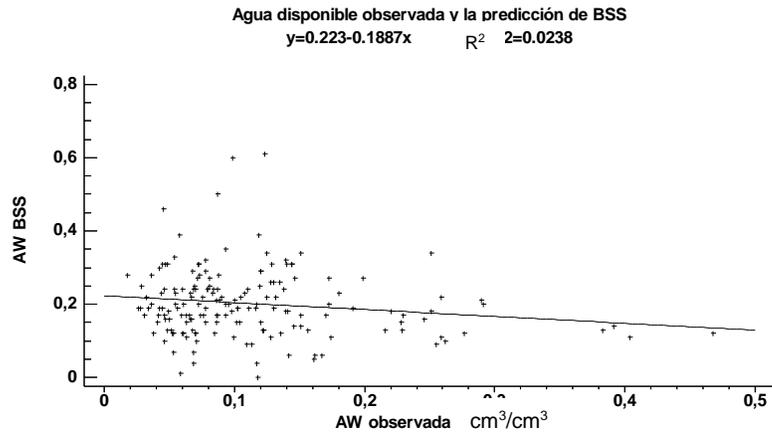


Figura 37: Capacidad de retención de agua (AW) observada y comparada con el modelo de British Soil Survey Topsoil (BTS).

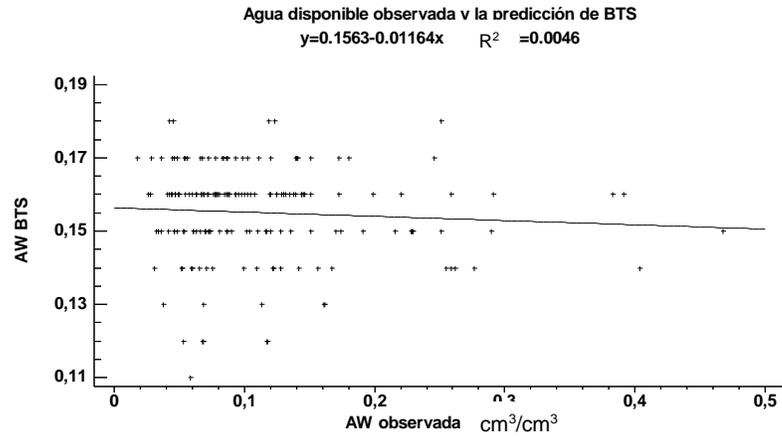


Figura 38: Capacidad de retención de agua (AW) observada y comparada con el modelo de Hutson.

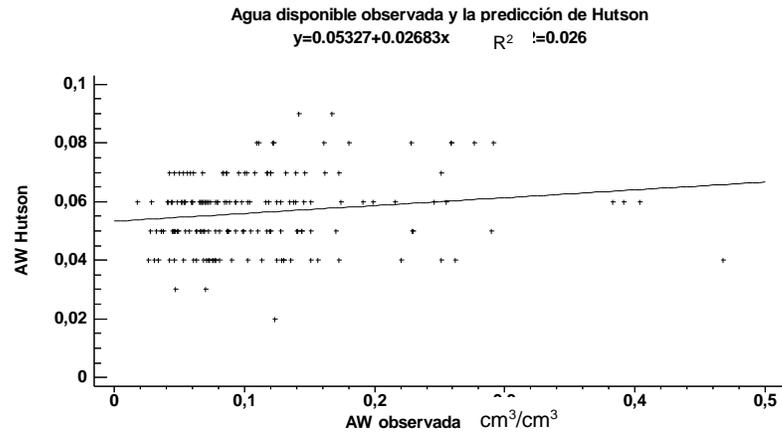


Figura 39: Capacidad de retención de agua (AW) observada y comparada con el modelo de Manrique.

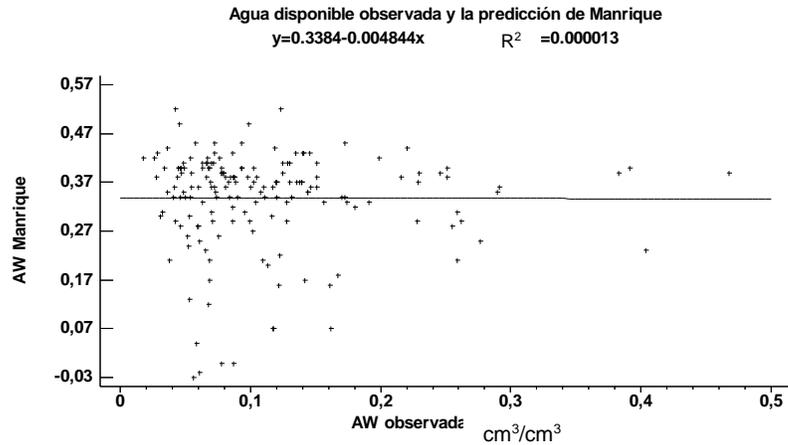


Figura 40: Capacidad de retención de agua (AW) observada y comparada con el modelo de Rawls.

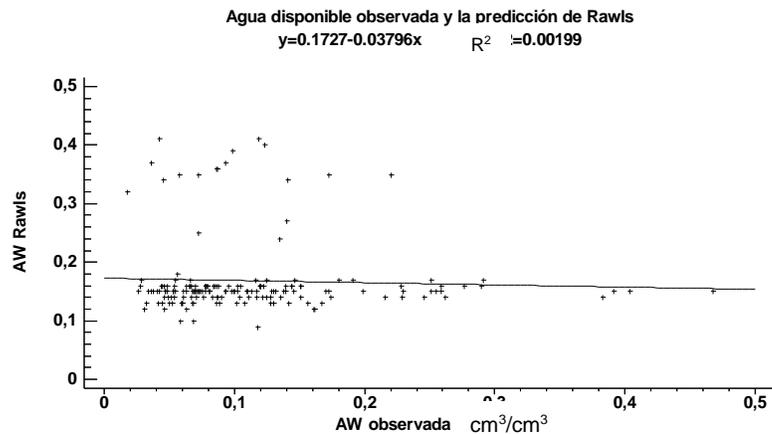


Figura 41: Capacidad de retención de agua (AW) observada y comparada con el modelo de Tomasella.

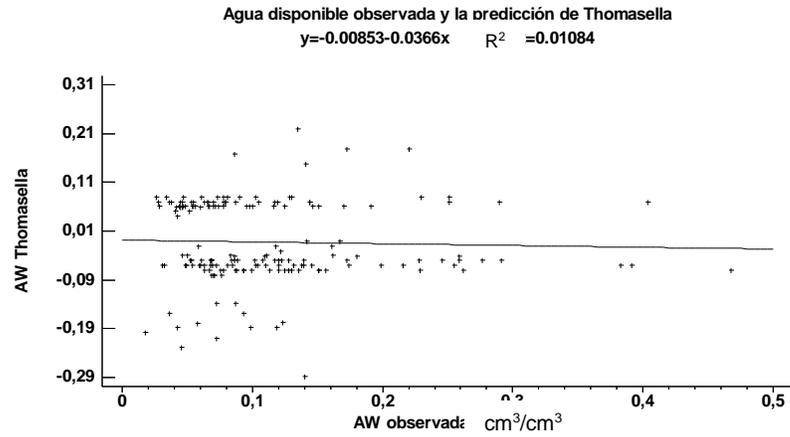


Figura 42: Capacidad de retención de agua (AW) observada y comparada con el modelo de Saxton y Rawls.

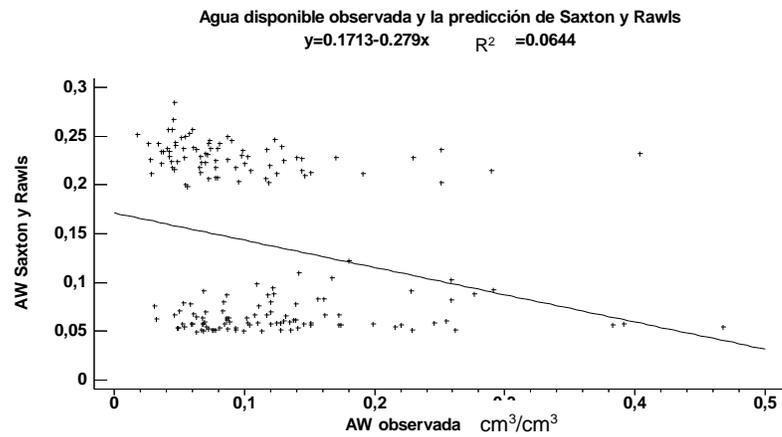


Figura 43: Capacidad de retención de agua (AW) observada y comparada con el modelo RETC.

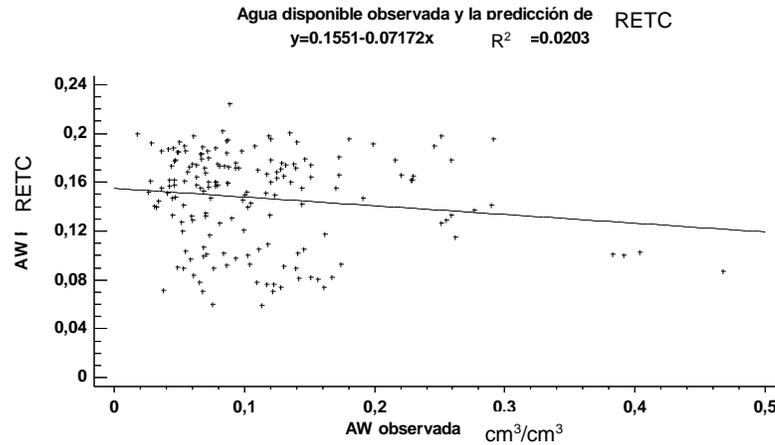
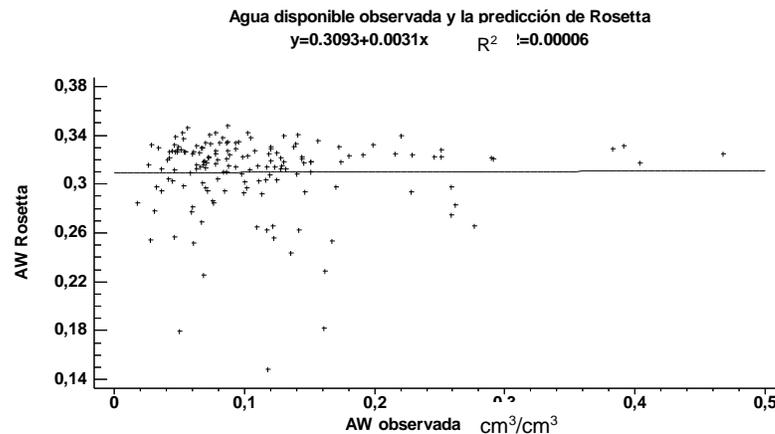


Figura 44: Capacidad de retención de agua (AW) observada y comparada con el modelo Rosetta.



En cuanto a los coeficientes de determinación, estos son bajos para todos los modelos analizados. En el caso de Saxton y Rawls este presenta valores alrededor del 4 % de explicación de los datos o de capacidad de predicción (Figura 42). Por el contrario,

Manrique (Figura 39), Rosetta (Figura 44), *British Top Soil* (Figura 37), Rawls (Figura 40) y Baumer (Figura 34) reflejan desempeños de predicción menores al 1 %; mientras que para los demás modelos se presentan valores intermedios.

Con respecto a los valores calculados del agua disponible, estos muestran una variedad de resultados. Para Rawls (Figura 40), los valores de predicción máximos son cercanos a los $0,5 \text{ cm}^3/\text{cm}^3$ y, al igual que Brakiensiek (Figura 35), algunos son similares a los observados. Del mismo modo, Manrique (Figura 39) muestra valores máximos de $0,57 \text{ cm}^3/\text{cm}^3$ y *British Sub Soil* (Figura 36) predice resultados de hasta $0,8 \text{ cm}^3/\text{cm}^3$, los cuales son bastante altos en comparación con los observados (alrededor de $0,5 \text{ cm}^3/\text{cm}^3$).

En cuanto al error medio (Tabla 6), este es bajo en la mayoría de los casos; sin embargo, Manrique (Figura 39) muestra valores altos en la raíz del error cuadrático medio ($0,25 \text{ cm}^3/\text{cm}^3$); mientras que Tomasella (Figura 41) presenta el $0,17 \text{ cm}^3/\text{cm}^3$ de raíz del error cuadrático medio. Por tanto, indican que estos son los valores más elevados, con una gran dispersión de los datos y poco grado de predicción de los mismos.

Tabla 6: Evaluación de ajuste de los modelos para la capacidad de retención de agua (AW) en el suelo.

		R²	MSE	RMSE	ME
	AW Baumer	0,0061	0,00785	0,08860	0,01546
	AW Brakiensiek	0,0286	0,01874	0,13688	-0,07689
	AW BSSL	0,0238	0,02458	0,15678	-0,08689
	AW BSST	0,0046	0,00832	0,09122	-0,04066
AW	AW Hutson	0,0260	0,00961	0,09803	0,05814
	AW Manrique	0,0000	0,06608	0,25706	-0,22363
	AW Rawls	0,0020	0,01378	0,11737	-0,05380
	AW Tomasella	0,0108	0,02942	0,17153	0,12620
	AW Saxton	0,0644	0,01686	0,12984	-0,02651

	R²	MSE	RMSE	ME
AW RETC	0,0203	0,00963	0,09811	-0,03300
AW Rosetta	0,0001	-0,16896	0,04261	0,20643

R²: coeficiente de determinación, MSE: error cuadrático medio, RMSE: raíz del error cuadrático medio, ME: error medio

3.6 RESULTADOS DE LOS MODELOS DE EDAFOTRANSFERENCIA DESARROLLADOS CON REDES NEURONALES

3.6.1 Variables seleccionadas para las redes neuronales. A partir de la selección inicial de 12 variables para cada modelo, la red neuronal halló las más relevantes. Así, en la Tabla 7, se encuentran todas las variables disponibles que se obtuvieron de cada punto o muestra extraída de campo y del modelo de elevación digital.

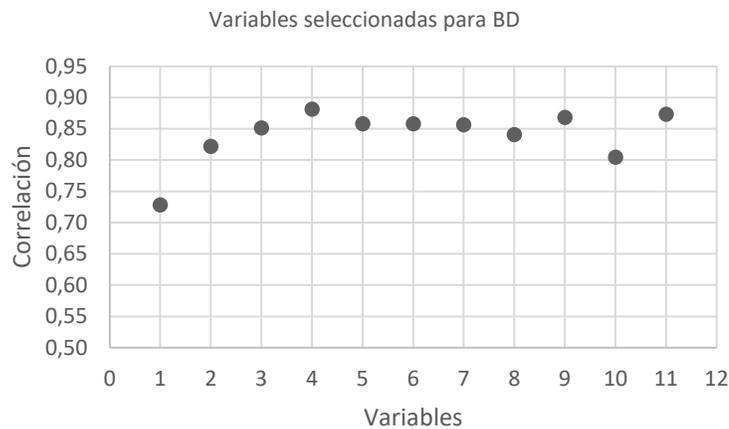
Tabla 7: Variables predictivas observadas.

	Unidades	Media	Desviación estándar	Mínimo	Máximo
Coordenada X	m	1171580,38	19106,281	1142945,38	1193084,41
Coordenada Y	m	995251,641	17519,677	951133,475	1010884,90
Elevación	m	2323,260	512,013	1540,000	3398,000
Pendiente	%	39,721	23,867	8,433	123,811
Curvatura del terreno		-0,141	1,734	-5,742	5,951
Curvatura-perfil		0,067	1,086	-3,932	3,971
Curvatura-plano		-0,074	0,827	-3,278	2,747
Área drenante acumulada	m ²	53,927	371,192	0,000	4752,000
Espesor	cm	46,068	22,308	5,000	100,000

	Unidades	Media	Desviación estándar	Mínimo	Máximo
Profundidad - centroide	cm	46,963	26,789	2,500	90,000
ARENAS	%	78,055	5,811	59,000	92,500
ARCILLAS	%	7,613	3,338	3,200	23,650
CO (carbono orgánico)	%	5,145	3,712	0,141	24,483
Cobertura del suelo		2,910	1,140	1,000	4,000
Cuenca		1,458	0,500	1,000	2,000
BD (Densidad aparente)	g/cm ³	0,738	0,251	0,180	1,710
WP (Punto de marchitez)		0,647	0,356	0,042	1,948
FC (Capacidad de campo)		0,806	0,380	0,112	2,147
AW (Disponibilidad de agua)		0,159	0,096	0,032	0,483

De esta forma, las variables se sometieron al análisis de Pearson y Spearman, se encontraron las redundantes, y se seleccionaron 12 (Tabla 2). En esta tabla, se observan las variables no redundantes a usar, lo que contribuye a reducir las variables de entrada y a tener una convergencia más eficiente en cuanto a la generación de modelos de la red neuronal. En las Figuras 45, 46, 47 y 48 se puede observar el comportamiento de las variables.

Figura 45: Variables seleccionadas para red neuronal en la predicción de la densidad aparente (BD).

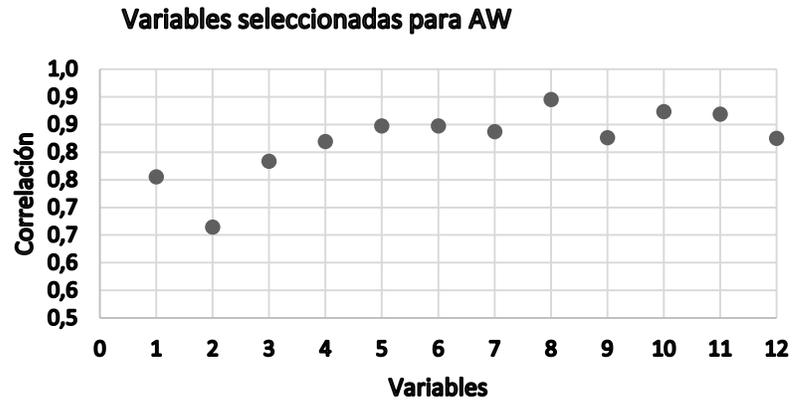


En cuanto al crecimiento de la relación entre las variables, este se observa hasta el número siete. Dichas variables corresponden, en su orden, a la altura, el contenido de materia orgánica, la curvatura del terreno, el porcentaje de arenas, la pendiente, el porcentaje de arcillas y la cobertura.

De esta forma, después de hacer la relación entre las siete variables principales escogidas, se presenta un comportamiento irregular con valores menores a la séptima variable, donde alcanzan alguna significancia la curvatura y el centroide; sin embargo, se decidió trabajar solamente con las primeras siete variables.

Al comparar con las variables de edafotransferencia tradicionales, que se basan en la textura (aquí incluidas), se involucran otras de fácil consecución y que se consideran relevantes para la determinación de la densidad aparente. Como ya lo habían mencionado Botula et al. (2012) y Tomasella et al. (2003), la inclusión de elementos — como la materia orgánica— mejora la predicción de las variables; por tanto, aquí se incluye otras que no han sido objeto de análisis.

Figura 46: Variables seleccionadas para red neuronal en la predicción del agua retenida por el suelo (AW).

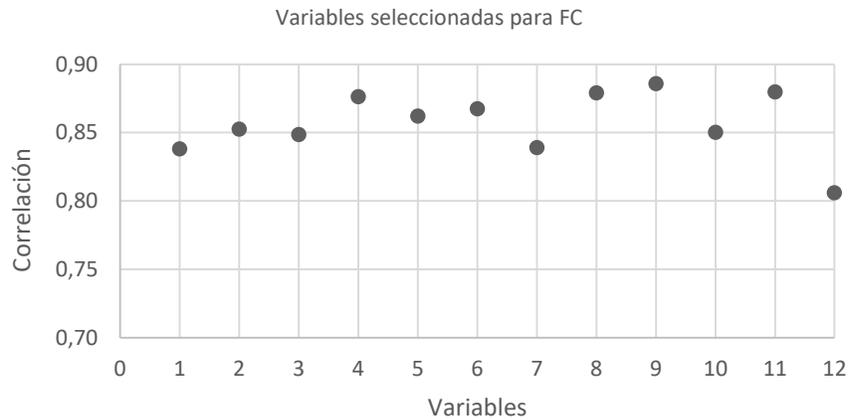


Con relación a la capacidad de retención de agua para el suelo se seleccionaron siete variables: la altura del punto sobre el nivel del mar, la latitud, la densidad aparente, el espesor del horizonte del suelo, el porcentaje de materia orgánica, la cobertura y el porcentaje de arenas.

A partir de la séptima variable, se presenta un comportamiento de aumento y disminución de la influencia en relación con las otras variables.

Por tanto, se observa que la textura del suelo y el contenido de materia orgánica son fundamentales en la determinación de la cantidad de agua retenida por el suelo. Sin embargo, las demás variables aquí incluidas también presentan una buena relación entre ellas y son relevantes para la predicción del contenido de humedad.

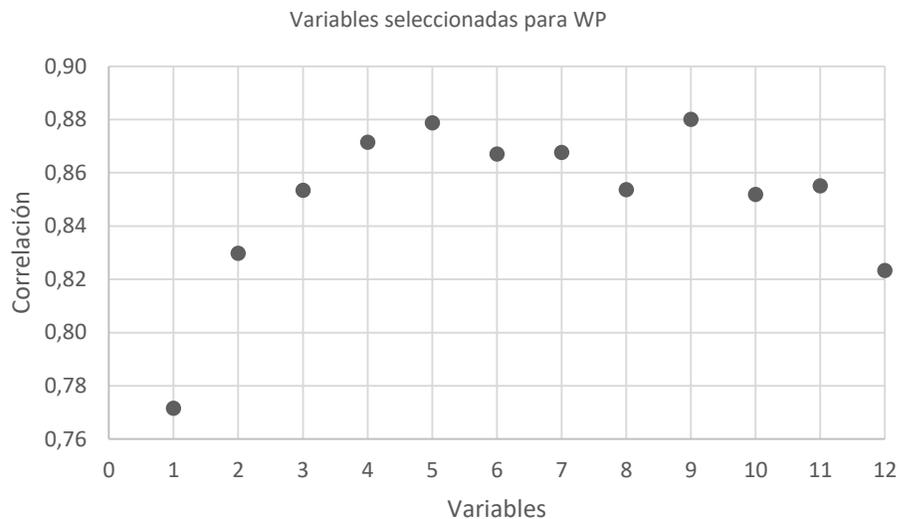
Figura 47: Variables seleccionadas para red neuronal en la predicción de la capacidad de campo (FC).



En lo que concierne a las variables que se incluyeron para la predicción de la capacidad de campo, ni la textura, ni la materia orgánica tuvieron inserción como se venía observando en las variables anteriores; mientras que se incluyen la densidad aparente, la altura, la pendiente, la latitud y la cobertura.

Sin embargo, la densidad aparente es una representación de la textura y el contenido de materia orgánica, pues esta variable depende de las otras. En relación con las demás variables involucradas, estas se obtuvieron del modelo de elevación digital de la zona. En cuanto a la cobertura, esta si se determinó a partir de las observaciones que se hicieron en campo en el momento de la toma de las muestras.

Figura 48: Variables seleccionadas para red neuronal en la predicción del punto de marchitez permanente (WP).



De los 50 000 modelos analizados para cada variable (AW, BD, FC y WP), se escogió el que presentó el mayor valor de ajuste para las tres fases: entrenamiento, validación y test. En la Figura 53 se muestra la nube de puntos y la distribución de los modelos. De igual forma, se presenta una representación de las capas de las redes neuronales que se plantearon (Figuras 49, 50, 51 y 52), y la representación de las redes neuronales con los pesos y los sesgos hallados para el modelo óptimo (Anexo 2).

En la Figura 53 se presenta en el eje X los datos del entrenamiento, en el eje Y la validación; a color, la fase de test para cada una de las variables a predecir. Con respecto a las variables capacidad de campo, punto de marchitez permanente y densidad aparente se obtuvieron 50 000 modelos, y en el caso de la retención de agua del suelo fueron 10 000.

Para cada variable se seleccionó el modelo que presentó el mejor desempeño; así, el coeficiente de correlación de Pearson se utilizó como indicador de esta ejecución y se escogió el de más alto valor para cada caso. De esta forma, este valor es un promedio de las tres fases: entrenamiento, validación y test.

Figura 49: Representación gráfica de la red neuronal para la predicción del agua disponible retenida en el suelo (AW).

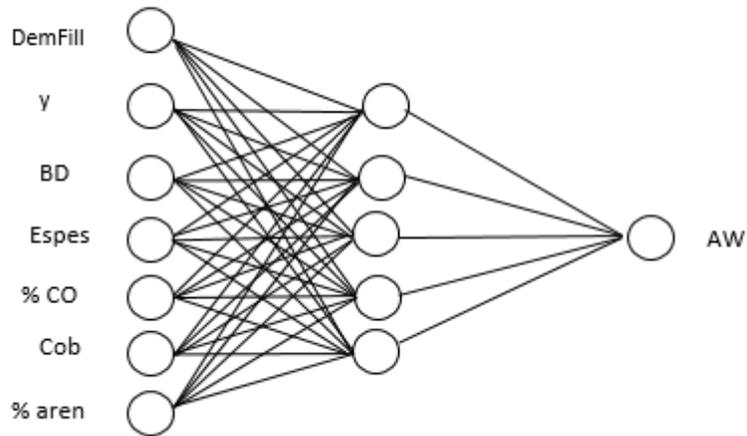


Figura 50: Representación gráfica de la red neuronal para la predicción de la densidad aparente (BD) del suelo.

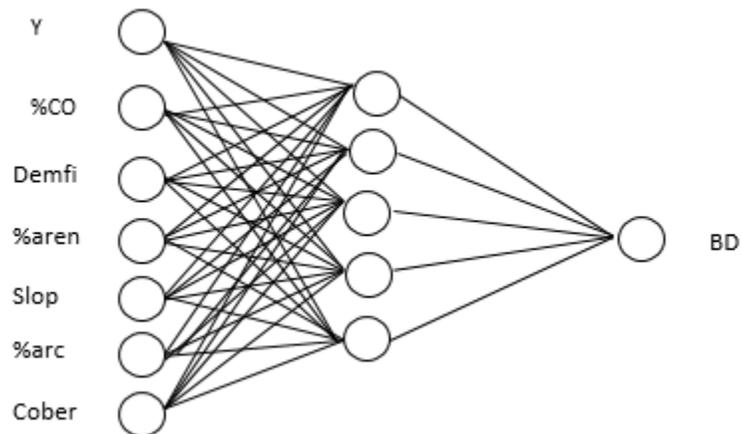


Figura 51: Representación gráfica de la red neuronal para la predicción de la variable capacidad de campo (FC).

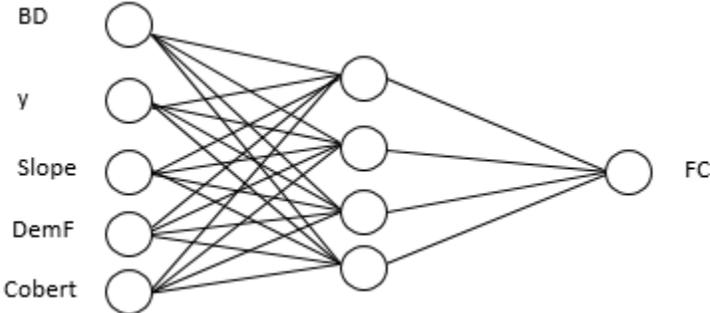


Figura 52: Representación gráfica de la red neuronal para la predicción del punto de marchitez permanente (WP).

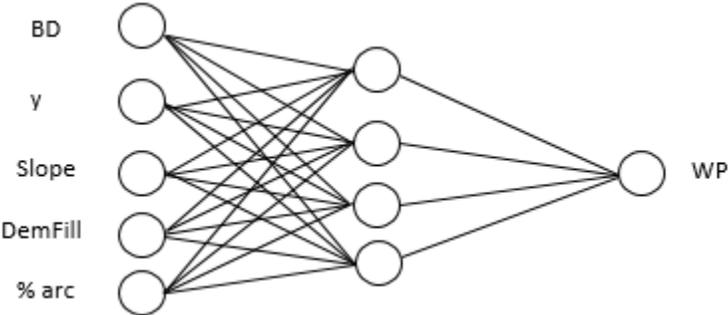


Figura 53: Modelos generados por la red neuronal para la selección del mejor modelo de predicción para la capacidad de campo (FC) [arriba izquierda], el punto de marchitez permanente (WP) [arriba derecha], el agua retenida por el suelo (AW) [abajo izquierda] y la densidad aparente (BD) [abajo derecha].

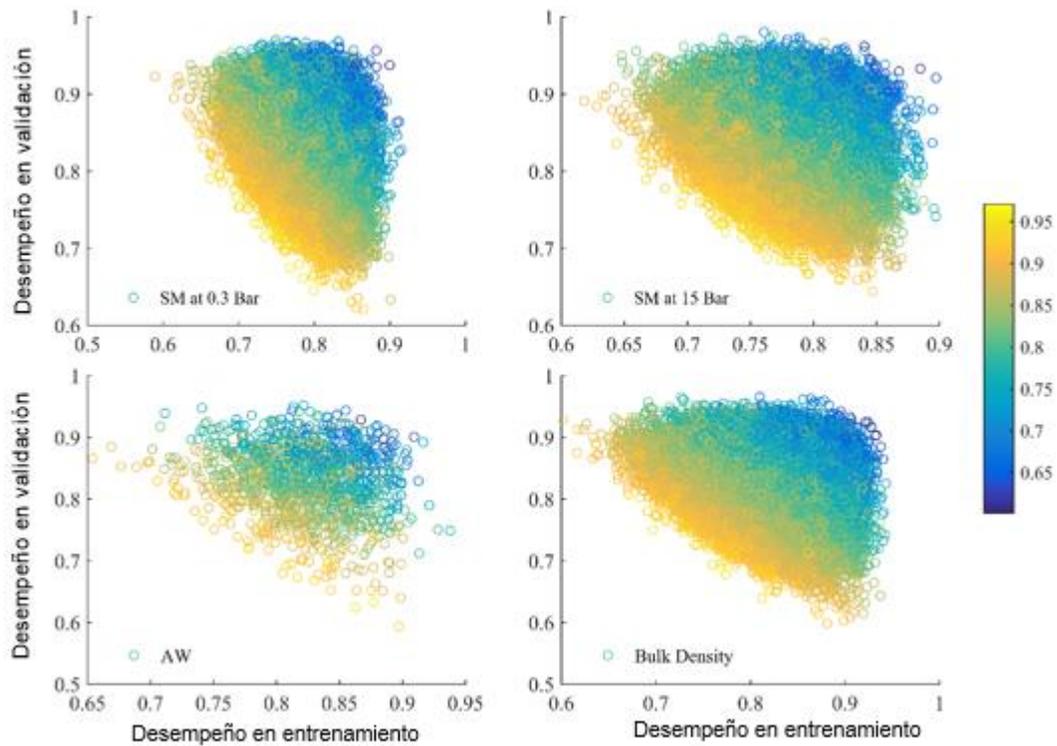


Tabla 8: Síntesis estadística para cada etapa de las variables dependientes analizadas.

		Entrenamiento	Validación	Test
WP	R ²	0,6433	0,7362	0,7909
	MSE	0,0300	0,0530	0,0350
	RMSE	0,1740	0,2300	0,1880
	ME	-0,0043	-0,0302	0,0123
FC	R ²	0,7489	0,7556	0,7467
	MSE	0,0330	0,0330	0,0419
	RMSE	0,1818	0,1815	0,2046

	ME	-0,0012	-0,0095	0,0396
	R ²	0,7482	0,8415	0,7589
AW	MSE	0,0034	0,0059	0,0103
	RMSE	0,0582	0,0769	0,1016
	ME	0,0003	-0,0500	-0,0440
	R ²	0,7763	0,7581	0,7803
BD	MSE	0,0128	0,0221	0,0397
	RMSE	0,1133	0,1485	0,1992
	ME	-0,001	0,033	-0,066

WP: punto de marchitez permanente, FC: capacidad de campo, AW: el agua retenida por el suelo, BD: densidad aparente, R²: coeficiente de determinación, MSE: error cuadrático medio, RMSE: raíz del error cuadrático medio, ME: error medio

3.6.2 Ecuaciones derivadas de las redes neuronales. Para la densidad aparente (BD)

$$\begin{aligned}
 z1 = & \frac{(y - 994752.019)}{17808.352} * (-1.41964861) + \frac{(\%CO - 5.21591108)}{3.89602738} * (-0.27041271) \\
 & + \frac{(DF - 2309.73143)}{497.095775} * 1.93085395 + \frac{(\%ARE - 78.2579665)}{5.787864} \\
 & * 2.43523037 + \frac{(S - 39.3864724)}{23.6274486} * 0.02477277 + \frac{(\%ARC - 7.62092869)}{3.37162842} \\
 & * (-0.26259648) + \frac{(COV - 2.94)}{1.12218998} * (-1.845510087) - 3.4646195
 \end{aligned}$$

$$\begin{aligned}
z2 = & \frac{(y - 994752.019)}{17808.352} * (-1.42981112) + \frac{(\%CO - 5.21591108)}{3.89602738} * (-0.04010654) \\
& + \frac{(DF - 2309.73143)}{497.095775} * 0.81814557 + \frac{(\%ARE - 78.2579665)}{5.787864} \\
& * 0.48571791 + \frac{(S - 39.3864724)}{23.6274486} * (-0.58097011) \\
& + \frac{(\%ARC - 7.62092869)}{3.37162842} * (0.116126657) + \frac{(COV - 2.94)}{1.12218998} \\
& * (0.461471543) - 0.28487283
\end{aligned}$$

$$\begin{aligned}
z3 = & \frac{(y - 994752.019)}{17808.352} * (1.0934146) + \frac{(\%CO - 5.21591108)}{3.89602738} * (-0.10092958) \\
& + \frac{(DF - 2309.73143)}{497.095775} * (-1.74636257) + \frac{(\%ARE - 78.2579665)}{5.787864} \\
& * (-0.55745337) + \frac{(S - 39.3864724)}{23.6274486} * (1.29080269) \\
& + \frac{(\%ARC - 7.62092869)}{3.37162842} * (0.312723543) + \frac{(COV - 2.94)}{1.12218998} \\
& * (-1.394179885) + 1.15610633
\end{aligned}$$

$$\begin{aligned}
z4 = & \frac{(y - 994752.019)}{17808.352} * (-0.79231966) + \frac{(\%CO - 5.21591108)}{3.89602738} * (0.43937729) \\
& + \frac{(DF - 2309.73143)}{497.095775} * (0.62634213) + \frac{(\%ARE - 78.2579665)}{5.787864} \\
& * (-0.178081) + \frac{(S - 39.3864724)}{23.6274486} * (0.58920622) \\
& + \frac{(\%ARC - 7.62092869)}{3.37162842} * (1.457852228) + \frac{(COV - 2.94)}{1.12218998} * (-0.45522862) \\
& * -2.20834835
\end{aligned}$$

$$\begin{aligned}
z5 = & \frac{(y - 994752.019)}{17808.352} * (0.04467209) + \frac{(\%CO - 5.21591108)}{3.89602738} * (0.94756279) \\
& + \frac{(DF - 2309.73143)}{497.095775} * (-0.93616492) + \frac{(\%ARE - 78.2579665)}{5.787864} \\
& * (0.24670923) + \frac{(S - 39.3864724)}{23.6274486} * (0.57756649) \\
& + \frac{(\%ARC - 7.62092869)}{3.37162842} * (-0.807467837) + \frac{(COV - 2.94)}{1.12218998} \\
& * (-0.031107209) + 2.33734783
\end{aligned}$$

$$\begin{aligned}
Z6 = & \left(\frac{2}{1 + EXP(-2 * Z1)} - 1 \right) * (-0.83174172) + \left(\frac{2}{1 + EXP(-2 * Z2)} - 1 \right) \\
& * (2.20367448) + \left(\frac{2}{1 + EXP(-2 * Z3)} - 1 \right) * (1.59441057) \\
& + \left(\frac{2}{1 + EXP(-2 * Z4)} - 1 \right) * (-1.52653229) + \left(\frac{2}{1 + EXP(-2 * Z5)} - 1 \right) \\
& * (-1.447093132) + (-0.53461571)
\end{aligned}$$

$$BD = Z6 * 0.25487223 + 0.74182857$$

Ecuación 18: Densidad aparente (BD).

Donde:

y= latitud en metros.

%CO= porcentaje de carbono orgánico.

DF= altura sobre el nivel del mar en metros.

%ARE= contenido de arena en porcentaje.

S= pendiente en porcentaje.

% ARC= contenido de arcilla en porcentaje.

COV= cobertura de la zona en cuestión.

Para el agua retenida en el suelo (AW)

$$\begin{aligned}
W1 = & \frac{(DF - 2309.7314)}{497.09577} * (-0.2692721) + \frac{(y - 994752.02)}{17808.352} * (-3.0057258) \\
& + \frac{(BD - 0.7418286)}{0.2548722} * 2.5839004 + \frac{(ESP - 45.885714)}{22.633983} * 1.6570626 \\
& + \frac{(\%CO - 5.2159111)}{3.8960274} * (-1.8993339) + \frac{(COV - 2.94)}{1.12218998} * (-2.3175196) \\
& + \frac{(\%ARE - 78.25796647)}{5.787864} * (-0.187313961) - 3.9885747
\end{aligned}$$

$$\begin{aligned}
W2 = & \frac{(DF - 2309.7314)}{497.09577} * (-4.9695725) + \frac{(y - 994752.02)}{17808.352} * (4.9959173) \\
& + \frac{(BD - 0.7418286)}{0.2548722} * 1.342401996 + \frac{(ESP - 45.885714)}{22.633983} * 0.027654114 \\
& + \frac{(\%CO - 5.2159111)}{3.8960274} * (4.057335167) + \frac{(COV - 2.94)}{1.12218998} * (-7.28705119) \\
& + \frac{(\%ARE - 78.25796647)}{5.787864} * (-1.832719851) + 4.037926724
\end{aligned}$$

$$\begin{aligned}
W3 = & \frac{(DF - 2309.7314)}{497.09577} * (0.3150797) + \frac{(y - 994752.02)}{17808.352} * (-0.0651116) \\
& + \frac{(BD - 0.7418286)}{0.2548722} * 1.998596527 + \frac{(ESP - 45.885714)}{22.633983} * 1.168763249 \\
& + \frac{(\%CO - 5.2159111)}{3.8960274} * (0.447287966) + \frac{(COV - 2.94)}{1.12218998} * (0.95578397) \\
& + \frac{(\%ARE - 78.25796647)}{5.787864} * (0.61108628) + 4.73408256
\end{aligned}$$

$$\begin{aligned}
W4 = & \frac{(DF - 2309.7314)}{497.09577} * (-0.4846262) + \frac{(y - 994752.02)}{17808.352} * (0.6359133) \\
& + \frac{(BD - 0.7418286)}{0.2548722} * 0.013054584 + \frac{(ESP - 45.885714)}{22.633983} \\
& * (-0.027131683) + \frac{(\%CO - 5.2159111)}{3.8960274} * (0.125149252) + \frac{(COV - 2.94)}{1.12218998} \\
& * (-0.26193045) + \frac{(\%ARE - 78.25796647)}{5.787864} * (-0.046465595) \\
& + 0.771412494
\end{aligned}$$

$$\begin{aligned}
W5 = & \frac{(DF - 2309.7314)}{497.09577} * (-4.6747454) + \frac{(y - 994752.02)}{17808.352} * (1.0702083) \\
& + \frac{(BD - 0.7418286)}{0.2548722} * (-3.055661449) + \frac{(ESP - 45.885714)}{22.633983} \\
& * (2.687550664) + \frac{(\%CO - 5.2159111)}{3.8960274} * (-0.1854615) + \frac{(COV - 2.94)}{1.12218998} \\
& * (1.25735797) + \frac{(\%ARE - 78.25796647)}{5.787864} * (2.383681616) \\
& - 4.821859531
\end{aligned}$$

$$\begin{aligned}
W6 = & \left(\frac{2}{1 + EXP(-2 * W1)} - 1 \right) * (-0.5965735) + \left(\frac{2}{1 + EXP(-2 * W2)} - 1 \right) \\
& * (0.752778782) + \left(\frac{2}{1 + EXP(-2 * W3)} - 1 \right) * (-4.861796601) \\
& + \left(\frac{2}{1 + EXP(-2 * W4)} - 1 \right) * (-2.33509679) + \left(\frac{2}{1 + EXP(-2 * W5)} - 1 \right) \\
& * (0.58682831) + (5.736097978)
\end{aligned}$$

$$AW = W6 * 0.1211509 + 0.1636677$$

Ecuación 19: Agua retenida en el suelo (AW).

Donde:

DF= altura sobre el nivel del mar en metros.

BD= densidad aparente en g/cm³.

ESP= espesor del estrato desde la superficie en centímetros.

%CO= porcentaje de carbono orgánico.

COV= cobertura del lugar.

%ARE= porcentaje de arena presente.

Para la capacidad de campo (FC)

$$F1 = \frac{(BD - 0.74182857)}{0.25487223} * (1.85342861) + \frac{(y - 994752.02)}{17808.352} * (-8.24164021) \\ + \frac{(S - 39.3864724)}{23.6274486} * (-0.43085165) + \frac{(DF - 2309.73143)}{497.095775} \\ * (-0.70905405) + \frac{(COV - 2.94)}{1.12218998} * (3.99748212) + 3.81938307$$

$$F2 = \frac{(BD - 0.74182857)}{0.25487223} * (-5.927981212) + \frac{(y - 994752.02)}{17808.352} * (-7.43885494) \\ + \frac{(S - 39.3864724)}{23.6274486} * (-2.464593345) + \frac{(DF - 2309.73143)}{497.095775} \\ * (2.878079267) + \frac{(COV - 2.94)}{1.12218998} * (-7.173682263) - 7.83183253$$

$$F3 = \frac{(BD - 0.74182857)}{0.25487223} * (0.107402788) + \frac{(y - 994752.02)}{17808.352} * (-0.052617127) \\ + \frac{(S - 39.3864724)}{23.6274486} * (0.20853625) + \frac{(DF - 2309.73143)}{497.095775} \\ * (-0.09172925) + \frac{(COV - 2.94)}{1.12218998} * (-0.774585787) + 1.33176599$$

$$F4 = \frac{(BD - 0.74182857)}{0.25487223} * (0.513199159) + \frac{(y - 994752.02)}{17808.352} * (4.202136917) \\ + \frac{(S - 39.3864724)}{23.6274486} * (11.67751039) + \frac{(DF - 2309.73143)}{497.095775} \\ * (4.026387092) + \frac{(COV - 2.94)}{1.12218998} * (-2.932484867) - 1.69106171$$

$$F5 = \left(\frac{2}{1 + EXP(-2 * F1)} - 1 \right) * (-1.033510885) + \left(\frac{2}{1 + EXP(-2 * F2)} - 1 \right) \\ * (0.556479163) + \left(\frac{2}{1 + EXP(-2 * F3)} - 1 \right) * (-2.9849041) \\ + \left(\frac{2}{1 + EXP(-2 * F4)} - 1 \right) * (0.681203173) + (3.10766651)$$

$$FC = F5 * 0.37356002 + 0.78639625$$

Ecuación 20: Capacidad de campo (FC).

Donde:

BD= densidad aparente en g/cm³.

y= latitud en metros.

S= pendiente en porcentaje.

DF= altura sobre el nivel del mar,

COV= cobertura.

Para el punto de marchitez permanente (WP)

$$P1 = \frac{(BD - 0.74182857)}{0.25487223} * (-3.61855395) + \frac{(y - 994752.02)}{17808.352} * (-2.167373092) \\ + \frac{(DF - 2309.731429)}{497.0957745} * (-2.5300664) + \frac{(S - 39.38647244)}{23.6274486} \\ * (1.69374334) + \frac{(\%ARC - 7.620928691)}{3.37162842} * (-4.93081446) - 8.52791541$$

$$P2 = \frac{(BD - 0.74182857)}{0.25487223} * (-0.36251464) + \frac{(y - 994752.02)}{17808.352} * (0.418648205) \\ + \frac{(DF - 2309.731429)}{497.0957745} * (0.25645228) + \frac{(S - 39.38647244)}{23.6274486} \\ * (-0.11205681) + \frac{(\%ARC - 7.620928691)}{3.37162842} * (0.05637114) - 0.67115601$$

$$P3 = \frac{(BD - 0.74182857)}{0.25487223} * (-3.631797133) + \frac{(y - 994752.02)}{17808.352} * (2.396833679) \\ + \frac{(DF - 2309.731429)}{497.0957745} * (2.20974602) + \frac{(S - 39.38647244)}{23.6274486} \\ * (17.0065841) + \frac{(\%ARC - 7.620928691)}{3.37162842} * (-3.74906283) - 33.3850622$$

$$P4 = \frac{(BD - 0.74182857)}{0.25487223} * (13.20193656) + \frac{(y - 994752.02)}{17808.352} * (-3.781373004) \\ + \frac{(DF - 2309.731429)}{497.0957745} * (-9.18364043) + \frac{(S - 39.38647244)}{23.6274486} \\ * (-6.9362707) + \frac{(\%ARC - 7.620928691)}{3.37162842} * (-0.62190061) + 2.75639434$$

$$P5 = \left(\frac{2}{1 + EXP(-2 * P1)} - 1 \right) * (1.204836508) + \left(\frac{2}{1 + EXP(-2 * P2)} - 1 \right) \\ * (2.63910173) + \left(\frac{2}{1 + EXP(-2 * P3)} - 1 \right) * (0.96071935) \\ + \left(\frac{2}{1 + EXP(-2 * P4)} - 1 \right) * (1.06383934) + (2.40023433) \\ WP = P5 * 0.34179705 + 0.6227286$$

Ecuación 21: Punto de marchitez permanente (WP).

Donde:

BD= densidad aparente en g/cm³.

y= latitud en metros.

S= pendiente en porcentaje.

%ARC= porcentaje de arcilla.

3.7 DENSIDAD APARENTE

En cuanto al desempeño de la red neuronal se observa que el coeficiente de determinación presenta una precisión mayor en la evaluación final de los datos, al alcanzar una explicación de estos en un 78 %, con una evolución que viene en aumento desde el 75 % (Tabla 8 y Figuras 54, 55 y 56).

Con respecto a la dispersión de los datos, esta se encuentra en el rango de $0,11 \text{ g/cm}^3$ a $0,19 \text{ g/cm}^3$ y evoluciona de menor a mayor. Esta dispersión no parece muy grande, sin embargo, para suelos con altos contenidos de materia orgánica y baja densidad aparente es sensible este dato. Aquí se encontraron datos que varían entre los $0,5 \text{ g/cm}^3$ y los $1,7 \text{ g/cm}^3$. De este modo, Salamanca y Sadeghian (2005) encontraron que para la zona andina colombiana, la densidad aparente presenta un amplio rango (valores entre $0,58$ y $1,46 \text{ g/cm}^3$), cuya dispersión se hace notable por la amplia gama de suelos con estas características físicas.

Figura 54: Modelo de predicción de la red neuronal de la densidad aparente (DA) en la etapa de entrenamiento.

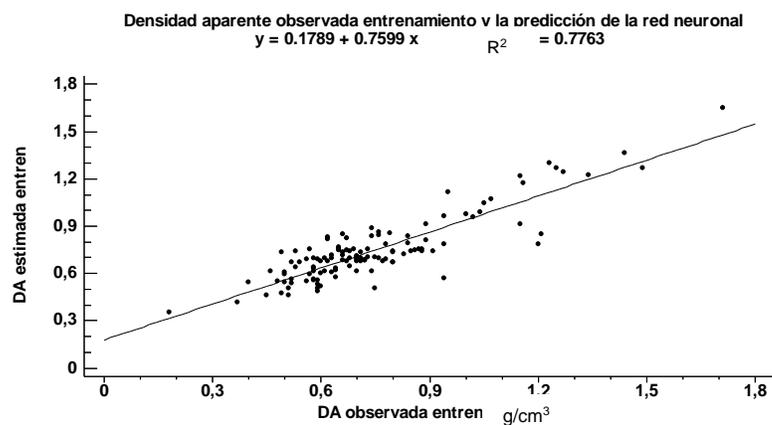


Figura 55: Modelo de predicción de la red neuronal de la densidad aparente (DA) en la etapa de validación.

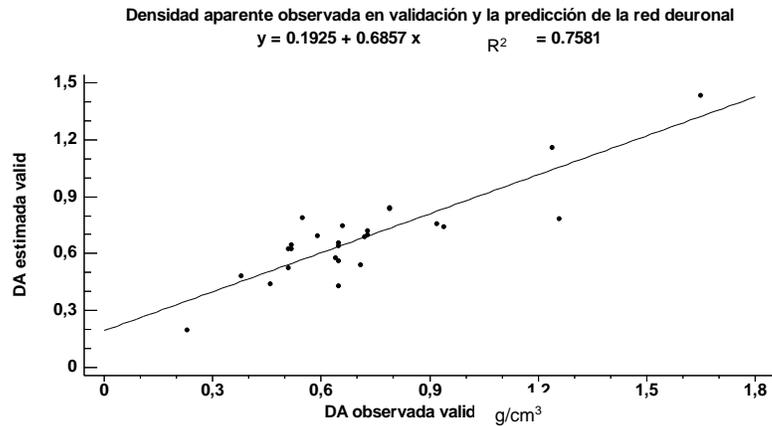
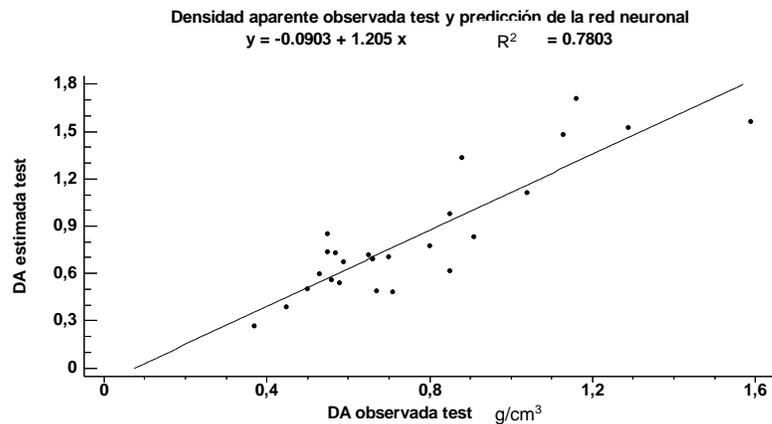


Figura 56: Modelo de predicción de la red neuronal de la densidad aparente en la etapa de test.



3.8 PUNTO DE MARCHITEZ PERMANENTE

Con respecto a la red neuronal, esta evolucionó en la predicción al presentar un mejor ajuste en la fase de evaluación final, donde alcanzó un coeficiente de determinación del

79 %. Esta evolución crece desde el 64 % para el entrenamiento (Figura 57), el 73 % para la validación (Figura 58) y el 79 % para la evaluación final o test (Figura 59).

Lo anterior, contrasta con la dispersión de los datos expresada como la raíz del error cuadrático medio. Este valor varía entre $0,17 \text{ cm}^3/\text{cm}^3$, $0,23 \text{ cm}^3/\text{cm}^3$ y $0,18 \text{ cm}^3/\text{cm}^3$ como promedio en las tres fases evaluadas.

Estos parecen valores altos, comparados con los calculados por otros autores, para las curvas de retención de humedad. Koekkoekk y Bootlink (1999) y Minasny (1999) reportaron dispersiones máximas de $0,06 \text{ cm}^3/\text{cm}^3$ y Rubio (2005) de $0,095 \text{ cm}^3/\text{cm}^3$. Sin embargo, los valores aquí hallados son consistentes y no presentan variaciones grandes con porcentajes alrededor del 20 %.

Figura 57: Modelo de predicción de la red neuronal del punto de marchitez permanente (WP) en la etapa de entrenamiento.

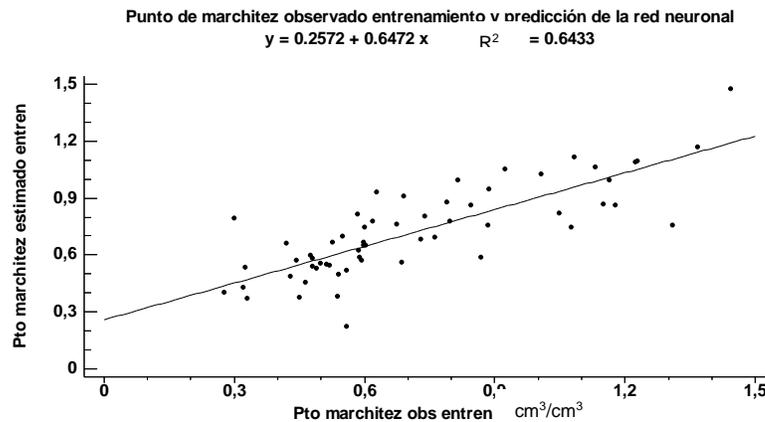


Figura 58: Modelo de predicción de la red neuronal del punto de marchitez permanente (WP) en la etapa de validación.

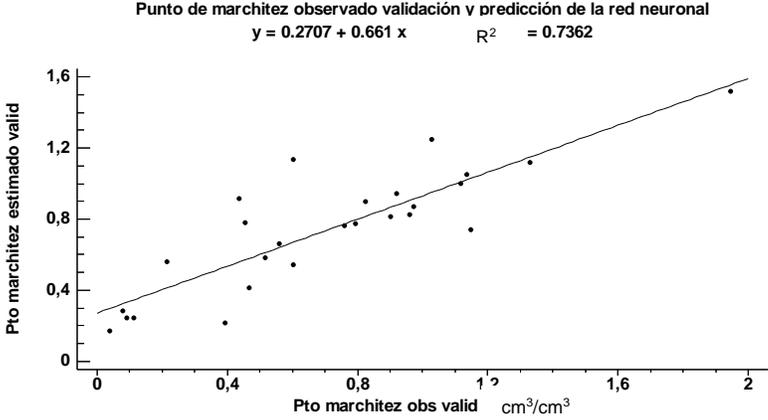
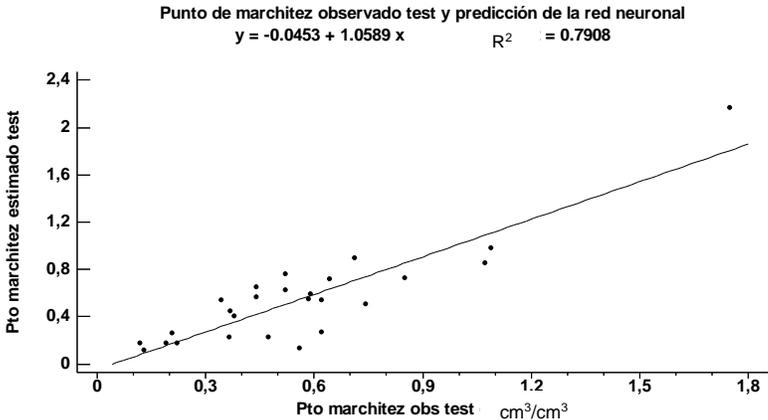


Figura 59: Modelo de predicción de la red neuronal del punto de marchitez permanente (WP) en la etapa de test.



3.9 CAPACIDAD DE CAMPO

En la evaluación de las tres fases de la red neuronal: entrenamiento, validación y test, el ajuste del modelo por el coeficiente de determinación no varía en gran medida, y oscila alrededor del 75 % para la explicación de los datos calculados (Figuras 60, 61 y 62).

Con relación a la dispersión de los datos, esta varía entre los $0,18 \text{ cm}^3/\text{cm}^3$ y los $0,20 \text{ cm}^3/\text{cm}^3$. Las investigaciones de Schaap (1998) y Rubio (2005) muestran dispersiones máximas alrededor de los $0,10 \text{ cm}^3/\text{cm}^3$ en las curvas de retención de humedad, las cuales parecen altas comparadas con estas últimas; no obstante, el análisis se hace aquí para toda la profundidad del perfil, mientras que los investigadores hacen diferencias entre los horizontes superficiales y los profundos, al encontrarse cambios en la retención de agua a capacidad de campo.

Figura 60: Modelo de predicción de la red neuronal de la capacidad de campo en la etapa de entrenamiento.

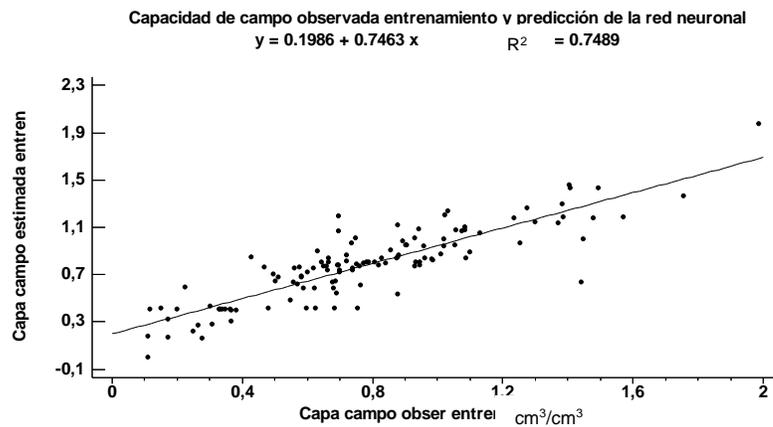


Figura 61: Modelo de predicción de la red neuronal de la capacidad de campo en la etapa de validación.

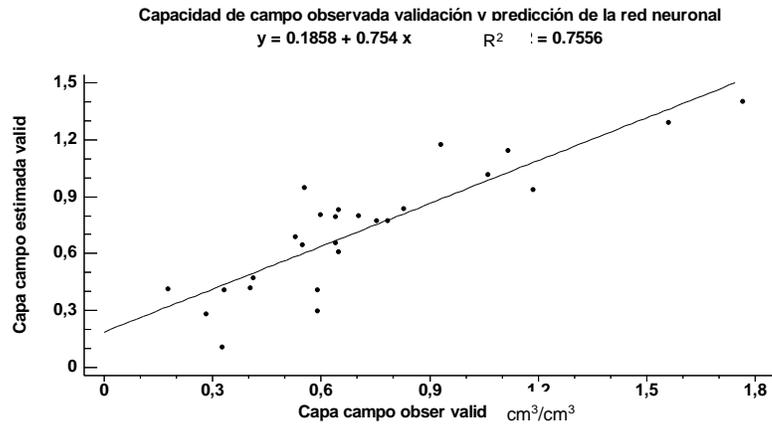
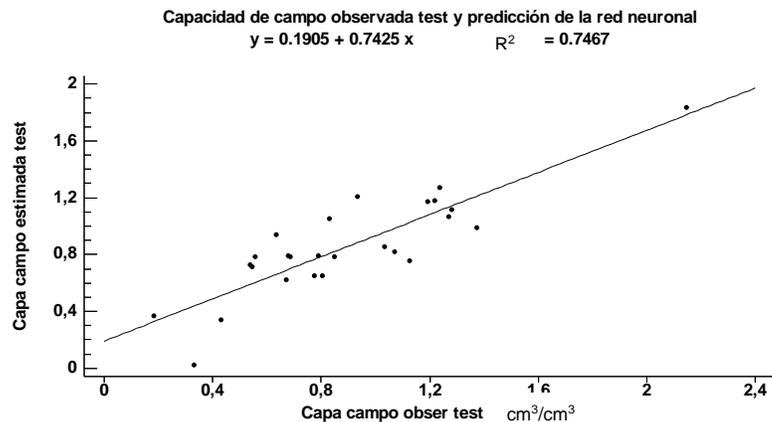


Figura 62: Modelo de predicción de la red neuronal de la capacidad de campo en la etapa de test.



3.10 RETENCIÓN DE AGUA EN EL SUELO

En cuanto a la retención de agua, la cual proviene de la diferencia entre la capacidad de campo y el punto de marchitez permanente, presenta un desempeño similar a estas. Aquí, se observan variaciones en la validación, con un 84 % de explicación de los datos

(Figura 64) y las otras dos fases de entrenamiento y evaluación de los datos (Figuras 63 y 65) con un ajuste del 75 %.

Con respecto a la dispersión de los datos, esta ya es similar a la encontrada por los investigadores citados anteriormente (Schaap et al., 1998; Koekkoek, 1999; Minasny, 1999; Rubio, 2005), quienes encontraron valores que oscilaron alrededor de los $0,06 \text{ cm}^3/\text{cm}^3$ y $1,0 \text{ cm}^3/\text{cm}^3$, lo cual —junto con el coeficiente de determinación— presenta una representación buena del contenido de agua retenido por los suelos neotropicales de la zona andina colombiana estudiada.

Figura 63: Modelo de predicción de la red neuronal del agua retenida por el suelo (AW) en la etapa de entrenamiento.

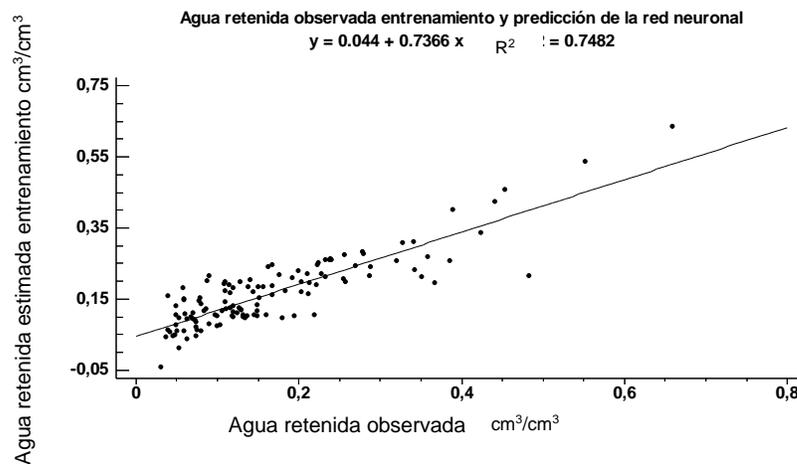


Figura 64: Modelo de predicción de la red neuronal del agua retenida por el suelo (AW) en la etapa de validación.

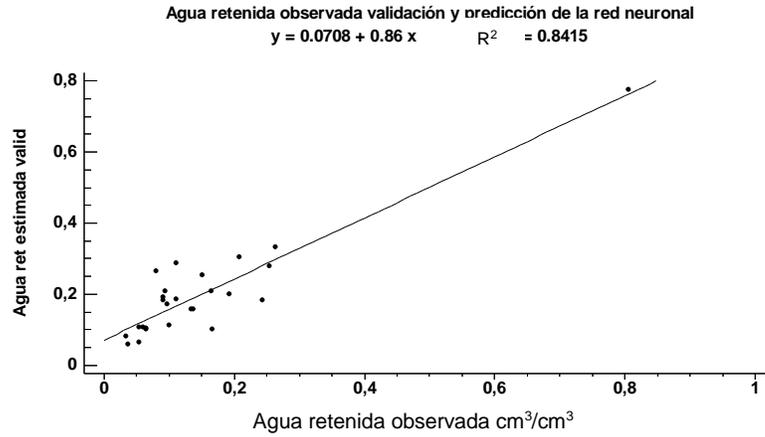
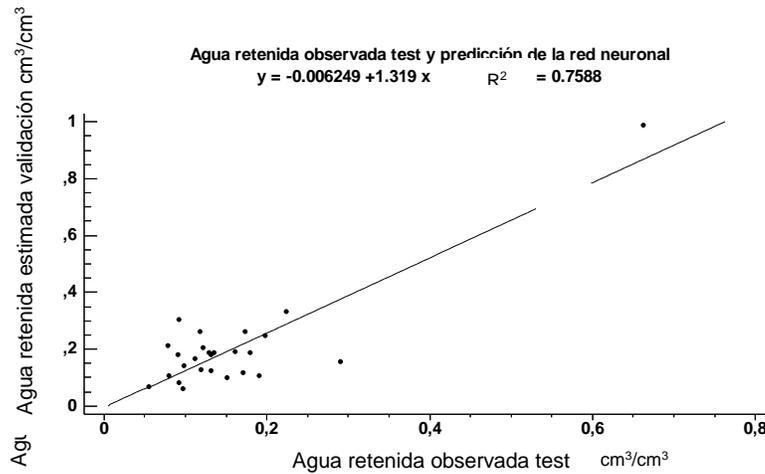


Figura 65: Modelo de predicción de la red neuronal del agua retenida por el suelo (AW) en la etapa de test.



3.10 RESULTADOS DE LOS ÁRBOLES ALTAMENTE ALEATORIZADOS (*EXTRA TREES*)

Agua disponible en el suelo (AW)

Al igual que en el caso de la red neuronal, se usan las mismas 12 variables potencialmente predictivas para la construcción de los modelos *Extra Trees*. En su orden: la latitud, la altura sobre el nivel del mar, la pendiente del terreno, la curvatura del terreno, la acumulación del drenaje del punto, el espesor del horizonte, la ubicación del centroide del estrato desde la superficie, el porcentaje de arenas, el porcentaje de arcillas, el contenido de carbono orgánico, la cobertura del suelo y la densidad aparente. Para ello, se generaron cien modelos de los árboles altamente aleatorizados, los cuales seleccionaron desde una (1) hasta seis (6) variables con coeficientes de determinación (R^2) que van desde 0,32 a 0,97 en calibración y de -0,15 a 0,557 en validación (Figuras 66 y 67). De estos modelos, se seleccionó el que presentó mayor coeficiente de determinación en validación cruzada, donde el modelo con el mejor desempeño involucró tres variables y alcanzó un desempeño del 93,96 % en calibración y 55,72 % en validación.

En cuanto a las variables predictivas del mejor modelo, estas fueron la altura sobre el nivel del mar, la densidad aparente y la curvatura del terreno.

Figura 66: Evolución de los 100 modelos generados por árboles extremadamente aleatorizados en la fase de calibración y validación, para el agua disponible en el suelo (AW).

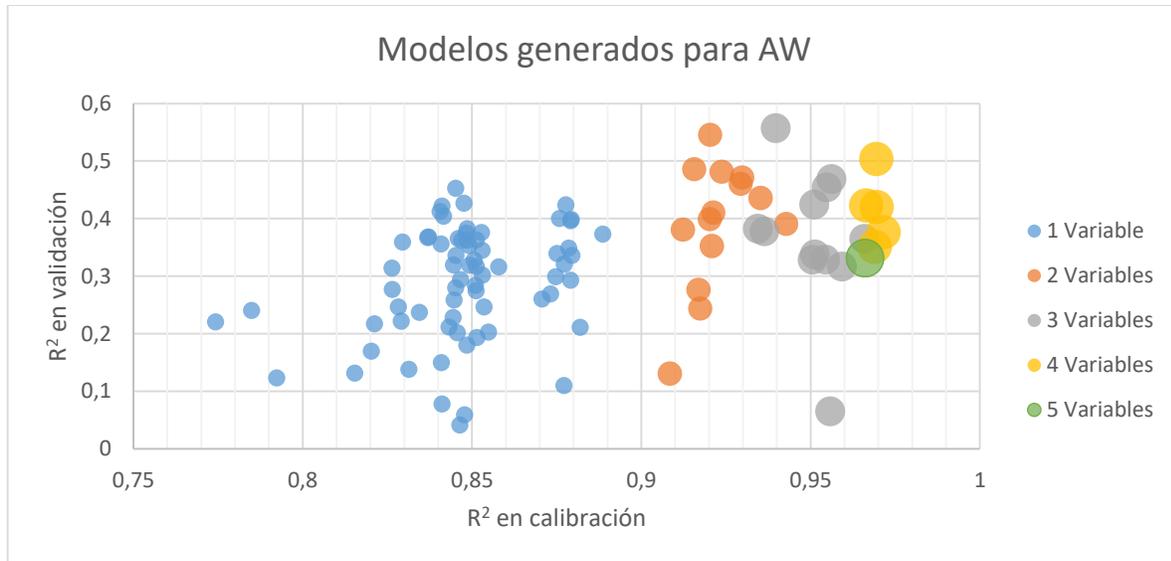
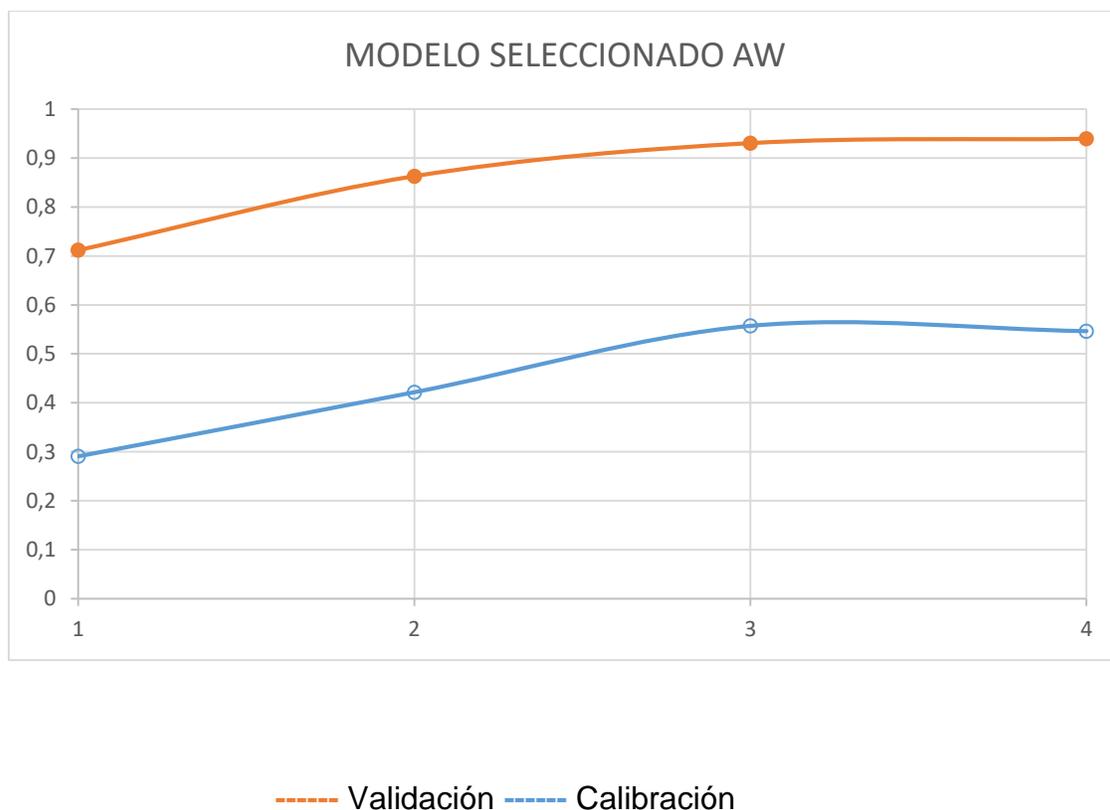


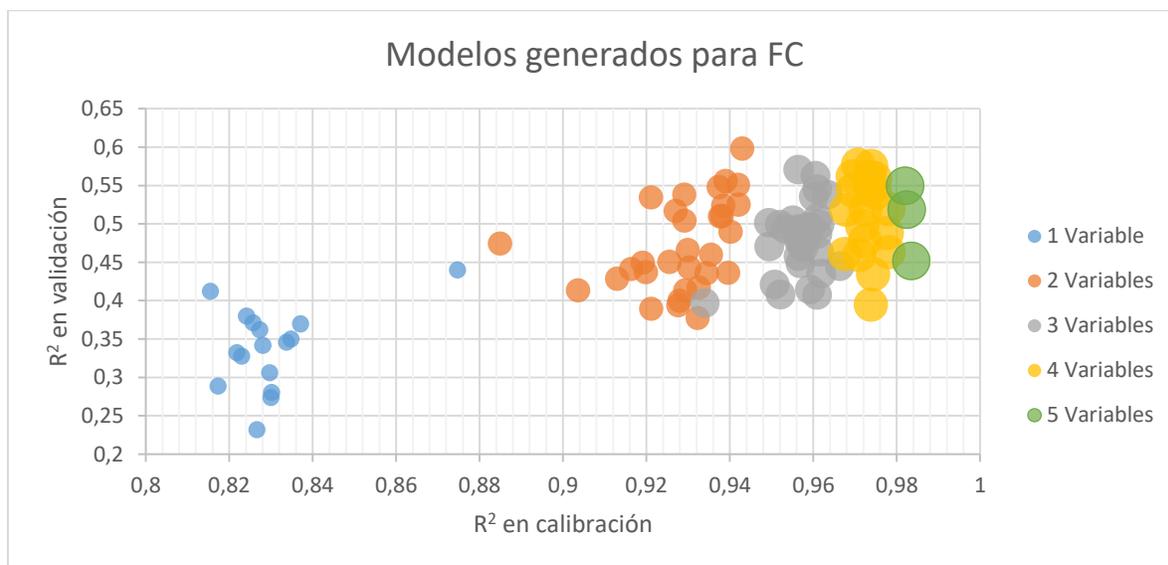
Figura 67: Evolución del modelo seleccionado por árboles extremadamente aleatorizados en validación y calibración, para el agua disponible en el suelo (AW).



La capacidad de campo (CF)

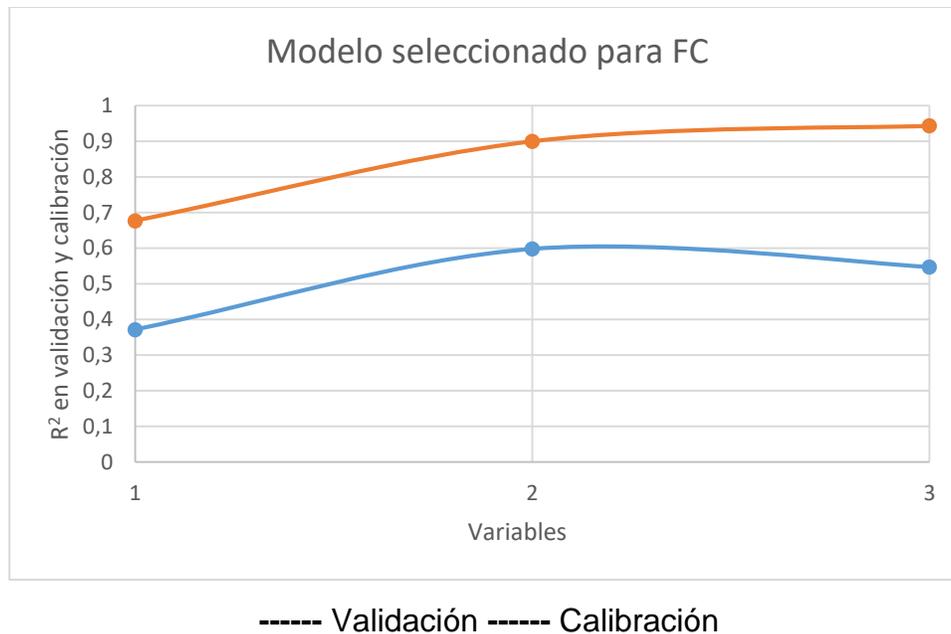
Con relación a la capacidad de campo se observa la evolución de los 100 modelos generados por los árboles extremadamente aleatorizados (Figura 68) con rangos del coeficiente de determinación (R^2) entre 0,066 y 0,598 en validación, y de 0,619 y 0,983 en calibración.

Figura 68: Evolución de los 100 modelos generados por árboles extremadamente aleatorizados en la fase de calibración y validación para la capacidad de campo (FC).



De estos cien modelos, se seleccionó el que mejor desempeño obtuvo en el proceso de la validación cruzada que involucra dos variables: la densidad aparente y la latitud. Lo anterior muestra una alta parsimonia, pues se presenta una capacidad de predicción alta con un número de variables bajas. En lo que respecta a los coeficientes de determinación para este modelo, estos son de 0,9429 en calibración y de 0,5981 en validación, como se observa en la Figura 69.

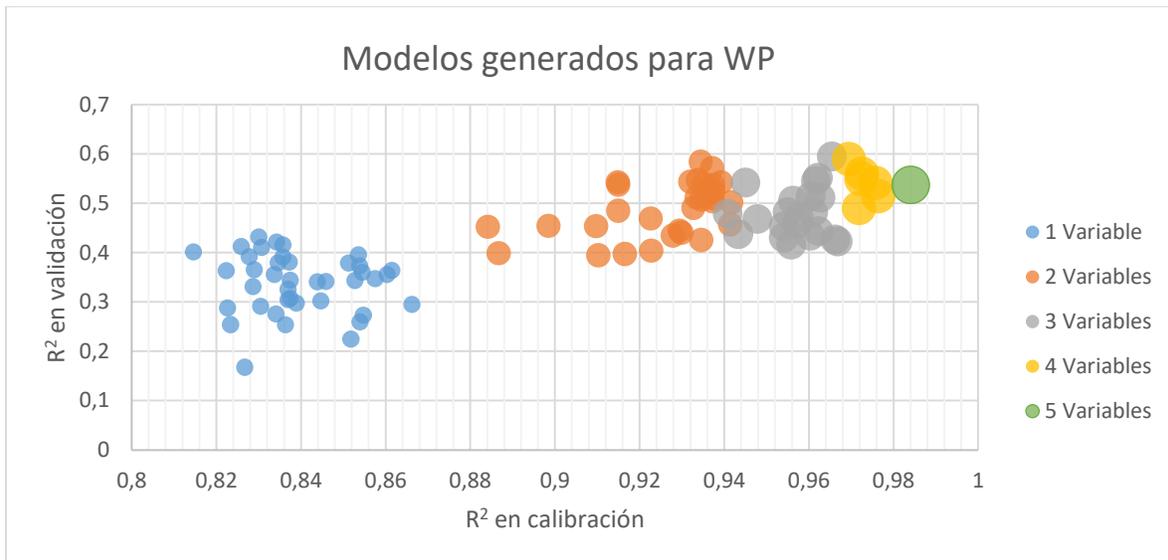
Figura 69: Evolución del modelo seleccionado por árboles extremadamente aleatorizados en validación y calibración para capacidad de campo (FC).



Punto de marchitez permanente (WP)

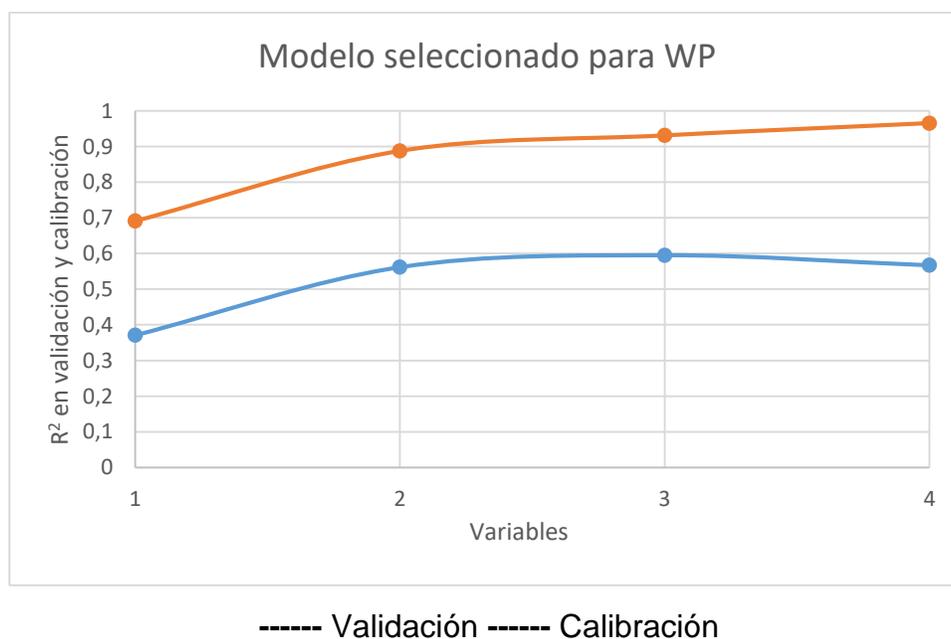
Se generaron cien modelos, donde se involucró desde una hasta cinco variables. De los modelos en el proceso de calibración se presentaron R^2 entre 0,631 y 0,984. En la validación cruzada estos valores están entre 0.112 y 59.5 (Figura 70).

Figura 70: Evolución de los 100 modelos generados por árboles extremadamente aleatorizados en la fase de calibración y validación, para el punto de marchitez (WP).



Del modelo seleccionado se muestra su evolución con tres variables, estas son la latitud norte, la densidad aparente y la altura sobre el nivel del mar. Los valores alcanzados en el desempeño son del 96,54 % en calibración y del 59,5% (Figura 71).

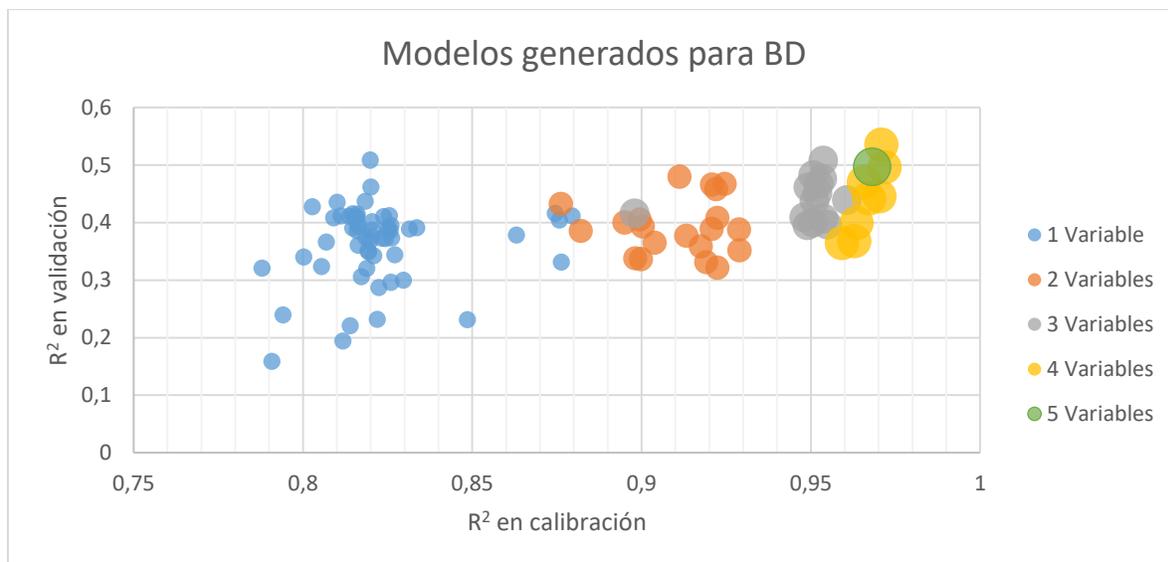
Figura 71: Modelo seleccionado por árboles extremadamente aleatorizados en las fases de validación y calibración, para el punto de marchitez (WP).



La densidad aparente (BD)

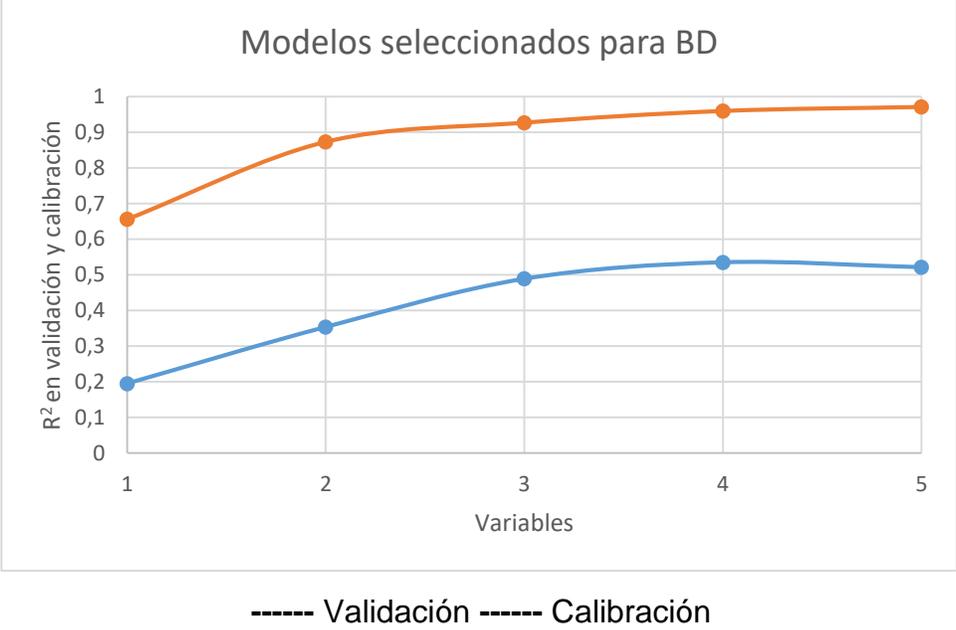
En cuanto a la densidad aparente, esta aparece con el mayor número de variables involucradas en la fase de calibración (cuatro) y alcanza un valor máximo del coeficiente de determinación (R^2) de 0,977 y mínimo de 0,2914. Para la validación, se obtuvieron valores entre los 0,1279 y 0,5352. Con respecto a los cien modelos generados y clasificados de acuerdo con las variables involucradas (Figura 72), se observa que el modelo con el mejor desempeño es el que presenta las coordenadas 0,97 y 0,535 con cuatro variables.

Figura 72: Evolución de los 100 modelos generados por árboles extremadamente aleatorizados en la fase de calibración y validación, para la densidad aparente (BD).



El modelo seleccionado, del cual se observa su evolución (Figura 73) en las fases de calibración y validación, involucra cuatro variables: el porcentaje de carbono orgánico, el porcentaje de arcilla, la latitud norte y las celdas acumuladas de drenaje.

Figura 73: Modelo seleccionado por árboles extremadamente aleatorizados en las fases de validación y calibración para la densidad aparente (BD).



4. ANÁLISIS DE RESULTADOS

4.1 CARACTERÍSTICAS FÍSICAS DE LOS SUELOS

En lo concerniente a los datos de la texturas analizadas, estas se encuentran en el rango de arenoso, arenoso franco y franco arenoso. La predominancia de los suelos Andisoles y Entisoles presenta gran cantidad de arenas o pseudoarenas, lo cual le da la característica encontrada (Figura 5). Algunas características del origen del suelo pueden influir en la textura, el material parental, el grado de evolución, y la interperación. A su vez, al estar en una zona de origen volcánico, esto parece influir en la textura principalmente arenosa que se presenta (Kooijman et al., 2005; Salamanca y Sadeghian, 2005). De otra parte, los suelos de origen volcánico se ven influenciados en su transformación por la temperatura y por la lluvia; en este caso, se tienen altitudes que varían desde los 1200 m hasta los 3000 m de altura, donde se mezclan con la materia orgánica para su mineralización, lo cual da origen a las texturas encontradas (Ibañez et al., 2011a,b).

En cuanto a propiedades como la densidad aparente, esta tiene un amplio rango en los suelos analizados (desde los $0,18 \text{ g/cm}^3$ hasta $1,71 \text{ g/cm}^3$), donde la distribución en profundidad de las muestras analizadas hace que la densidad aparente se incremente; no obstante, la gran mayoría de las muestras están en el rango de los $0,6 \text{ g/cm}^3$ a los $0,9 \text{ g/cm}^3$ (Figura 6).

Con relación a las densidades menores a uno, estas proveen mejores características de aireación y del movimiento del agua en el suelo (Barry, 1999; Salamanca, 2004). Esta densidad también está relacionada con la materia orgánica, pues esta disminuye en la medida que la materia orgánica aumenta. En este caso, se observa que a mayor profundidad, la densidad aparente debería tener valores más altos y disminuir los contenidos de materia orgánica (Figura 7) (Wolf, 2003; Valencia, 1999). En cuanto a la predicción con las ecuaciones de Baumer y Rawls (Tabla 7; Figuras 10 y 11), no se

observó una buena respuesta; en el mejor de los casos se acerca al 18 % de las predicciones, lo cual no corresponde con los datos tomados de campo.

4.2 PUNTO DE MARCHITEZ

En lo que respecta a los datos producidos por los modelos de edafotransferencia evaluados, estos se compararon con los valores observados y se espera que estos den como resultado una correlación lineal y un valor cercano a la unidad —con corte en el eje X en cero— como lo proponen algunos autores (Kobayashi y Salam, 2000). De igual forma, los valores de R^2 son realmente bajos (Tablas 2, 4 y 5) y no se ajustan de manera aceptable a una relación lineal; esto indica que los modelos propuestos en la literatura no reflejan muy bien las características de los suelos analizados.

En cuanto al contenido de agua del suelo (WP), este alcanza un coeficiente de determinación máximo de 0,0577, donde la aplicación del modelo propuesto por Rosetta presenta este nivel de predicción; sin embargo, el MSE (el cual muestra la dispersión de los datos) es alto y su predicción es subestimada. En este contexto, muchas de las estimaciones de los contenidos de agua en el suelo, cuando son utilizadas en otras latitudes diferentes a las de su origen, no muestran buena respuesta de predicción. Es así como De Medeiros (2004) propuso un modelo que subestima los datos, como lo muestra Martínez (2008); de igual forma, Rubio (2003) mediante el modelo Rosetta, derivó las curvas de retención de humedad para suelos franco limosos y, mostró que para los extremos, los datos se muestran bajos en comparación con los reales.

Con relación a las predicciones de Brakiensek (Figura 13) y de Saxton y Rawls (Figura 20), estas presentan valores de predicción más altos con respecto a la de los investigadores comparados. Así, los valores máximos de la estimación del punto de marchitez permanente rondan en $0,6 \text{ cm}^3/\text{cm}^3$; sin embargo, para los valores altos y bajos no se presentan buenas respuestas.

En lo concerniente a los demás investigadores, estos presentan predicciones en un rango determinado. *British Subsoil* y *Topsoil*, así como Hutson (Figuras 14, 15 y 16) muestran valores entre $0,05 \text{ cm}^3/\text{cm}^3$ y $0,2 \text{ cm}^3/\text{cm}^3$, los cuales son bastantes subestimados con respecto a los valores obtenidos a partir de los análisis de laboratorio. En lo que respecta a los modelos RETC y Rosetta (Figuras 21 y 22), estos presentan un comportamiento parecido en la predicción debido a que utilizan las variables de Van Genuchten para la estimación del punto de marchitez permanente. En este caso, estos investigadores usan como base de la estimación, la textura y la densidad aparente del suelo, y dejan de lado variables importantes del suelo como la materia orgánica. Así mismo, algunos investigadores han tratado de introducir la combinación de variables y observar cuales son las que proporcionan mejor predicción; mas, no han obtenidos buenos resultados, tal como lo experimentó Soto et al. (2001) quien involucró la textura como primer dato estimador, luego le adicionó la materia orgánica, el pH y la densidad aparente; no obstante, no obtuvo mejoras en la predicción.

En cuanto a otros estudios, Tomasella (Figura 19) y Manrique (Figura 17) presentan los datos de predicción más bajos de los investigadores evaluados. Estos autores basaron sus desarrollos en involucrar la textura de los suelos, la densidad aparente, la materia orgánica y la humedad equivalente.

En contraste con lo anterior, Nguyen (2017), con los modelos de datos recolectados y analizados de suelos en regiones tropicales, estos dan mejores resultados de predicción y, por consiguiente, mejores ajustes lineales con respecto a los modelos desarrollados para regiones templadas. Fue así como Medrado y Lima (2014) compararon sus resultados con los propuestos por Tomasella y obtuvieron resultados significativos (alrededor del 70 %) al utilizar la ecuación de Van Genuchten, que no es lineal, sino al derivar sus coeficientes para los suelos brasileños.

Otro hecho a tener en cuenta y palpable en cuanto a los datos estimados por los diferentes modelos, es el alto contenido de arena que presentan las muestras. Dado que estos contenidos superan el 70 % y, en algunos casos, los valores de carbono orgánico

el 10 %, la predicción del contenido de agua o de retención de esta —para los modelos evaluados— la muestran baja. Lo anterior explicaría el poco ajuste lineal en comparación con otros autores que introdujeron como variable el carbono orgánico, lo cual les dio mejores resultados (Rawls and Brakensiek, 1982; De Jong, 1983; Riley, 1979; Ambroise et al., 1992; Kern, 1995).

4.3 CAPACIDAD DE CAMPO

Para todos los casos analizados, las relaciones lineales entre los datos hallados en campo y los calculados por los diferentes investigadores, no presentan buena relación. En este ámbito, los valores no alcanzan más allá del 6,6 %, en el mejor de los casos (modelo Rosetta) y, en otros, (modelos como el de Tomasella y Saxton) presentan una baja explicación de su predicción, con respecto a los datos tomados de laboratorio. En cuanto al error medio (Tabla 5), este es alto e indica la dispersión de los datos, al igual que el error cuadrático medio y su raíz.

Así, la mayoría de los investigadores predicen con algún grado de exactitud los valores bajos de la capacidad de campo, con rangos entre el $0,2 \text{ cm}^3/\text{cm}^3$ y el $0,25 \text{ cm}^3/\text{cm}^3$, como es el caso de Baumer (Figura 23), Brakensiek (Figura 24) y *British Subsoil* (Figura 25), al igual que Hutson, Rawls y RETC (Figuras 27, 29 y 32).

En cuanto a *British Topsoil* y Tomasella (Figuras 26 y 30), no se observan que expliquen ningún dato obtenido en laboratorio; de este modo, la respuesta a la capacidad de campo de estos suelos no arroja ningún resultado válido.

Para la predicción de datos intermedios con valores entre $0,4 \text{ cm}^3/\text{cm}^3$ y $0,5 \text{ cm}^3/\text{cm}^3$, investigadores como Manrique, Saxton y Rawls, y Rosetta (Figuras 28, 31 y 33) son quienes presentan los mejores resultados; sin embargo, los errores calculados demuestran la dispersión de todo el conjunto de datos.

Con respecto las ecuaciones de SOILPAR para el cálculo de puntos de la curva de retención, autores como Zimmerman et al. (2011) ya habían utilizado algunas y obtuvieron datos diversos hasta para las mismas características de suelo; por lo anterior, afirman que todas estas ecuaciones se deben utilizar con precaución y que aún no hay modelos universales para estimar estas variables de contenido de agua en el suelo. No obstante, Rosetta mostró los mejores resultados en cuanto a los parámetros hidráulicos estimados, con un rango de error del 20 %; mientras que los demás errores son mucho mayores al sobreestimar o subestimar los contenidos de agua del suelo.

4.4 RETENCIÓN DE AGUA

En lo concerniente a los modelos analizados, todos sobreestimaron o subestimaron el contenido de agua disponible en el suelo (Baumer, Brakensiek, *British Subsoil*, Manrique, Rawls, Saxton y Rawls, Rosetta) (Figuras 34, 35, 36, 39, 40, 42 y 44). A su vez, en contraste con lo anterior, *British Topsoil* (Figura 37), Hutson (Figura 38), Tomasella (Figura 41) y RETC (Figura 43) tienden a subestimar los datos.

Con relación a la retención de agua en el suelo relacionada con los contenidos de materia orgánica, esta muestra una concentración entre los $0,01 \text{ cm}^3/\text{cm}^3$ y $0,24 \text{ cm}^3/\text{cm}^3$ (Figuras 8 y 9). Este elemento participa activamente en el suelo y produce mayor porosidad y retención de agua; además, con densidades aparentes bajas refleja una conductividad hidráulica proporcional al contenido de esta (Rubio, 2005; Brady, 1984). Con los datos obtenidos en campo se aprecia que no hay mucha variación en cuanto al agua contenida en el suelo con la profundidad; de igual modo, el porcentaje de carbono orgánico está concentrado hasta el 10 % con retenciones de $0,25 \text{ cm}^3/\text{cm}^3$ y tiene buenos contenidos en todos los horizontes analizados, tal como lo encontrado por Salamanca et al. (2005) para suelos con vocación cafetera en Colombia.

En cuanto a los suelos que mejor expresan los contenidos de agua del suelo, Blanco (2015) encontró que son los que tienen la mayor cantidad de variables parecidas con las cuales fueron calibrados. Así, destaca que el modelo de Rawls en 1982, que fue derivado

de un amplio número de suelos en la región de Norte América, y presenta las mejores correlaciones de predicción con los datos tomados de campo. Con relación a los altos valores en el error cuadrático medio y en su raíz, estos se pueden deber a la propagación de los errores en los diferentes modelos evaluados, así como a la variabilidad espacial de los suelos que se usan para la calibración de los diferentes modelos y al amplio rango de los datos entre los observados y los calculados (Tabla 6).

Debido a lo anterior, es necesario buscar modelos que se ajusten a la realidad que presentan los suelos colombianos; en especial, a los de la zona andina donde se asienta la mayor parte de la población y existe una gran oferta ambiental.

4.5 VARIABLES PREDICTIVAS

En este contexto, los investigadores han relacionado las propiedades hidráulicas, físicas y la fracción mineral de los suelos de las muestras tomadas en diferentes partes. Con estos datos, ellos han tratado de encasillar los suelos, según lo observado en la composición textural, y con base en esto han tratado de establecer parámetros iguales como si todos los suelos fueran homogéneos (Zimmerman, 2011; Carsel, 1988; Rawls, 1982). Por tal razón, con estas ecuaciones no se obtuvieron buenos resultados (Tablas 3, 4, 5 y 6).

A partir de lo anterior, se introdujeron otras variables y se realizaron regresiones simples y múltiples de las cuales se obtuvieron nuevas ecuaciones que mejoraron la predicción de variables hidrodinámicas del suelo. Fue así como se introdujeron, entre otras: la densidad aparente, la porosidad y la materia orgánica, así como puntos de la curva de retención de humedad, donde se muestran los trabajos con mejor predicción; sin embargo, en esta investigación, estas no reflejan muy bien las características de los suelos del Tolima y Quindío (Zimmerman, 2011; Zimmerman y Basile, 2006; Rawls, 1992; Williams et al., 1992).

En cuanto a análisis de suelos, Zimmerman (2011) utilizó *software* como Rosetta y SOILPAR 2.0 en la pampa Argentina y obtuvo resultados disimiles, donde algunos son sobreestimados y otros son subestimados. Dentro de estos, el resultado con menor variabilidad fue la humedad de saturación, con rangos de variación de 20 %, lo que parece no muy preciso; sin embargo, lo consideran con menor variabilidad. Los autores concluyen que la utilización de estas ecuaciones debe hacerse con cuidado, dado que resultados diferentes para una misma muestra —con varias ecuaciones— indica que no existen ecuaciones universales aplicables a las diferentes muestras de suelos.

Si bien, Blanco (2015) afirma que se han alcanzado avances en las funciones de edafotransferencia, su aplicación sigue siendo limitada debido a que se han propuesto para zonas específicas, en algún tipo de suelo, y se incluyen variables que no son fáciles de determinar o se han mezclado los datos de validación con los del entrenamiento (Blanco, 2015; Heuscher, 2005; Vos, 2005).

Aunque, Blanco (2015), plantea las ecuaciones de regresión de algunas variables del suelo y estas dan buenos resultados para sus muestras, la predicción con funciones de edafotransferencia de otros autores arrojan valores de r (coeficiente de correlación) entre los 0,6 y los 0,7 —lo cual es bueno— pero que tienen alguna similitud con los aquí hallados. A pesar de lo anterior, sigue habiendo incertidumbre en los datos obtenidos con diferentes funciones; por tanto, se observan mejores resultados aplicados a suelos similares para los cuales fueron derivadas. Este autor en su estudio plantea que sería bueno tener otras variables, como las geomorfométricas, e involucrarlas para explicar la predicción de las variables hidrodinámicas.

Las funciones de edafotransferencia, en gran medida, han sido derivadas de regresiones estadísticas. En este contexto, según Vereecken (2004) son una buena herramienta; sin embargo, hay que tener en cuenta algunos aspectos: primero, se recomienda observar o buscar si existen datos y estudios similares; luego, con el desarrollo de la regresión, construir un modelo de los existentes; y, por último, validarlo para mirar su ajuste. Es necesario, siempre, observar los errores, calcular el ajuste de la ecuación derivada,

considerar sus límites, el coeficiente de correlación y de determinación; así como el error cuadrático medio, tal como se ha hecho en este trabajo de investigación. Es probable que, dada la propagación de los errores y los valores bajos en los coeficientes de correlación estimados, sean escasas las ecuaciones planteadas por otros autores en otras latitudes que logren representar las funciones de los suelos del Tolima y el Quindío (Pachepsky, 1982; Rawls y Brakensiek, 1989; Scheinost, 1997).

En este contexto, otros autores han tratado de introducir variables que no se obtienen en campo, sino a partir de imágenes digitales (Minasny et al., 2008; Heuvelink y Pebesma, 1999). Es así como con imágenes espectrales es posible determinar datos medidos de la superficie del suelo, que también derivan en funciones de edafotransferencia, con resultados buenos que involucran varias propiedades físicas y químicas (Minasny et al., 2008).

Con relación a los análisis sobre el comportamiento de diversas funciones de edafotransferencia, Medina (2002) y Tomasella (2000) analizaron y observaron que la mayoría involucra el tamaño de las partículas o la textura, la densidad aparente y en algunos casos, la materia orgánica contenida en el suelo. Ellos afirman que estas no son suficientes para la determinación de la retención de la agua en el suelo; por tanto, sugieren que es necesario involucrar otras variables para, de esta forma, obtener una mayor precisión en el cálculo de la retención de agua en este caso. Sin embargo, a su vez, se deben tener el menor número de variables y que estas sean fácilmente medibles. Es así como algunos autores han intentado tener en cuenta otras variables como los contenidos de óxidos de hierro y aluminio, mas, son determinaciones costosas y que llevan mucho trabajo, no son simples ni económicas (Medina et al., 2002).

En este ámbito, involucrar otras variables de fácil adquisición es una alternativa que se viene desarrollando; por ende, elementos como la pendiente, el perfil de la curvatura y la cobertura se pueden extraer fácilmente de un modelo de elevación digital y han demostrado que mejoran la predicción (Van Looy et al., 2017; Romano, 2004; McBratney et al., 2003; Romano y Palladino, 2002).

De las variables seleccionadas inicialmente (19) se seleccionaron 12 como las no redundantes para un modelo predictivo. Lo anterior se realizó mediante el análisis de las correlaciones de Pearson y Spearman. Fue así como quedaron excluidas las variables longitud (que es la coordenada geográfica oeste o este) y la curvatura (longitudinal y transversal), las cuales están explicadas a partir de la variable general de la curvatura del terreno y de la cuenca en la cual fue tomado el punto; además, se excluyeron como variables de entrada la capacidad de campo, el punto de marchitez permanente y la retención de agua, consideradas como variables predictivas (ver las tablas de la correlación del Anexo 1).

4.6 REDES NEURONALES

Con respecto a la búsqueda del modelo mediante redes neuronales, se realizó otra selección de variables a través del proceso paso a paso de dichas redes. Como resultado, para la densidad aparente se encontró que 7 son las variables relevantes para la construcción del modelo predictivo, al igual que la cantidad de agua retenida por el suelo. En cuanto a las variables de la capacidad de campo y el punto de marchitez permanente, solo se necesitaron 5 variables de entrada para la construcción del modelo predictivo. Lo anterior, hizo mucho más rápido el proceso de generación de los modelos para las variables a predecir (Tabla 2 y Figuras 45, 46, 47 y 48).

Con relación al desempeño de la red neuronal, para todos los casos es bueno. En lo que respecta al punto de marchitez, el coeficiente de determinación presenta valores crecientes en las tres etapas: entrenamiento, validación y test, y alcanza su valor máximo (79 %) en la última etapa. Esto hace ver la bondad de esta técnica para la búsqueda de las predicciones de las variables y en lo concerniente al comportamiento de estas fases (Figuras 57, 58 y 59). Los demás indicadores, tales como el error medio, el error cuadrático medio y su raíz, son bajos (Tabla 8); sin embargo, investigadores como Koekkoekk (1999), Minasny et al. (1999) y Rubio (2005) reportan datos con errores menores.

En lo concerniente a la ecuación que predice el punto de marchitez permanente, esta involucra cinco variables relevantes: la densidad aparente, la altitud, la latitud, la pendiente y el porcentaje de arcilla contenido en el suelo. De las anteriores, solo dos (la densidad aparente y el contenido de arcilla) son tomadas del lugar de muestreo, las demás son extraídas de un modelo de elevación digital. En los estudios de Bayat (2011), al igual que en el de Wang et al. (2012), se establece que para su red neuronal es necesario trabajar con variables extraídas de las muestras de suelo, tales como las fracciones minerales, la densidad aparente y el tamaño de los poros. Si bien, se obtuvieron buenos resultados en la predicción, si se involucran otras variables que puedan tener influencia en la predicción —y que son de fácil adquisición— esto también lleva a buenos resultados.

En cuanto a la capacidad de campo (Tabla 8) se encuentra que el coeficiente de determinación es estable para las tres etapas de desempeño de la red, con errores bajos y un valor bastante aceptable para la predicción de esta variable (75 %). Si bien, Schaap (1998) y Rubio (2005) encontraron errores medios alrededor del $0,1 \text{ cm}^3/\text{cm}^3$, sus análisis los hacen al diferenciar a las profundidades de los diferentes horizontes; lo anterior es contrario a lo aquí expuesto, dado que se tomaron todos los perfiles sin clasificarlos.

Para la capacidad de campo, las variables predictivas involucradas fueron la densidad aparente, la latitud, la pendiente del terreno, la elevación sobre el nivel del mar y la cobertura que presenta la zona. De las anteriores, solo la densidad aparente se determinó en laboratorio, las demás son producto del modelo de elevación digital. Esto hace que predecir el contenido de agua a capacidad de campo para estos suelos fuese más fácil, gracias al acceso a la información base que se requiere.

En lo que respecta al agua disponible, esta tiene un desempeño elevado en el periodo de validación y alcanzó un valor del 84 % en el coeficiente de determinación. En este contexto, la predicción de la densidad aparente y el coeficiente de determinación se mantuvieron estables en las tres fases, con valores alrededor del 76 % (Tabla 8).

Con relación a las variables involucradas para predecir el agua disponible, estas fueron la altura sobre el nivel del mar, la densidad aparente, el espesor del horizonte, el porcentaje de carbono orgánico, la cobertura y el porcentaje de arena contenida en el suelo. De esta forma, se observa una combinación de características de la muestra de suelo, así como de su ubicación, donde predominan las primeras e indican que para predecir esta variable es necesario tener las características físicas del suelo, tal como lo hicieron Bayat (2011) y Wang et al. (2012) para sus redes neuronales.

En cuanto a la densidad aparente como variable predictiva, el coeficiente de determinación oscila alrededor del 76 % de desempeño en las tres fases analizadas; si bien, los errores fueron bajos, estos puede ser sensibles dado que el contenido de materia orgánica afecta el resultado (Tabla 8 y Figuras 54, 55 y 56)

En lo que concierne a las variables involucradas para predecir la densidad aparente de los suelos neoandinos, estas fueron la latitud, el contenido de carbono orgánico, la altitud sobre el nivel del mar, el porcentaje de arena que presenta el suelo, la pendiente del lugar, el porcentaje de arcilla contenida y la cobertura de la zona.

Con respecto a las redes neuronales, estas se presentan como una herramienta para proponer modelos no lineales. En el ámbito de este trabajo, investigadores como Sarmadian y Keshavarzy (2010) encontraron coeficientes de determinación de 0,72 para la red neuronal planteada por ellos y, comparada con los modelos derivados de regresiones multivariantes, estos explicaron los datos hasta en un 50 %. No obstante, la raíz del error cuadrático medio aumentó, mas, esto también le sucedió a otros investigadores (Amini et al., 2005; Tamari et al., 1996; Minasny y MacBratney, 2002).

Se destaca que las redes neuronales no requieren un modelo previo al que deben ajustarse, como sucede con las regresiones, pues previamente no se conoce la relación que hay entre las entradas y las salidas, según lo habían afirmado Schaap y Leij (1998). Además, pueden tener varias etapas de entrenamiento y generar gran precisión en la predicción de las variables (Gardner y Dorling, 1998; Ebrahim-Zadeh et al., 2017).

Asimismo, la estimación de las propiedades hidráulicas del suelo supera a las regresiones multivariantes, donde la no linealidad del comportamiento de la red neuronal le permite alcanzar un mejor resultado comparado con los modelos lineales.

Al compararse los modelos de las redes neuronales con los de regresión (Pachepsky, 1996) se encontró que para las primeras, estos predicen mucho mejor los parámetros hidrodinámicos del suelo al presentar un error menor y baja dispersión de los datos. Sin embargo, se aclara que si se cuenta con datos bien seleccionados y con un buen entrenamiento, los modelos lineales pueden dar una buena predicción.

De otra parte, las redes neuronales, según Nemes (2003) y Parasuraman (2006), tienen mejor desempeño cuando se tiene un buen número de datos, en lugar de muchos datos de diversos lugares. Si estos datos están relacionados con las propiedades reales del suelo y son de una misma zona, así no sean muchos, la red neuronal presenta un mejor desempeño que el hecho de tomar datos de otras latitudes. Según lo anterior, esto hace relevante el estudio de los suelos de la región, a partir de los cuales se tiene poca información y pocas funciones de edafotransferencia. En consecuencia, el tomar otras variables disponibles reforzó la efectividad de la predicción de la red neuronal y ratificó la importancia del uso de los datos locales.

4.7 ÁRBOLES ALTAMENTE ALEATORIZADOS

En el ámbito de los árboles altamente aleatorizados y extremadamente aleatorizados, estos tienen una alta robustez para establecer los mejores desempeños con el menor número de variables. De todos los datos, se generaron aleatoriamente 100 modelos, a partir de los cuales se realizaron las etapas de entrenamiento, la validación cruzada y las pruebas con los datos disponibles, donde se tuvieron en cuenta las medias y las desviaciones estándar de las variables de salida.

Con relación a los árboles extremadamente aleatorizados, estos necesitan unos parámetros adicionales para su correcto desempeño, tales como la cantidad de árboles

a ensamblar (M), la cantidad de muestras mínimas requeridas para hacer la división en el nodo (n min) y el parámetro de fuerza de selección de atributo (K). En esta investigación se designó un número de 100 árboles a construir ($M=100$), el número de muestras para hacer la división en nodo (n min=5) y el parámetro de fuerza que corresponde a la cantidad de variables de entrada en cada predicción; así, para AW, FC y WP estas son doce, y en el caso de BD, son once. Estos valores se escogieron debido al rendimiento computacional, pues a mayor número de árboles, y con valores diferentes de datos para la división, no se observó mejora en el desempeño (Geurts et al., 2006; Ahmad et al., 2018).

Agua disponible en el suelo (AW)

En cuanto a los modelos elaborados en la etapa de calibración, se generaron cien que alcanzaron un máximo del 97,27 % de R^2 , el cual evolucionó desde el 32 % —con una sola variable— y alcanzó el valor más alto al involucrar seis variables como máximo. Dado que cada modelo evoluciona desde un coeficiente de determinación bajo y va ascendiendo hasta que alcanza un máximo, con la siguiente variable, cuyo desempeño es menor, el modelo se detiene y está totalmente construido (Figuras 66 y 67).

De esta forma, en la Figura 66 se observa la evolución de los diferentes modelos generados en las etapas de validación y calibración, además de las variables involucradas. Por tanto, el modelo seleccionado presenta un R^2 de calibración del 93,96 % y en validación del 55,72 % con tres variables.

Con relación a las variables involucradas en el modelo seleccionado, estas son la altura sobre el nivel del mar, la densidad aparente y la curvatura del terreno. De este modo, se observa en las dos etapas el crecimiento del desempeño, el cual parte de valores bajos (0,29) y llega hasta el punto más alto con tres variables (0,557); ya para la siguiente variable desciende hasta 0,546 y detiene la construcción del modelo (Figura 67).

Capacidad de campo (FC)

Con respecto a los cien modelos generados, tanto en la calibración como en la validación cruzada (Figura 68), el modelo que mejor se desempeñó tuvo valores entre los 0,598 y los 0,9429 de R^2 , con dos variables involucradas. Así, el hecho de presentar dos variables para el modelo predictivo del agua en el suelo —a capacidad de campo— lo hace parsimonioso, fácil de utilizar y con variables relativamente fáciles de determinar.

En lo concerniente a la evolución del modelo seleccionado en las etapas de calibración y validación cruzada (Figura 69), este alcanzó un desempeño del 59,8 % con dos variables. Dichas variables fueron la densidad aparente y la altura sobre el nivel del mar. A su vez, estas variables involucraron tanto el trabajo de campo como el de laboratorio, donde se encontró que la densidad aparente es una característica de cada una de las muestras —a la par con la textura— y que también está relacionada con la materia orgánica contenida en el suelo. La otra variable, la altura sobre el nivel del mar, se obtuvo del modelo de elevación digital y es un dato que es de fácil consecución, lo cual hace que este modelo predictivo sea sencillo en su funcionamiento.

Punto de marchitez permanente (WP)

Para este punto, se generaron cien modelos, los cuales en calibración evolucionaron desde el 81 % hasta el 98 % de R^2 . De este modo, en el proceso de la validación cruzada fue desde el 16 % hasta el 59,5 % de R^2 , e involucró desde una hasta cinco variables, como se observa en la Figura 70.

En cuanto al modelo seleccionado (0,969; 0,589) con tres variables involucradas: la latitud norte, la densidad aparente y la altura sobre el nivel del mar, una de ellas, la densidad aparente, es una variable física; las otras dos fueron derivadas del modelo de elevación digital. De esta forma, el hecho de involucrar pocas variables, lo hizo y lo hace un modelo sencillo —y con información posible de encontrar— como se requiere en las investigaciones (Figura 71).

Densidad aparente (BD)

Con relación a esta variable predictiva, se generaron cien modelos (Figura 72) e involucraron desde una hasta cinco variables. Las evoluciones en las etapas de calibración y validación se incrementaron y alcanzaron valores hasta del 97 % de R^2 en la calibración y del 53,5 % en la validación. En cuanto al modelo seleccionado, se incluyeron cuatro variables, estas son el porcentaje de carbono, el porcentaje de arcilla presente en el suelo, la latitud norte y el drenaje acumulado de las celdas.

Así, en la Figura 73, se observa la evolución del modelo seleccionado con las cuatro variables para la predicción de la densidad aparente. En la etapa de calibración, se alcanzó un coeficiente de determinación de 0,959 con cuatro variables y de 0,535 para la validación. A su vez, se evidencia cómo los árboles extremadamente aleatorizados detienen la construcción del modelo, cuando este empieza a descender en el coeficiente de determinación.

Comparación entre los diferentes modelos

Con respecto a los modelos de predicción realizados por diferentes investigadores, a partir de los datos procedentes de diferentes partes del mundo, estos no arrojaron buenos resultados debido a que su predicción no es coincidente con los datos tomados en campo. En este contexto, las principales variables involucradas en los diferentes modelos son la textura, la densidad aparente y la cantidad de carbono orgánico.

En lo que concierne a las redes neuronales, estas mostraron un desempeño mucho mejor que el caso anterior, donde, en la etapa de calibración, estuvo entre el 63 % en R^2 y llegó hasta 75 % para la validación y el test. En todos los casos, el ajuste del modelo estuvo alrededor del 75 % de R^2 y se observó una mejora sustancial comparada con los modelos propuestos por diversos autores. Así, las variables involucradas para los modelos predictores están entre las características físicas del suelo, la densidad aparente, la cantidad de arcilla, el contenido de carbono orgánico —así como espesor de los horizontes— y se complementa con variables del modelo de elevación digital como

son la altura sobre el nivel del mar, la latitud del punto, la cobertura de la zona y la pendiente del terreno.

En relación con los árboles altamente aleatorizados, estos presentaron, en la etapa de calibración, desempeños altos con valores alrededor del 98 % de R^2 para todos los casos. Para la validación el desempeño, esta disminuyó pero alcanzó valores cercanos al 55 %, lo cual es mucho mejor que cualquiera de los modelos expuestos en esta investigación por autores de otras latitudes. En cuanto a las variables seleccionadas para el modelo, se escogieron las físicas del suelo, como son las del modelo de elevación digital. En este contexto, las variables fueron la densidad aparente, el contenido de arcilla y de carbono orgánico. En cuanto a las variables seleccionadas para el modelo de elevación digital, estas fueron la curvatura, el drenaje de la zona, la elevación sobre el nivel del mar y la latitud. De esta forma, la inclusión de otras variables disponibles en los modelos de elevación digital permitió un mejor desempeño a los modelos aquí planteados, poco usados para el cálculo de la densidad aparente del suelo, y de los contenidos de agua en el suelo.

Al comparar los modelos de las redes neuronales, y los árboles extremadamente aleatorizados, se encontró que las variables involucradas en los modelos seleccionados de las variables predictivas tuvieron datos tomados de campo y determinadas en laboratorio, con las del modelo de elevación digital. En ambos modelos, la densidad aparente es una variable recurrente, al igual que la altura sobre el nivel del mar; estas aparecen como variables independientes tanto en redes neuronales como en los árboles extremadamente aleatorizados. Lo anterior, puede deberse a la gran variedad de suelos que se usaron para la derivación de los modelos predictivos; así, en la densidad aparente, estos valores oscilaron entre los 0,18 g/cm³ hasta los 1,71 g/cm³, y la altitud desde los 1300 m s.n.m. hasta los 3200 m s.n.m.

Otra variable relevante es la latitud norte, pues se presenta en varios modelos generados en los casos aquí analizados. Esta variable representa la ubicación sobre el globo terráqueo que involucra la radiación solar, la influencia de la inclinación del eje terrestre

y de alguna manera, los cambios de temperatura, según la época del año en latitudes más septentrionales.

Otras variables que también están involucradas en los modelos planteados por los *Extra Trees* son la textura, la cual es citada por diversos investigadores (Rawls 1982, Rosetta, SOILPAR), la cual es relevante para la caracterización de los suelos, su origen, y la relación con el paso de fluidos a través de esta matriz. De igual modo, están las celdas acumuladas de drenaje, pues por estas se transportan materiales como las texturas y la materia orgánica. De esta forma, la cobertura del suelo influye en la cantidad de agua disponible por los materiales que aporta, tales como la materia orgánica y la disposición para una rápida o lenta evaporación.

En cuanto a las redes neuronales, se presenta como variable de entrada común la textura, la cual depende del espesor del horizonte donde se presenta la migración de sustancias, el agua que transporta los diferentes solutos, el proceso de descomposición de la materia orgánica y los cambios en la densidad aparente por la acumulación de esta o su cambio a otros materiales. Con relación a la pendiente y la curvatura, estas se muestran como variables que influyen en el transporte de sedimentos o acumulación de estos, al dar diversos resultados en cuanto a la densidad aparente o la capacidad de retención de agua del suelo.

Por último, los modelos predictivos derivados de los árboles extremadamente aleatorizados presentan mucho menos variables, en promedio tres, con un mínimo de dos y un máximo de cuatro, lo cual lo hace económico en el uso o determinación de estos valores. En contraste, en las redes neuronales hay más variables involucradas —mínimo cinco variables y máximo siete— por lo tanto, se requieren valores del terreno y de modelos de elevación digital. Sin embargo, estas últimas son unas herramientas poderosas que determinan cuales son las variables principales que se deben usar para predecir una variable del agua en el suelo o la densidad aparente.

5. CONCLUSIONES

Los modelos planteados por diferentes autores representan una herramienta para la predicción del punto de marchitez permanente y la capacidad de campo de un suelo, pues con unos datos básicos de entrada, se pueden calcular estos valores. Sin embargo, al ser desarrollados en otras latitudes, estos presentan errores grandes para los suelos colombianos; de este modo, arrojan resultados cercanos al 10 % de R^2 comparado con los observados en el mejor de los casos, puesto que algunos no tienen ningún poder de predicción.

Las funciones que han sido desarrolladas en otras latitudes sirven como una guía para determinar algunas variables hidrodinámicas del suelo; no obstante, se deben usar, en lo posible, funciones de suelos con características similares.

Si bien, el número de muestras analizadas en este estudio no es tan alto, estas son una guía para el desarrollo de funciones de edafotransferencia de suelos andinos, derivados principalmente del comportamiento geológico, edafológico y climático de la zona, lo cual le confiere unas características especiales.

Además de lo anterior, se pueden involucrar otros datos que ayudan a explicar la cantidad de agua retenida por el suelo, tales como la pendiente, la cobertura y la ubicación espacial; datos que son fáciles de determinar y al alcance de los usuarios, y que también intervienen en las variables a estimar.

La inclusión de estas últimas variables hace que los datos de predicción tengan mejor ajuste en los modelos planteados. De este modo, se puede tener una mejor predicción de las variables sin aumentar el trabajo de la consecución de nuevas variables que ayuden a explicar el comportamiento hidrodinámico de los suelos del Tolima y Quindío.

En cuanto a las redes neuronales, estas son una herramienta poderosa, pues no se ajustan a un modelo determinado sino que buscan el modelo que mejor resultados ofrezca; para este caso, con 50.000 modelos analizados para cada variable dependiente, se escogió el de más alto promedio en sus tres fases: entrenamiento, validación y prueba o test final, lo cual dio como resultados, ajustes del R^2 por encima de 75 % y MSE relativamente bajos. Lo anterior, indica que el modelo se ajusta muy bien y su dispersión es baja.

En esta investigación se observó que las ecuaciones propuestas por otros autores tienen un ajuste bajo (un determinante que llega hasta el 10 %). Es así como a partir de las investigaciones realizadas en varias partes del mundo, estas no presentan una buena respuesta, lo cual indica que la latitud y el origen de los suelos pueden tener especial importancia en las características de estos.

Con respecto a las redes neuronales, estas pudieron derivar variables y ecuaciones que representan tanto a la densidad aparente como a los contenidos de agua disponible; asimismo, el punto de marchitez permanente y la capacidad de campo para los suelos de los andes colombianos. Esas alcanzaron desempeños para las predicciones cercanos al 75 % en R^2 , los cuales son muy buenos comparados con los resultados de los modelos propuestos anteriormente, y derivados, en particular, de regresiones lineales.

Los árboles altamente aleatorizados y los árboles extremadamente aleatorizados, son otra herramienta computacional poderosa para la clasificación, jerarquización y modelación de las variables físicas del suelo, así como las del modelo de elevación digital. Con desempeños para la calibración alrededor del 98 % y la validación cercanos al 55 %, estos reflejan de algún modo el comportamiento del contenido del agua en los suelos de la zona andina y de su densidad aparente, al involucrar tanto a las variables del suelo como a las del modelo de elevación digital, al alcanzar un total de seis variables para explicar el comportamiento de estas.

En ambos modelos, redes neuronales y árboles extremadamente aleatorizados, las variables que presentan mayor recurrencia son la densidad aparente, la altura sobre el nivel del mar y la altitud. Otras que se presentan en ambos modelos son la textura expresada como porcentaje de arcilla y el contenido de carbono orgánico. Con menor frecuencia, están la pendiente, la cobertura y el espesor del horizonte que está en las redes neuronales.

En cuanto al desempeño computacional, los árboles extremadamente aleatorizados son mucho más versátiles. Cada ronda del proceso de generación de los modelos —que fueron cien— se demoró alrededor de un día en comparación con las redes neuronales, las cuales se tardaron cerca de una semana en cada variable. Estas generaron cincuenta mil modelos. Para esta investigación se analizaron cuatro, la densidad aparente, el punto de marchitez permanente, la capacidad de campo y el agua retenida por el suelo.

Por último, y como conclusión final, con el desarrollo de *software* y el acceso al procesamiento de computadores, los investigadores pueden acceder a diferentes herramientas con la finalidad de resolver casos que se tienen pero que no se ajustan a los modelos tradicionales; lo anterior, permite la comparación con los resultados obtenidos por otros autores.

6. FUTURAS LÍNEAS DE INVESTIGACIÓN

Con el desarrollo de los sensores remotos se ha abierto nuevas posibilidades en cuanto a la inclusión de otras variables fáciles de identificar. Entre estas se tienen la pendiente, la altura, y la cobertura como posibilidades para mejorar el cálculo de la retención de agua y la determinación de la conductividad hidráulica en diferentes suelos. A su vez, se puede comparar con investigaciones ya realizadas y solo hay que adicionar estas u otras variables para comparar los resultados.

Con el uso de los detectores remotos, es posible generar nuevas funciones de pedotransferencias que serían de gran utilidad en sitios de difícil acceso, pero que son de gran importancia ecológica a nivel de producción del agua o de la conservación. Con esto se podría generalizar el uso de las funciones de edafotransferencia al ahorrar costos de mano de obra, laboratorio y tiempo. Asimismo, además de las zonas tropicales —de las cuales se tiene poca información— se tendría acceso a ella para futuras investigaciones.

En la actualidad, con los datos sobre suelos que se tienen alrededor del mundo, no son suficientes los modelos de edafotransferencia desarrollados; en consecuencia, hay que seguir con el trabajo de campo en locaciones con suelos poco estudiados, como es el caso de suelos andinos neotropicales. Dicho trabajo es complejo y costoso dadas las condiciones del terreno, pero reforzaría las investigaciones ya realizadas.

Se sugiere recopilar toda la información que se encuentra dispersa; de este modo, hacer una base de datos a nivel mundial y el planteamiento de nuevas funciones de pedotransferencia al servicio de la humanidad.

Con nuevas técnicas como las redes neuronales y otras técnicas de aprendizaje de máquinas (regresión por contrastes, entre otras), es necesario explorar el cálculo de nuevas funciones de edafotransferencia, o la mejor determinación de los coeficientes de curvas de retención de humedad, como las propuestas por Van Genuchten.

En futuras investigaciones, se debe considerar el efecto de los fragmentos de roca en el comportamiento hidráulico del suelo y su impacto en el desempeño de las funciones de edafotransferencia.

Con relación a los árboles extremadamente aleatorizados, es necesario seguir investigando la estabilidad de los modelos —con el número generado por el algoritmo— debido al gran consumo de tiempo en el proceso de la información, con el fin de encontrar el número óptimo de árboles a generar.

Se debe seguir generando nuevo conocimiento con herramientas como las de clasificación y selección de variables, pues estas permiten procesar la información y trabajar con la más relevante. Esto se puede probar al combinar los dos modelos para la evaluación de las variables predictivas expuestos en esta investigación, con los árboles extremadamente aleatorizados, seleccionar las variables de mayor importancia y luego derivar las ecuaciones de modelado con las redes neuronales.

REFERENCIAS

- Acutis, M., y Donatelli, M. (2003). SOILPAR 2.00: Software to estimate soil hydrological parameters and functions. *European Journal of Agronomy*, 373-377.
- Adams, W. A. (1973). The effect of organic matter on the bulk and true densities of some uncultivated Podzolic soils. *Journal of Soil Science*, 24, 1, 10-17.
- Adhikary, P. P., Chakraborty, D., Kalra, N., Sachdev, C. B., Patra, A. K., Kumar, S., Tomar, R. K., Chandna, P., Raghav, D., Agrawal, K., y Sehgal, M. (2008). Pedotransfer functions for predicting the hydraulic properties of Indian soils. *Australian Journal of Soil Research*, 46 (5), 476–484.
- Ahmad, M. W., Reynolds, J., y Rezgui, Y. (2018). Predictive modelling for solar thermal energy systems: A comparison of support vector regression, random forest, extra trees and regression trees. *Journal of Cleaner Production*, 203, 810-821.
- Aina, P. O., y Periaswamy, S. P. (1985). Estimating available water-holding capacity of western Nigerian soils from soil texture and bulk density, using core and sieved samples. *Soil Science*, 140, 55-58.
- Ambroise, B., Reutenauer, D., y Viville, D. (1992). Estimating soil water retention properties from mineral and organic fractions of coarse-textured soils in the Vosges mountains of France. En M. T. van Genuchten, Leij, F. J., y Lund, L. J. (Eds.), *Indirect methods for estimating the hydraulic properties of unsaturated soils* (pp. 453-462). Riverside CA, U.S.A: University of California.American Society of Agronomy, ASA. (2002). *Methods of soil analysis. Part 1: Physical and mineralogical methods*. Klute, A. (Ed). Wisconsin, USA: Soil Science Society of America, Inc. Publisher Madinson.
- Amini, M., Abbaspour, K., Khademi, N., Fathianpour, M., Afyuni, y Schulin, R. (2005). Neural network models to predict cationic exchange capacity in arid regions of Iran, *European Journal of Soil Science*, 53, 748-757.
- Arrieche, I., y Pacheco, Y. (1998). Determination of Organic Carbon In Soil Samples Using Two Analytical Methods. *Fondo Nacional de Investigaciones Agropecuarias del Estado Yaracuy*, 6,12.

- Arroyave, F. P. (2007). *Contribución de la precipitación horizontal al ciclo hidrológico de los páramos, con referencia inicial al páramo de Guerrero* [Tesis MSc.] Universidad Nacional de Colombia. Medellín.
- Baker, L., y Ellison, D. (2007). Optimization of pedotransfer functions using an artificial neural network ensemble method. *Geoderma*, 108, 277–285.
- Barraientos, R. E., Cruz, N., Acosta, H. G., Rabatte, I., Gogeoascoechea, M. C., Pavón, P., y Blázquez, S. L. (2009). Árboles de decisión como herramienta en el diagnóstico médico. *Revista médica de la Universidad Veracruzana*, 9(2), 19-24.
- Barron, G., y Peterson, J. L. (1968). The genera of Hyphomycetes from soil. *Journal Article Soil Science V*, 106, 477.
- Barros, H., Van, L. Q. Nunes, A., y Scarpore, F. (2013). Pedotransfer function to estimate water retention parameters of soil in northeastern Brazil. *Revista Brasileira de Ciências do Solo*, 37, 379-391.
- Barry, A. (1999). *Soil biological, chemical and physical dynamics during transition to non-thermal residue grass seed management system*. Oregon: Oregon State University and College Agriculture.
- Baumer, O., Kenyon, P., y Bettis, J. (1994). *MUUF v214 User's Manual*. Lincoln, Neb, U.S.A: National Soil Survey Center.
- Bayat, H., Neyshabouri, M., Mohammadi, K., y Nariman-Zadeh, N. (2011). Estimating water retention with pedotransfer functions multi objective group method of data handling and ANNs. *Pedosphere*, 21, 107–114.
- Bishop, C. (1996). Neural Networks for Pattern Recognition. *Technical Report: NCRG /96/001*. Birmingham, UK: Oxford University Press, *Neural computing Research Group, Aston University*.
- Blanco, A. (2015). Estudio de la distribución espacial y cartográfica digital de algunas propiedades físicas, químicas e hidrodinámicas de suelos de la cuenca del Segura [Tesis Doctoral]. Universidad de Murcia, España.
- Bonet-Cruz, I., Salazar-Martínez, S., Rodríguez-Abed, A., Grau-Ábalo, R., y García-Lorenzo, M. M. (2007). Redes neuronales recurrentes para el análisis de secuencias. *Revista Cubana de Ciencias Informáticas*, 1, 4, 48-57.

- Botula, Y. D. (2013). *Indirect methods to predict hydrophysical properties of soils of Lower Congo*. Gent, Belgium: Ghent University.
- Botula, Y. D, Cornelis, W. M., Baert, G., y Van, R. E. (2012). Evaluation of pedotransfer functions for predicting water retention of soils in Lower Congo (D.R. Congo). *Agricultural Water Management*, 111, 1–10.
- Bouyoucos, G. J. (1963). Direction for Making mechanical analysis of soil by hydrometer method. *Soil Science*, 42, 25-30.
- Brady, N. C. (1984). *The nature and properties of soils*. New York, U.S.A.: MacMillan Publishing Company.
- Brakensiek, D. L., Rawls, W. J., y Stephenson, G. R. (1986). A note on determining soil properties for soils containing rock fragments. *Journal of Range Management*, 39(5), 408–409.
- Briggs, L. J., y McLane, J. W. (1907). The moisture equivalent of soils. U.S.D.A. *Bur. Soils Bull.*, 45. Washington D.C.: U.S.D.A.
- Briggs, L. J., y Shantz, H. L. (1912). The wilting coefficient for different plants and its indirect determination. *Bull 230*. Washington, D.C.: USDA Bureau Plant Ind.
- Brooks, R. H., y Corey, A. T. (1964). *Hydraulic properties of porous media, Hydrology paper No. 3*. Fort Collins Colorado, U.S.A.: Colorado State University.
- Brooks, R. H., y Corey, A. T. (1966). Properties of porous media affecting fluid flow. *Journal of the Irrigation and Drainage Division*, 92, 61–88.
- Bruand, A., Duval, O., Gaillard, H., Darthout, R., y Jamagne, M. (1996). Variabilité des propriétés de rétention en eau des sols: Importance de la densité apparente. *Etude et Gestion des sols*, 31, 27–40
- Bruand, A., Perez-Fernandez, P., y Duval, O. (2003). Use of class pedotransfer functions based on texture and bulk density of clods to generate water retention curves. *Soil Use and Management*, 19, 232-242. Doi 10.1079/SUM2003196.
- Bruijnzeel, L. A. (2001). Hydrology of tropical montane cloud forests: A Reassessment. *Land Use and Water Resources Research*, 1, 1.1-1.18.

- Bugna, G., Grace, J. M., y Yuch-Ping, H. (2020). Sensitivity of using stable water isotopic tracers to study the hydrology of isolated wetlands in North Florida. *Journal of Hydrology*, 580.
- Calegari da Silva, A. (2015). *Modelos de pedotransferência aplicados na dimulação das funções hidráulicas e da variabilidade espacial do solo* [Dissertação à obtenção do título de Mestre em Ciência do Solo]. Universidad Federal de Paraná.
- Calegari Da Silva, A., Armindo, R., Dos Santos, A., y Schaap, M. (2017). SPLINTEX: A physically-based pedotransfer function for modeling soil hydraulic functions. *Soil & Tillage Research* 174, 261-272.
- Calle, K., y Proaño, J. (2006). *Determinación de la curva de retención de humedad para los principales tipos de suelos de la península de Santa Elena, Provincia del Guayas*. X Congreso Ecuatoriano de la Ciencia del Suelos. Guayaquil, Ecuador.
- Campbell, G. S. (1974). A simple method for determining unsaturated conductivity from moisture retention data. *Soil Science*, 117, 311–314.
- Campbell, G. S. (1985). *Soil physics with BASIC*. Springer-Verlag: New York. *Elsevier Science*, 14, 149.
- Carsel, G., y Parrish, R. (1988). Developing joint probability distributions of soil water retention characteristics. *Water Resources*, 24, 755–769.
- Cassel, D. K., y Nielsen, D. R. (1986). Field capacity and available water capacity. En Klute, A., Campbell, G. S., Jackson, R. D., Mortland, M. M., y Nielsen, D. R. (Eds.). *Methods of soil analysis, Part 1. Physical and mineralogical methods. 2nd ed. SSSA Book Ser. 1.* (pp. 901–926). Madison, WI, USA: ASA and SSSA, Madison. Doi:10.2136/sssabookser5.1.2ed.c36
- Cavelier, J. (1991). El ciclo del agua en los bosques montanos. Cap 4. En Uribe, C. (Ed.), *Bosques de Niebla de Colombia* (pp. 69-83). Bogotá, Colombia: Banco de Occidente.
- Christensen, N. (2005). Irrigation management using soil moisture monitors. *Western nutrient management conference*, 46-53.
- Corporación Autónoma Regional del Tolima CORTOLIMA. (2006). *Plan de ordenamiento y manejo de la cuenca mayor del río Coello*. Ibagué, Colombia: CORTOLIMA.

- Cosby, B. J., Hornberger, G. M., Clapp, R. B., y Ginn, T. R. (1984) A statistical exploration of soil moisture characteristics to the physical properties of soils. *Water Resources Research*, 20, 682–690.
- Cousin, I., Nicoullaud, B., y Coutadeur, C. (2003). Influence of rock fragments on the water retention and water percolation in a calcareous soil. *Catena*, 53, 97–114.
- Cybenko, G. (1989). Approximation by superpositions of a sigmoidal function. *Mathematics of control, signals, and systems*, 2, 303–314.
- De Jong, R. (1983). Soil water desorption curves estimated from limited data. *Journal of Soil Science*, 63, 697-703.
- De Medeiros-Silveira, F., Santi, G., Reinert, D., Reichter, J., Calesso, R., Gubiani, P., y Collares, G. (2004). *Estimación de la retención de agua a través de pedofunciones para lagunos suelos brasileiros*. XV reunión brasilera de manejo y conservación de suelos y aguas.
- Díaz-Granados, M. A., Navarrete, J. D., y Suárez, T. (2005). Páramos: hidrosistemas sensibles. *Revista de Ingeniería 22. Facultad de Ingeniería Universidad de los Andes*, 64-75.
- Diebold, C. H. (1954). Permeability and intake rates of medium textured soils in relation to silt content and degree of compaction. *Soil Science Society of America Journal*, 18, 339–343. doi:10.2136/sssaj1954.0361599500180003002
- Dijkerman, J.C. (1988). An Ustult-Aquult-Tropept catena in Sierra Leone, West Africa,II. Land qualities and land evaluation. *Geoderma*, 42(1), 29–49.
- Dong, G., y Taslimitehrani, V. (2015). Pattern-aided regression modeling and prediction model analysis. *IEEE Transactions on Knowledge and Data Engineering*, 27, 9, 2452-2465. doi: 10.1109/TKDE.2015.2411609.
- Dorronsoso, C. (2005). *Introducción a la edafología*. Granada, España: Universidad de Granada.
- Dunham, M. H. (2003). *Data mining. Introductory and advanced topics*. Upper Saddle River (N J): Prentice Hall.

- Ebrahim-Zadeh, G., Bayat, H., Safari, S., y Abyaneh, A. H. (2017). Vereecken, H. Investigating the correlation between soil tensile strength curve and soil water retention curve via modeling. *Soil and Tillage Research*, 167, 9–29.
- Escobar, G., Jurado, R., y Guerrero, R. (1972). Propiedades físicas de algunos suelos derivados de ceniza volcánica del altiplano de Pasto, Nariño, Colombia. *Turrialba*, 22, 338-346.
- Fayyad, U. M., e Irani, K. B. (1993) *Multi-interval discretization of continuous-valued attributes for classification learning* (pp. 1022-1027). Proceedings of the 13th International Joint Conference on Artificial Intelligence (IJCAI-93), Chambéry, 28 August-3 September 1993.
- Flores, L. y Alcalá, J. (2010). Manual de Procedimientos Analíticos. *Laboratorio de Física de Suelos*. México. Universidad Nacional Autónoma de México.
- Forsythe, W. (1975). Física de Suelos. Manual de Laboratorio. *Instituto Interamericano de Ciencias Agrícolas IICA*. San José de Costa Rica. 212 p.
- Fredlund, W., Fredlund, D., y Wilson, G. (2007). *Estimation of unsaturated soil properties using a knowledge based system*. Conference proceeding paper. Computing in civil engineering Philadelphia.
- Fredlund, W., y Xing, A. (1994). Equation for the soil water characteristic curve. *Canadian Geotechnical Journal*, 31, 521–532.
- Galelli, S., y Castelleti, A. (2013). Tree based iterative input variable selection hydrological modeling. *Water Resources Research*, 49-6.
- García, J., y Medina, H. (2009). Una revisión sobre las funciones de pedotransferencia en la determinación de las propiedades hidráulicas del suelo. *Revista Ciencias Técnicas Agropecuarias*, 18-3.
- García-Laencina, P., Figueiras-Vidal, A., Serrano-García, J., y Sancho-Gómez, J. (2005). Exploiting multitask learning schemes using private subnetworks. Proceedings of the 8th International Work-Conference on Artificial Neural Networks, (pp. 233-240), Barcelona, Spain.
- Gardner, M., y Dorling, S. (1998). Artificial neural networks (the multilayer perceptron)—a review of applications in the atmospheric sciences. *Atmospheric Environment*, 32, 2627–2636.

- Gelman, F., Binstock, R., y Halicz, L. (2011). Application of the Walkley-Black titration for organic carbon quantification in organic rich sedimentary rocks. Israel: The Ministry National Infrastructures, Geological Survey of Israel.
- Geurts, P., Ernst, D., y Wehenkel, L. (2006). *Extremely Randomized Trees*. Mach Learn. Springer Science and Business Media, Inc. DOI 10.1007/s10994-006-6226-1
- Ghanbarian, B., Taslimitehrani, V., Dong, G., y Pachepsky, Y. (2015). Scale-dependent pedotransfer functions reliability for estimating saturated hydraulic conductivity. *Journal of Hydrology*, 528, 127–137. <https://doi.org/10.1016/j.catena.2016.10.015>.
- Ghanbarian, B., Taslimitehrani, V., y Pachepsky, Y. A. (2017). Accuracy of sample dimension-dependent pedotransfer functions in estimation of soil saturated hydraulic conductivity. *Catena*, 149.
- Givi, J., Prasher, S., y Patel, R. (2004). Evaluation of pedotransfer functions in predicting the soil water contents at field capacity and wilting point. *Agricultural water Management*, 70.
- Gupta, S.C., Larson, W.E., (1979). Estimating soil water retention characteristics from particle size distribution, organic matter percent, and bulk density. *Water Resources Research*, 15 (6), 1633–1635.
- Hernández, J. J. (2011). *Evaluación del efecto de la aplicación de diferentes láminas de riego en el cultivo de rosa (Rosa sp) cv. Freedom, bajo invernadero en la sabana de Bogotá* [Tesis de maestría]. Facultad de Ingeniería Agrícola y Civil, Universidad Nacional de Colombia.
- Heuscher, S., Brandt, C., y Jardine, P. (2005). Using soil physical and chemical properties to estimate bulk density. *Soil Science Society of America Journal*, 69, 51–56.
- Heuvelink, G. B. M., y Pebesma, E. J. (1999). Spatial aggregation and soil process modeling. *Geoderma*, 89, 47–65.
- Higgins, J. (2006). *The radical statistician: a beginner's guide to unleashing the power of applied statistics in the real world*. 5th edition. U.S.A.: Jim Higgins publishing.
- Hodge, V. y Austin, J. A. (2004). Survey of outlier detection methodologies. *Artificial Intelligence*, 22(2), 85-126.
- Hudson, B. D. (1994). Soil organic matter and available water capacity. *Journal of Soil Water Conservation*, 49, 189–194.

- Hutson, J. L. (1986). Water retentivity of some South African soils in relation to particle size criteria and bulk density. *South African Journal of Plant and Soil*, 3, 151-155.
- Hutson, J. L., y Cass, A. A. (1987). Retentivity function for use in soil water simulation model. *Journal of Soil Science*, 38, 105–113.
- Hutson, J. L. y Wagenet, R. J. (1991). Simulating nitrogen dynamics in soils using a deterministic model. *Soil Use and Management*, 7, 74-78.
- Hutson, J. L. y Wagenet, R. J. (1992). *LEACHM: Leaching Estimation And Chemistry Model: A process based model of water and solute movement transformations, plant uptake and chemical reactions in the unsaturated zone*. Continuum Vol. 2, Version 3. Ithaca, New York, US.A.: Water Resources Inst., Cornell University.
- Hutson, J. (2003). *LEACHM Leaching estimation and chemistry model. Model description and user guide*. Australia: The Flinders University.
- Ibañez, S., Gisbert, J., y Moreno, H. (2011^a). *Andisoles. Escuela Técnica Superior de ingeniería Agronómica y del Medio Natural*. Universidad Politécnica de Valencia.
- Ibañez, S., Gisbert, J., y Moreno, H. (2011^b). *Entisoles. Escuela Técnica Superior de ingeniería Agronómica y del Medio Natural*. Universidad Politécnica de Valencia.
- Ibañez, S., Gisbert, J., y Moreno, H. (2011^c). *Inceptisoles. Escuela Técnica Superior de ingeniería Agronómica y del Medio Natural*. Universidad Politécnica de Valencia.
- Instituto Geográfico Agustín Codazzi. IGAC. (2003). *Estudio general de suelos, evaluación y zonificación de las tierras del departamento del Amazonas*. Bogotá, Colombia: IGAC.
- Instituto Geográfico Agustín Codazzi. IGAC. (2013). *Estudio semidetallado de suelos del Quindío*. Bogotá, Colombia: IGAC.
- Jaramillo, J. D. F. (2000). Clasificación taxonómica de los suelos del altiplano de San Félix, departamento de Caldas. *Revista Facultad Nacional de Agronomía*, 53, 2, 1059-1076.
- Jaynes, D. B., y Tyler, E. J. (1984). Using soil physical properties to estimate hydraulic conductivity. *Soil Science*, 138, 298–305.
- Kern, I. S. (1995). Evaluation of soil water retention models based on basic soil physical properties. *Soil Science Society of America Journal*, 59, 1134-1141.

- Kobayashi, K. y Salam, M. (2000). Comparing Simulated and Measured Values Using Mean Squared Deviation and Its Components. *Agronomy Journal*, 92, 345-352.
- Koekkoek, E., y Bootlink, H. (1999). Neural network models to predict soil water retention. *European Journal Soil Science*, 50, 489–495.
- Kooijman, A., Gongejans, J., y Sevink, J. (2005). Parent material effects of Mediterranean woodland ecosystem in NE Spain. *Catena*, 59, 12.
- Kutílek, M., y Nielsen, D., (1994). Soil hydrology. Catena Verlag, *Cremlingen-Dested*, 179-205.
- Lambers, H. F., Chapin III, y Pons, T. (1997). *Plant Physiological Ecology*. Berlin, Germany: Springer Verlag.
- León, R. (2001). Comparación de métodos de análisis mecánicos de suelos. *Terra*, 19, 219–225.
- Lloret, P. (2000). *Problemática de los Recursos Hídricos en el Ecuador*. Foro de los Recursos Hídricos. Quito, Ecuador: CAMAREN.
- Loyola, J., y Prevedello, C. (2002). Modelos Analíticos Para Predição do Processo Da Redistribuição da Água No Solo. *Revista Brasileira de Ciência do Solo*, 27(5), 783–787.
- Maier, H., y Dandy, G. (2000). Neural networks for the prediction and forecasting of water resources variables: a review of modelling issues and application. *Environmental Modelling & Software*, 15, 101–124.
- Malagón D. (2003). Ensayo sobre tipología de suelos colombianos – énfasis en génesis y aspectos ambientales. *Revista Académica Colombiana de la Ciencia*, 27, 104, 319- 341.
- Manrique, L. A., y Jones, C. A. (1991). Bulk density of soils in relation to soil physical and chemical properties. *Soil Science Society of America Journal*, 55, 476–481.
- Mao, W., y Wang, F. (2012). *Advances in intelligence and security informatics*. Oxford, UK: Elsevier.
- Mariño, Y. A. (2006). Evaluación del punto de marchitez permanente bajo condiciones de invernadero como variable para la asignación de clones de Gmelina arborea a sitios potenciales de plantación [Trabajo de grado Biólogo]. Pontificia Universidad javeriana.

- Martínez, E. (2008). *Estudios de propiedades hídricas del suelo mediante medidores de actividad de agua en la zona regable de Terra Chá* [Tesis doctoral]. Universidad Santiago de Compostela.
- Martínez, J., Ceballos, A., Casado, S., y Moran, C. (2004). *Estimación de propiedades hidrológicas de suelo y formaciones superficiales de dehesa mediante funciones de edafotransferencia. Contribuciones recientes sobre geomorfología*. Actas de la VII reunión nacional de Geomorfología. Toledo, España.
- Matich, D. J. (2001). *Redes Neuronales: Conceptos Básicos y Aplicaciones. Libro de clase. Informática aplicada a la ingeniería de procesos*. Universidad Tecnológica Nacional facultad Regional Rosario Argentina.
- McBratney, A., Mendonça, S., y Minasny, B. (2003). On digital soil mapping. *Geoderma*, 117, 3–52.
- Medina, H. T., Mohamed, T., del Valle, A. A., y Ruiz, M. E. (2002). Estimating soil water retention curve in Rhodic Ferralsols from basic soil data, *Geoderma*, 108, 277-285.
- Medina-Merino, R., y Ñique-Chacón, C. (2017). Bosques aleatorios como extensión de los árboles de clasificación con los programas R y Python. *Interfases*, 10, 165-189. doi:<http://dx.doi.org/10.26439/interfases2017.n10.1775>
- Medrado, E., y Lima, J. E. F. W. (2014). Development of pedotransfer functions for estimating water retention curve for tropical soils of the Brazilian savanna. *Geoderma Regional*, 1, 59-66.
- Milly, P. (1994). climate, interseasonal storage of soil water, and the annual water balance. *Advance Water Resources*, 17, 19-24.
- Minasny, B., y Hartemink, A. E. (2011). Predicting soil properties in the tropics. *Earth-Science Reviews*, 106 (1–2), 52–62.
- Minasny, B., y McBratney, A. B. (2002). *Neuropack: Neural Network package for fitting pedotransfer functions*. Sydney, Australia: Australian Centre for Precision Agriculture.
- Minasny, B., McBratney, A., y Bristow, K. (1999). Comparison of different approaches to the development of pedotransfer functions for water retention curves. *Geoderma*, 93, 225-253

- Minasny, B., McBratney, A. B., McKenzie, N., y Grundy, M. (2008). Predicting soil properties using pedotransfer functions and environmental correlation. *Guidelines for surveying soil and land resources*, 349–367.
- Minasny, B., McBratney, A. B., Mendosa-Santos, M., y Gonsarves dos Santos, H. (2003). *Revisión sobre funciones de pedotransferencia y nuevos métodos de predicción de clases y atributos del suelo*. Río de Janeiro: Empresa Brasileira de Investigación Agropecuaria, Centro Nacional de Investigación del suelo.
- Morales, L. (2008). *Evaluación de las propiedades físicas e hidráulicas del suelo bajo influencia de tres coberturas vegetales en Porcé II, Antioquia, Colombia* [Tesis]. Universidad Nacional de Colombia, Sede Medellín.
- Mualem, Y. (1976). A new model for predicting the hydraulic conductivity of unsaturated porous media. *Water Resources Research*, 12, 513-522.
- Nelson, D. W., y Sommer, L. E. (1982). Total carbon, organic carbon and organic matter. Methods of soil analysis, Part 2. *Chemical and microbiological properties* (pp. 595-579). Madison: ASA-SSSA. ,
- Nemes, A. (2003). *Multi scale pedotransfer functions for Hungarian soils* [Doctoral Thesis]. The Netherlands: Wageningen University.
- Nemes, A., Rawls. W. J., y Pachepsky, Y. A. (2006). Use of the nonparametric nearest neighbor approach to estimate soil hydraulic properties. *Soil Science Society of America Journal*, 70, 327–336.
- Nemes, A., Schaap, M. G., y Wösten, J. H. M. (2002). Validation of international scale soil hydraulic pedotransfer functions for national scale applications. En *Soil Science. Confronting New Realities in the 21st Century*. 17th World Congress of Soil Science. August 14–21. Bangkok, Thailand.
- Nemes, A., Schaap, M. G., y Wösten, J. H. M. (2003). Functional evaluation of pedotransfer functions derived from different scales of data collection. *Soil Science Society of America Journal*, 67, 1093–1102.
- Nguyen, P. M., Haghverdi, A., de Pue, J., Botula, Y. D., Le, K. V., Waegeman, W., y Cornelis, W. M. (2017). Comparison of statistical regression and data-mining

- techniques in estimating soil water retention of tropical delta soils. *Agricultural Water Management*, 158, 126–138.
- Olaya-M. E. J., Martínez-C. F., Soares C. R. M., y Alcaraz-H. J. D. (2012). Modelling native fish richness to evaluate the effects of hydromorphological changes and river restoration (Júcar River Basin, Spain). *Science of the Total Environment*, 440, 95–105.
- Olden, J. Jackson, D. (2002). Illuminating the "black box": A randomization approach for understanding variable contributions in artificial neural networks. *Ecological Modelling* 154(1), 135-150. DOI: 10.1016/S0304-3800(02)00064-9
- Ortiz, A., y Socha, D. (2005). *Aplicación de las redes neuronales MLP a la predicción de un paso en series de tiempo* [Proyecto de grado]. Fundación universitaria Konrad Lorenz, Facultad de ingeniería de sistemas.
- Osorio, A., y Bahamon, C. (2008). *Dinámica de la humedad del suelo en bosques alto andinos en el páramo de guerrero, Cundinamarca-Colombia* [Tesis]. Universidad Nacional de Colombia sede Medellín
- Pacheco, E., y Ataroff, M. (2002). Relación precipitación-percolación en una selva nublada andina venezolana. *Selvas y bosques nublados andinos*, 4-62.
- Pachepsky, Y., y Rawls, W. J. (2004). Development of pedotransfer functions in soil hydrology. *Developments in Soil Science*, 30. Editors book. Elsevier Science.
- Pachepsky, Y., Shcherbakov, R. A., Varallyay, G., y Raijkai, K. (1982). Statistical analysis of water retention relations with other physical properties of soils. *Pochvovedenie*, 2, 42-52.
- Pachepsky, Y. A., Timlin, D., y Várallyay, G. (1996). Artificial neural networks to estimate soil water retention from easily measurable data. *Soil Science Society of America Journal*, 60, 727-733.
- Parasuraman, K., Elshorbagy, A., y Cheng, S. B. (2006). Estimating saturated hydraulic conductivity in spatially variable fields using Neural Network ensembles. *Soil Science Society of America Journal*, 70, 1851–1859.
- Patil, N. G., y Chaturvedi, A. (2012). Pedotransfer functions based on nearest neighbour and neural networks approach to estimate available water capacity of shrink-swell soils. *Indian Journal of Agricultural Sciences*, 82, 35–38.

- Patil, N. G., y Singh, S. K. (2016). Pedotransfer functions for estimating soil hydraulic properties: A review. *Pedosphere*, 26(4), 417–430.
- Pineda, C., y Vilorio, J. (1992). Funciones de edafotransferencia para determinar la retención de humedad en suelos de la cuenca del lago de Valencia. *Venezuelos*, 5, 39-44.
- Quinlan, J. R. (1986). Induction of decision trees. *Machine Learning*, 1(1), 81–106, March 1986.
- Quinlan, J. R. (1993). C 4.5: *Programs for machine learning*. San Francisco, CA, USA: Morgan Kaufmann Publishers Inc.
- Quinlan, J. R. (1996). Learning decision tree classifiers. *ACM Computing Surveys*, 28(1), 71-72.
- Ratliff, L. F., Ritchie, J., y Cassel, D. (1983). Field Measured limits of soil water availability as related to laboratory measured properties. *Soil Science Society American Journal*, 47, 770–775.
- Rawls, W. J. (1983). Estimating soil bulk density from particle size analysis and organic matter content. *Soil Science*, 135(2), 123–125.
- Rawls, W., Ahuja, L., y Brakensiek, D. (1992). *Estimating soil hydraulic properties from soils data. Indirect methods for estimating the hydraulic properties of unsaturated soils*. Riverside, U.S.A.: University of California.
- Rawls, W. J., y Brakensiek, D. L. (1989). Estimation of soil water retention and hydraulic properties. En H. J. Morel-Seytoux., (Ed.), *Unsaturated Flow in Hydrological Modeling: Theory and Practice* (pp. 275-300). Dordrecht: Kluwer Academic Publishers.
- Rawls, W., Brakensiek, D., y Saxton, K. (1982). Estimating soil water properties. *Transactions ASAE*, 25, 1316–1320.
- Reis Dos Santos, W. J., Curi, N. S., Sérgio H. G., Araújo, E., Frank, D., y Marques, J. J. (2013). Pedotransfer functions for water retention in different soil classes from the center-southern Rio Grande do Sul State. *Ciência e Agrotecnologia*, 37(1), 49-60.
- Riley, H. C. F. (1979). Relationship between soil moisture holding properties and soil texture, organic matter content, and bulk density. *Agricultural Research. Exp*, 30, 379-398.

- Rodrigo, J. A. (2017). *Árboles de predicción: bagging, random forest, boosting y C 5.0*. Estadística con R. https://rpubs.com/Joaquin_AR/255596
- Romano, N. (2004). Spatial structure of PTF estimates. En Y. Pachepsky & W. J. Rawls (Eds.), *Development of pedotransfer functions in soil hydrology*, 30 (pp. 295–315). Beltsville, MD, U.S.A.: Elsevier Science.
- Romano, N., y Palladino, M. (2002). Prediction of soil water retention using soil physical data and terrain attributes, *Journal of Hydrology*, 265, 56-75.
- Rubio, C. (2005). *Hidrodinámica de los suelos de un área de montaña media mediterránea sometida a cambios de uso y cubierta* [Tesis doctoral]. Universidad Autónoma de Barcelona.
- Rubio, C., y Llorens, P. (2003). *Evaluación del uso de funciones de edafotransferencia para la determinación de propiedades hidrodinámicas en suelos franco limosos (Cuencas experimentales d Vallcebre, Alt Llobregat)*. Pamplona, España: Universidad Pública de Navarra.
- Rucks, L., García, F., Kaplán, A., Ponce de León, J., y Hill, M. (2004). *Propiedades físicas de los suelos*. Universidad de la Republica. Facultad de Agronomía. Departamento de aguas y suelos. Montevideo Uruguay.
- Salamanca, A., y Sadeghian, S. (2005). La densidad aparente y su relación con otras propiedades en suelos de la zona cafetera Colombiana. *Cenicafé*, 56, 381-397.
- Salchow, E., Lal, R., Fausey, N. R., y Ward, A. (1996). Pedotransfer functions for variable alluvial soils in southern Ohio. *Geoderma* 73 (3–4), 165–181.
- Sánchez, P., y Camacho, E. (1981). *Suelos del trópico. Características y manejo*. Costa Rica: Instituto Interamericano para de Cooperación para la Agricultura.
- Santander, M. A. J., y Ruiz, V. R. (2004). *Relación entre variables cuantitativas* (pp. 1-30). Cuba: Informática Médica II, Editorial ECIMED.
- Sarmadian, F., y Keshavarzi, (2010). A. Developing pedotransfer functions for estimating some soil properties using artificial neural network and multivariate regression approaches. World Academy of Science, *Engineering Technology*, 48, 501–508.
- Saxton, K. E., Rawls, W. J., Romberger, J. S., y Papendick, R. I. (1986). Estimating generalized soil-water characteristics from texture. *Soil Science Society of America*, 50, 1031-1036. <https://doi.org/10.2136/sssaj1986.03615995005000040039x>

- Schaap, M. G., y Leij, F. J. (1998). Database related accuracy and uncertainty of pedotransfer functions. *Soil Science*, 163, 765-769.
- Schaap, M. G., Leij, F. J., y Van G. R. M. T. (2001). A computer program for estimating soil hydraulic parameters with hierarchical pedotransfer functions. *Journal of Hydrology*, 251, 163–176.
- Scheinost, A. C., Sinowski, W., y Auerswald, K. (1997). Regionalization of soil water retention curves in a highly variable soilscape. I. Developing a new pedotransfer function. *Geoderma*, 78, 129-143.
- Servicio Nacional de Aprendizaje SENA. (2013). *Manual de prácticas de campo y del laboratorio de suelos*. Espinal: SENA regional Tolima.
- Singer, M., y Munns, D. (1999). *Soil. An introduction*. U.S.A.: Prentice Hall.
- Soto, B., Arias, M., y Diaz-Fierros, F. (2001). Desarrollo de una función de edafotransferencia para suelos de Galicia (NW Spain) *Agrichimica XLV*, 210.
- Taiz, L., y Zeiger, E. (2002). *Plant physiology*. Redwood City, CA, U.S.A.: Benjamin Cummings Pulb. Co.
- Tamari, S., Wosten, J., y Ruiz-Suarez, J. C. (1996). Testing an artificial neural network for predicting soil hydraulic conductivity. *Soil Science Society of America Journal*, 60, 1732-1741.
- Taslimitehrani, V., y Dong, G. (2014) *A new CPXR based logistic regression method and clinical prognostic modeling results using the method on traumatic brain injury* (pp. 283-290). IEEE International Conference on Bioinformatics and Bioengineering, Boca Raton, FL. doi: 10.1109/BIBE.2014.16.
- Timlin, D. J., Pachepsky, Y., y Walthall, C. A. (2004). Mix of scales: topographic information, point samples and yield maps. Scaling methods in soil physics. bridging scales in soil physics (pp. 227-241). Boca Raton, FL: CRC Press.
- Tobón, C., Bruijnzeel, L. A., y Frumau, A. (2004). *Physical and hydraulic properties of tropical montane cloud forest soils and their changes after conversion to pasture*. Proceedings of the Second International Symposium: Science for conserving and managing tropical montane cloud forests, Waimea, Hawaii, July 27–August 1.
- Tobón, C. (2009). *Los bosques andinos y el agua*. Serie investigación y sistematización #4. Quito: Programa Regional ECOBONA – INTERCOOPERATION, CONDESAN.

- Tomasella, J., Hodnett, M., 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., Crestana, S., y Rawls, W. J. (2003). Comparison of two techniques to develop pedotransfer functions for water retention. *Soil Science Society of America Journal*, 67(4), 1085-1092.
- Thomasson, A. J., y Carter, A. D. (1989). *Data to feed calibrate land evaluation models. Application of computerized EC soil map climate data*. En H. A. J. van Lanen, y Bregt, A. K. (Eds) (pp. 35-43). Wageningen, The Netherlands: Soil Survey Institute.
- United States Department of Agriculture, USDA. (1999). *Servicio de conservación de recursos naturales. Guía para la evaluación de la calidad y salud del suelo*. Washington, United States of America: United States Department of Agriculture.
- United States Department Agriculture, USDA. (2014). *Servicio de conservación de recursos naturales. Claves para la taxonomía de suelos*. Decima segunda edición. U.S.A.: USDA.
- Uribe, I. A. (2010). *Guía Metodológica para la selección de técnicas de depuración de datos* [Tesis de Maestría]. Ingeniería de Sistemas. Universidad Nacional de Colombia Sede Medellín.
- U.S. Department of Agriculture, Natural Resources Conservation Service. (2014). *Kellogg Soil Survey Laboratory Methods Manual. Soil Survey Investigations Report No. 42, Version 5.0*. R. Burt and Soil Survey Staff (ed.). U.S. Department of Agriculture, Natural Resources Conservation Service.
- U.S. Environmental Protection Agency. (2002). *Soil Survey Laboratory Methods Manual. Methods for the Determination of Total Organic Carbon (TOC) in Soil and Sediments*. Las Vegas: U.S.Environmental Protection Agency. Exposure Research Laboratory.
- Valencia, G. (1999). *Fisiología, nutrición y fertilización del cafeto*. Chinchiná: Cenicafé Agroinsumos del café.
- Vanderlinden, K., Giráldez, J., y Van, M. M. (2003). *Evaluación de la capacidad de retención de agua de los suelos de Andalucía mediante el análisis del balance medio anual del agua. Estudio de la zona no saturada del suelo*. Vol VI, 131–136.

- Van Genuchten, M. T. (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. T., y Leij, F. J. (1989). Indirect methods for estimating the hydraulic properties of unsaturated soils (pp. 11–13). International Workshop. Riverside California.
- Van Genuchten, M. T., F. Leij, y S. Yates. (1991). *The RETC Code for Quantifying the Hydraulic Functions of Unsaturated Soils*. Oklahoma, U.S.A.: Robert S. Kerr Environmental Research Laboratory Office of Research and Development U. S. Environmental Protection Agency Ada.
- Van Looy, K., Bouma, J., Herbst, M., Koestel, J., Minasny, B., Mishra, U., y Vereecken, H. (2017). Pedotransfer functions in earth system science: Challenges and perspectives. *Reviews of Geophysics*, 55, 1199–1256.
- Vásquez, J. P. (2014). Red Neuronal feedforward como estimador de patrones de corrientes en el interior del puerto de Manzanillo sujeto a la acción de tsunamis. Instituto Mexicano del Transporte. *Publicación Técnica 406*, 63.
- Vereecken, H., y Herbst, M. (2004). Statistical Regression. *Developments in soil science*, 30, 3–23.
- Vereecken, H., Javaux, M., Weynants, M., Pachepsky, Y., Schaap, M. G., y Genuchten, Van. (2010). Using pedotransfer functions to estimate the van genuchten- mualem soil hydraulic properties: A review. *Vadose Zone Journal*, 9(4), 795-820.
- Villar J., y Ferrer, F. (2005). Técnicas de medida y control del agua en el suelo. Agua y Agronomía (pp. 23-86). Ed. Mndiprensa.
- Vos B., Van-Meirvenne, M., Quataert, P., y Muys, B. (2005). Predictive quality of pedotransfer functions for estimating bulk density of forest soils. *Soil Science Society of America Journal*, 69, 500–510.
- Walczack, R., Moreno, F., Stawinski, C., Fernández, E., y Aure, J. (2006). Modelling of soil water retention curve using soil solid phase parameters. *Journal of Hydrology*, 329.
- Walkley, A. (1947). A critical examination of a rapid method for determining organic carbon m soils: Effect of variations in digestion conditions and of inorganic soil constituents. *Soil Science*, 63, 251-263.

- Walkley, A., y Black, I. A. (1934). An examination of the Degtjareff method for determining organic carbon in soils: Effect of variations in digestion conditions and of inorganic soil constituents. *Soil Science*, 63, 251-263.
- Warner, B., y Misra, M. (1996). Understanding neural networks as statistical tools. *The American Statistician*, 50(4), 284–293.
- Wang, K., Zhang, R., y Wang, F. (2005). Testing the pore solid fractal model of the soil water retention function. *Soil Science Society of America Journal*, 69, 776-782.
- Wang, G., Zhang, Y., y Yu, N. (2012). Prediction of soil water retention and available water of sandy soils using pedotransfer functions. *Procedia Engineering*, 37, 49–53.
- Wassar, F., Gandolfi, C., Rienzner, M., Chiaradia, E., y Bernardoni, E. (2016). Predicted and measured soil retention curve parameters in Lombardy region north of Italy. *International Soil and Water Conservation Research*, 4, 207–214.
- Williams, R., Ahuja, L., y Naney, J. (1992). Comparison of methods to estimate soil water characteristics from limited texture, bulk density and limited data. *Soil Science*, 153, 172–184.
- William, J. R., Wang, E., Meinardus, A., Harman, W. L., Siemers, M., y Atwood, J. E. (2006). *Users Guide v. 0509*. TAES Temple TX.
- Wolf, B. y Snyder, G. (2003). *Sustainable soils; the place of organic matter in sustainable soils and their productivity*. New York: Food Products Press.
- Wösten, J. H. M., Pachepsky, Y. A., y Rawls, W. J. (2001). Pedotransfer functions: bridging the gap between available basic soil data and missing hydraulic characteristics. *Journal of Hydrology*, 251, 123-150.
- Yashuang, M., Xiaodong, L., y Lidong, W. (2018). A Pearson's correlation coefficient based decision tree and its parallel implementation. *Information Sciences*, 435, 40-58.
- Zhang, Y., y Schaap, M. (2017). Weighted recalibration of the Rosetta pedotransfer model with improved estimates of hydraulic parameter distributions and summary statistics (Rosetta3). *Journal of Hydrology*, 517, 39-53.
- Zhuang, J., Jin, Y., y Miyazaki, T. (2001). Estimating water retention characteristic from soil particle-size distribution using a non-similar media concept. *Soil Science* 166(5), 308-321. DOI: 10.1097/00010694-200105000-00002

Zimmerman, E., y Basile, P. (2006). *Funciones hidráulicas de suelos limosos: Regresiones con propiedades físicas y granulométricas*. XXII Congreso Latinoamericano de Hidráulica, Ciudad Guayana, Venezuela.

Zimmermann, E., y Basile, P. (2011). Estimación de parámetros hidráulicos en suelos limosos mediante diferentes funciones de Pedotransferencia. *Tecnología y Ciencias del Agua*, 2(1), 99-116.

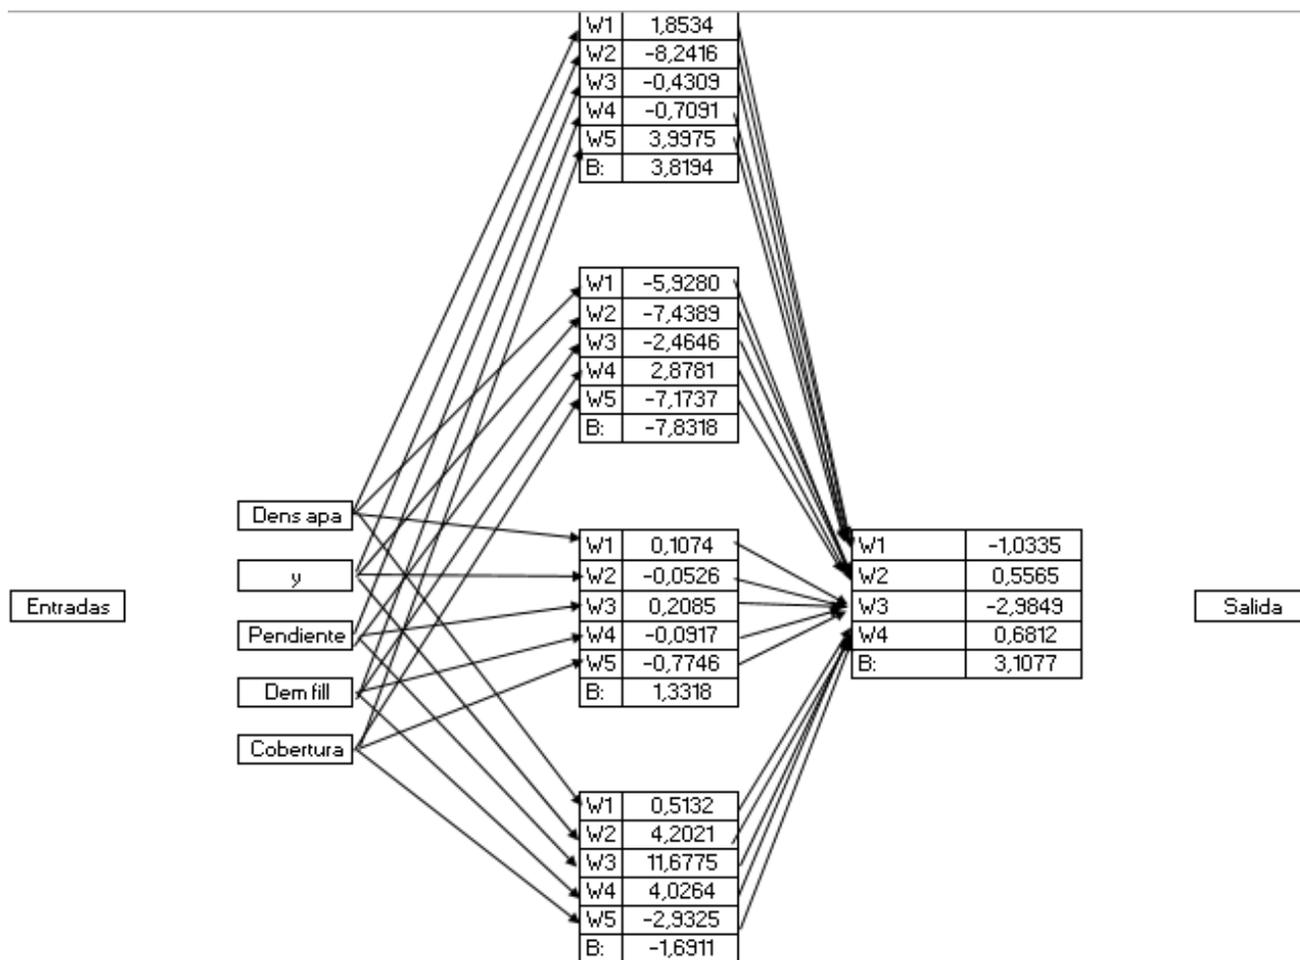
ANEXOS

Anexo A Correlaciones de Pearson y Spearman.

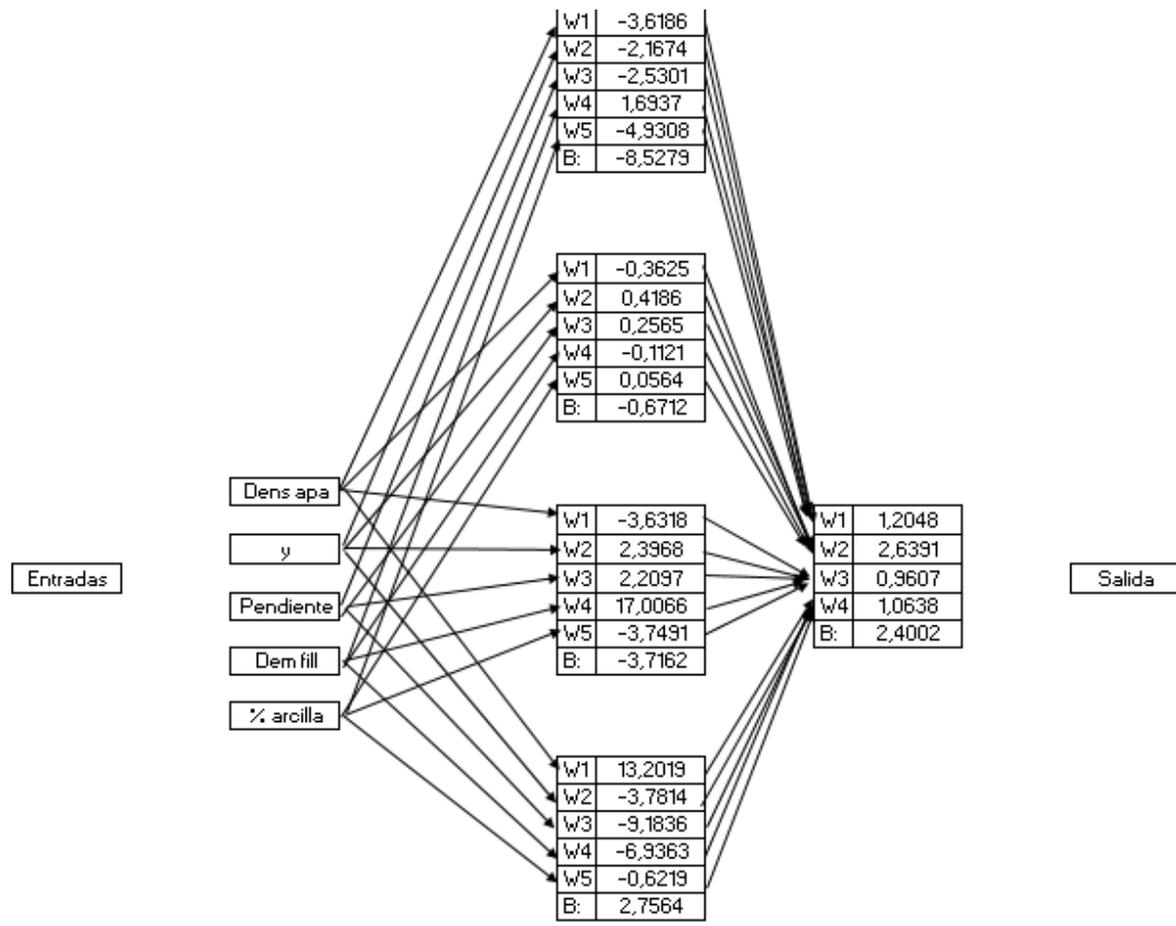
Correlación de Pearson																
	x	y	demfill	slope	curvatura	curv_profi	curv_plan	Accum	Espesor (cm)	Profundidad	%ARENAS	%ARCILLAS	% CO	cover	Cuenca	BD
x	1,00	0,45	0,85	0,61	0,00	0,06	0,07	-0,13	0,13	-0,05	0,35	-0,54	0,42	0,47	0,97	-0,36
y	0,45	1,00	0,07	-0,06	0,11	-0,09	0,11	-0,16	-0,20	-0,06	0,37	-0,42	0,23	0,16	0,27	-0,50
demfill	0,85	0,07	1,00	0,63	0,05	-0,03	0,07	-0,12	0,21	-0,02	0,30	-0,47	0,42	0,48	0,89	-0,29
slope	0,61	-0,06	0,63	1,00	-0,15	0,13	-0,14	-0,09	0,19	0,01	0,03	-0,27	0,23	0,31	0,69	-0,15
curvatura	0,00	0,11	0,05	-0,15	1,00	-0,92	0,87	-0,10	-0,02	0,03	0,05	-0,04	0,16	-0,04	-0,03	-0,05
curv_profi	0,06	-0,09	-0,03	0,13	-0,92	1,00	-0,61	0,08	0,03	-0,05	-0,08	-0,01	-0,12	0,09	0,09	0,02
curv_plan	0,07	0,11	0,07	-0,14	0,87	-0,61	1,00	-0,10	-0,01	0,00	0,01	-0,08	0,17	0,03	0,06	-0,08
Accum	-0,13	-0,16	-0,12	-0,09	-0,10	0,08	-0,10	1,00	0,17	0,02	-0,18	0,11	-0,12	0,08	-0,12	0,28
Espesor (cm)	0,13	-0,20	0,21	0,19	-0,02	0,03	-0,01	0,17	1,00	0,37	0,00	0,10	-0,18	0,18	0,18	0,20
Profundidad - centroid	-0,05	-0,06	-0,02	0,01	0,03	-0,05	0,00	0,02	0,37	1,00	0,06	0,01	-0,46	-0,02	-0,03	0,13
%ARENAS	0,35	0,37	0,30	0,03	0,05	-0,08	0,01	-0,18	0,00	0,06	1,00	-0,50	0,24	0,25	0,27	-0,43
%ARCILLAS	-0,54	-0,42	-0,47	-0,27	-0,04	-0,01	-0,08	0,11	0,10	0,01	-0,50	1,00	-0,27	-0,24	-0,48	0,58
% CO	0,42	0,23	0,42	0,23	0,16	-0,12	0,17	-0,12	-0,18	-0,46	0,24	-0,27	1,00	0,18	0,40	-0,43
cover	0,47	0,16	0,48	0,31	-0,04	0,09	0,03	0,08	0,18	-0,02	0,25	-0,24	0,18	1,00	0,44	-0,17
Cuenca	0,97	0,27	0,89	0,69	-0,03	0,09	0,06	-0,12	0,18	-0,03	0,27	-0,48	0,40	0,44	1,00	-0,28
BD	-0,36	-0,50	-0,29	-0,15	-0,05	0,02	-0,08	0,28	0,20	0,13	-0,43	0,58	-0,43	-0,17	-0,28	1,00

Correlación de Spearman																
	x	y	demfill	slope	curvatura	curv_profi	curv_plan	Accum	Espesor (cm)	Profundidad - cent	%ARENAS	%ARCILLAS	% CO	cover	Cuenca	BD
x	1,00	0,07	0,67	0,54	-0,04	0,07	0,06	0,12	0,09	-0,09	0,27	-0,64	0,42	0,20	0,86	-0,31
y	0,07	1,00	-0,31	-0,48	0,14	-0,17	0,08	-0,27	-0,31	-0,06	0,09	-0,03	0,04	-0,01	-0,23	-0,27
demfill	0,67	-0,31	1,00	0,65	0,00	0,04	0,03	0,08	0,22	-0,02	0,26	-0,56	0,39	0,34	0,86	-0,27
slope	0,54	-0,48	0,65	1,00	-0,15	0,20	-0,05	0,25	0,22	0,00	0,02	-0,38	0,26	0,15	0,72	-0,08
curvatura	-0,04	0,14	0,00	-0,15	1,00	-0,90	0,85	-0,58	-0,06	0,02	0,03	0,00	0,13	0,01	-0,11	0,04
curv_profi	0,07	-0,17	0,04	0,20	-0,90	1,00	-0,59	0,51	0,08	-0,04	-0,06	-0,03	-0,08	0,01	0,17	-0,06
curv_plan	0,06	0,08	0,03	-0,05	0,85	-0,59	1,00	-0,49	-0,04	-0,03	-0,02	-0,06	0,17	0,02	0,02	-0,02
Accum	0,12	-0,27	0,08	0,25	-0,58	0,51	-0,49	1,00	0,04	0,00	-0,15	0,00	-0,10	0,04	0,21	0,07
Espesor (cm)	0,09	-0,31	0,22	0,22	-0,06	0,08	-0,04	0,04	1,00	0,41	0,06	-0,06	-0,25	0,14	0,19	0,14
Profundidad - cent	-0,09	-0,06	-0,02	0,00	0,02	-0,04	-0,03	0,00	0,41	1,00	0,09	-0,05	-0,51	-0,01	-0,04	0,15
%ARENAS	0,27	0,09	0,26	0,02	0,03	-0,06	-0,02	-0,15	0,06	0,09	1,00	-0,39	0,15	0,19	0,23	-0,33
%ARCILLAS	-0,64	-0,03	-0,56	-0,38	0,00	-0,03	-0,06	0,00	-0,06	-0,05	-0,39	1,00	-0,24	-0,20	-0,59	0,40
% CO	0,42	0,04	0,39	0,26	0,13	-0,08	0,17	-0,10	-0,25	-0,51	0,15	-0,24	1,00	0,11	0,43	-0,40
cover	0,20	-0,01	0,34	0,15	0,01	0,01	0,02	0,04	0,14	-0,01	0,19	-0,20	0,11	1,00	0,25	-0,25
Cuenca	0,86	-0,23	0,86	0,72	-0,11	0,17	0,02	0,21	0,19	-0,04	0,23	-0,59	0,43	0,25	1,00	-0,24
BD	-0,31	-0,27	-0,27	-0,08	0,04	-0,06	-0,02	0,07	0,14	0,15	-0,33	0,40	-0,40	-0,25	-0,24	1,00

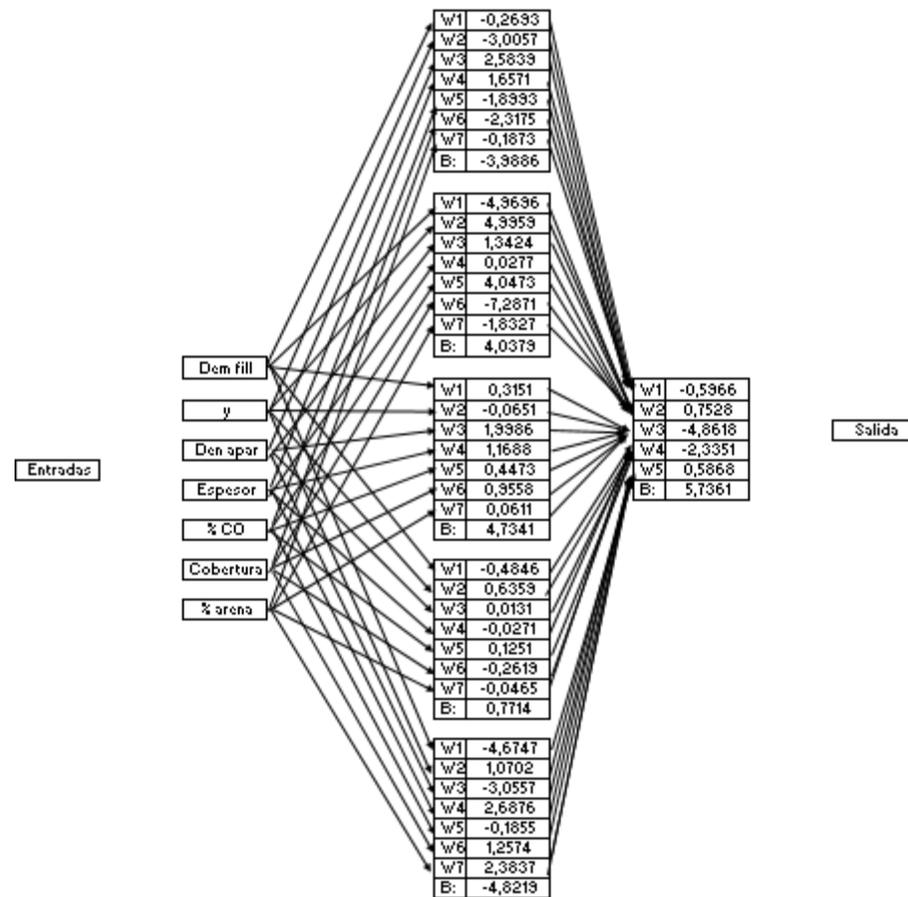
Anexo B: Representación gráfica de las redes neuronales.



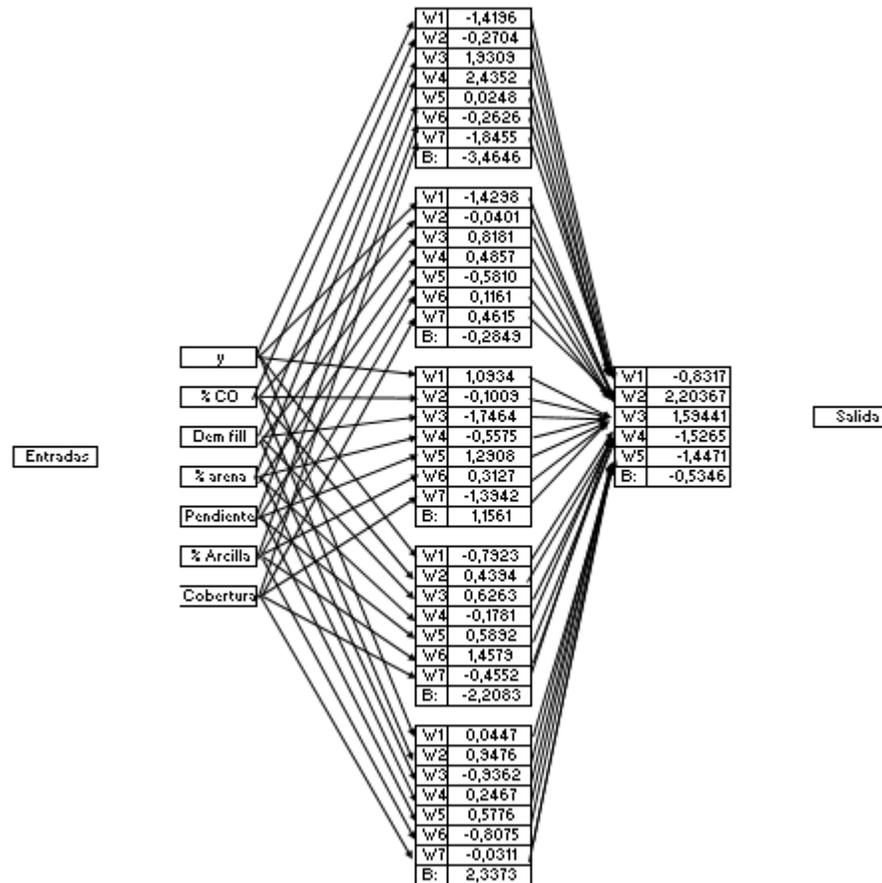
Representación de la red neuronal para capacidad de campo



Representación de la red neuronal para punto de marchitez permanente



Representación de la red neuronal para el agua retenida por el suelo



Representación de la red neuronal para la densidad aparente del suelo

Anexo C: Puntos de muestreo de las calicatas.

Calicata S1-A1				
Coordenadas:	X: 1192891,89	Cobertura: Bosque secundario		
	Y: 999900,341	Resultados de Laboratorio:		
Sistema de Coordenadas:	Magna-Sirgas Oeste			
		Muestreo	H1	H2
		Da (gr/cc)	0.46	0.81
		%ARENAS	77	71
		%ARCILLAS	7	6
		%LIMOS	16	23
		CLASE TEXTURAL	AF	AF
		Conductividad k10 (m/día)	8.34	4.05
		%H gravimétrico a 0Bar	158.17	103.49
		%H gravimétrico a 0,3 Bar	101.25	57.24
		%H gravimétrico a 1 Bar	97.32	54.05
		%H gravimétrico a 5 Bar	86.98	51.32
		%H gravimétrico a 10 Bar	76.91	48.59
%H gravimétrico a 15 Bar	72.98	45.41		



Calicata S1-2

Coordenadas	X: 1192478,08	Cobertura: Bosque secundario		
	Y: 1000243,4	Resultados de Laboratorio:		
Sistema de Coordenadas:	Magna-Sirgas Oeste	Muestreo	H1	H2
		Da (gr/cc)	0.55	0.87
		%ARENAS	78	76
		%ARCILLAS	7	5
		%LIMOS	15	19
		CLASE TEXTURAL	AF	AF
		Conductividad k10 (m/día)	27.5	9.65
		%H gravimétrico a 0Bar	123.57	83.21
		%H gravimétrico a 0,3 Bar	45.77	42.56
		%H gravimétrico a 1 Bar	36.87	38.14
		%H gravimétrico a 5 Bar	33.69	34.44
		%H gravimétrico a 10 Bar	32.06	31.53
		%H gravimétrico a 15 Bar	23.16	29.56



Calicata S1-3

Coordenadas:	X: 1192514,61	Cobertura: Bosque secundario		
	Y: 1000286,64	Resultados de Laboratorio:		
Sistema de Coordenadas:	Magna-Sirgas Oeste	Muestreo	H1	H2
		Da (gr/cc)	0.66	0.88
		%ARENAS	75	74
		%ARCILLAS	5	5
		%LIMOS	20	21
		CLASE TEXTURAL	AF	AF
		Conductividad k10 (m/día)	3.04	5.58



%H gravimétrico a 0Bar	142.11	89.9
%H gravimétrico a 0,3 Bar	69.91	51.3
%H gravimétrico a 1 Bar	63.89	47.52
%H gravimétrico a 5 Bar	53.13	42.82
%H gravimétrico a 10 Bar	49.97	41.83
%H gravimétrico a 15 Bar	47.72	38.06



Calicata S1-4

Coordenadas:	X: 1192402,34	Cobertura: Bosque secundario		
	Y: 1000345	Resultados de Laboratorio:		
Sistema de Coordenadas:	Magna-Sirgas Oeste	Muestreo	H1	H2
		Da (gr/cc)	0.8	0.66
		%ARENAS	77	76
		%ARCILLAS	5	4
		%LIMOS	18	20
		CLASE TEXTURAL	AF	AF



Conductividad k10 (m/día)	9.37	9.38
%H gravimétrico a 0Bar	141.77	92.32
%H gravimétrico a 0,3 Bar	73.96	56.03
%H gravimétrico a 1 Bar	68.88	52.77
%H gravimétrico a 5 Bar	66.28	47.19
%H gravimétrico a 10 Bar	61.12	47.06
%H gravimétrico a 15 Bar	56.04	43.80



Calicata S1-5

Coordenadas:	X: 1191338,58	Cobertura: Bosque															
	Y: 1000904,44																
Sistema de Coordenadas:	Magna-Sirgas Oeste	Resultados de Laboratorio:															
		<table border="1"> <thead> <tr> <th>Muestreo</th> <th>H1</th> <th>H2</th> </tr> </thead> <tbody> <tr> <td>Da (gr/cc)</td> <td>0.53</td> <td>0.76</td> </tr> <tr> <td>%ARENAS</td> <td>81.35</td> <td>82.35</td> </tr> <tr> <td>%ARCILLAS</td> <td>5</td> <td>6</td> </tr> <tr> <td>%LIMOS</td> <td>13.65</td> <td>11.65</td> </tr> </tbody> </table>	Muestreo	H1	H2	Da (gr/cc)	0.53	0.76	%ARENAS	81.35	82.35	%ARCILLAS	5	6	%LIMOS	13.65	11.65
Muestreo	H1	H2															
Da (gr/cc)	0.53	0.76															
%ARENAS	81.35	82.35															
%ARCILLAS	5	6															
%LIMOS	13.65	11.65															



CLASE TEXTURAL	AF	AF
Conductividad k10 (m/día)	4.25	7.99
%H gravimétrico a 0Bar	117.95	81.98
%H gravimétrico a 0,3 Bar	78.18	67.42
%H gravimétrico a 1 Bar	76.02	66.18
%H gravimétrico a 5 Bar	72.98	64.05
%H gravimétrico a 10 Bar	69.66	61.44
%H gravimétrico a 15 Bar	69.78	61.17



Calicata S1-6

Coordenadas:	X: 1191767,36	Cobertura: Bosque secundario												
	Y: 1000792,63	Resultados de Laboratorio:												
Sistema de Coordenadas:	Magna-Sirgas Oeste	<table border="1"> <thead> <tr> <th>Muestreo</th> <th>H1</th> <th>H2</th> </tr> </thead> <tbody> <tr> <td>Da (gr/cc)</td> <td>0.71</td> <td>1.21</td> </tr> <tr> <td>%ARENAS</td> <td>82.7</td> <td>81.35</td> </tr> <tr> <td>%ARCILLAS</td> <td>12</td> <td>6</td> </tr> </tbody> </table>	Muestreo	H1	H2	Da (gr/cc)	0.71	1.21	%ARENAS	82.7	81.35	%ARCILLAS	12	6
Muestreo	H1	H2												
Da (gr/cc)	0.71	1.21												
%ARENAS	82.7	81.35												
%ARCILLAS	12	6												



%LIMOS	5.3	12.65
CLASE TEXTURAL	AF	AF
Conductividad k10 (m/día)	8.99	8.28
%H gravimétrico a 0Bar	101.69	44.24
%H gravimétrico a 0,3 Bar	62.49	30.83
%H gravimétrico a 1 Bar	60.36	30.11
%H gravimétrico a 5 Bar	58.48	29.03
%H gravimétrico a 10 Bar	56.12	27.77
%H gravimétrico a 15 Bar	56.00	27.67



Calicata S1-7*

Coordenadas:	X: 1191632,73	Cobertura: Bosque secundario	
	Y: 999633,766	Resultados de Laboratorio:	
Sistema de Coordenadas:	Magna-Sirgas Oeste	Muestreo	H1 H2



Da (gr/cc)	1.21	0.45
%ARENAS	81.35	75.35
%ARCILLAS	6	11
%LIMOS	12.65	13.65
CLASE TEXTURAL	AF	AF
Conductividad k10 (m/día)	8.28	0.39
%H gravimétrico a 0Bar	44.24	75.39
%H gravimétrico a 0,3 Bar	30.83	53.48
%H gravimétrico a 1 Bar	30.11	51.89
%H gravimétrico a 5 Bar	29.03	50.40
%H gravimétrico a 10 Bar	27.77	48.86
%H gravimétrico a 15 Bar	27.67	48.78



Calicata S2-7

Coordenadas:	X: 1192368,57	Cobertura: Potrero con rastrojo
	Y: 999772,84	Resultados de Laboratorio:

Sistema de Magna-Sirgas Oeste
 Coordenadas:



Muestreo	H1	H2
Da (gr/cc)	0.91	0.76
%ARENAS	90.35	75.35
%ARCILLAS	7	9
%LIMOS	2.65	15.65
CLASE TEXTURAL	AF	AF
Conductividad k10 (m/día)	9.87	0.74
%H gravimétrico a 0Bar	193.25	73.08
%H gravimétrico a 0,3 Bar	144.1	49.69
%H gravimétrico a 1 Bar	140.52	47.15
%H gravimétrico a 5 Bar	137.97	46.49
%H gravimétrico a 10 Bar	134.63	44.35
%H gravimétrico a 15 Bar	133.13	44.34



Calicata S1-8

Coordenadas: X: 1191551,78 Cobertura: Bosque secundario

Y: 1000422,6

Sistema de
Coordenadas: Magna-Sirgas Oeste

Resultados de Laboratorio:

Muestreo	H1	H2
Da (gr/cc)	0.56	0.85
%ARENAS	78.7	70.35
%ARCILLAS	10	11
%LIMOS	11.3	18.65
CLASE TEXTURAL	AF	AF
Conductividad k10 (m/día)	5.68	1.16
%H gravimétrico a 0Bar	172.56	91.59
%H gravimétrico a 0,3 Bar	113.05	63.97
%H gravimétrico a 1 Bar	110.16	62.59
%H gravimétrico a 5 Bar	108.24	61.20
%H gravimétrico a 10 Bar	104.75	59.07
%H gravimétrico a 15 Bar	104.65	58.89



Calicata S1-9

Coordenadas:	X: 1191398,09	Cobertura: Bosque secundario																																							
	Y: 1000626,9	Resultados de Laboratorio:																																							
Sistema de Coordenadas:	Magna-Sirgas Oeste																																								
		<table border="1"> <thead> <tr> <th>Muestreo</th> <th>H1</th> <th>H2</th> </tr> </thead> <tbody> <tr> <td>Da (gr/cc)</td> <td>0.67</td> <td>0.70</td> </tr> <tr> <td>%ARENAS</td> <td>78.7</td> <td>78.7</td> </tr> <tr> <td>%ARCILLAS</td> <td>10</td> <td>10</td> </tr> <tr> <td>%LIMOS</td> <td>11.3</td> <td>11.3</td> </tr> <tr> <td>CLASE TEXTURAL</td> <td>AF</td> <td>AF</td> </tr> <tr> <td>Conductividad k10 (m/día)</td> <td>8.15</td> <td>6.01</td> </tr> <tr> <td>%H gravimétrico a 0Bar</td> <td>135.12</td> <td>110.76</td> </tr> <tr> <td>%H gravimétrico a 0,3 Bar</td> <td>83.08</td> <td>64.65</td> </tr> <tr> <td>%H gravimétrico a 1 Bar</td> <td>80.37</td> <td>62.68</td> </tr> <tr> <td>%H gravimétrico a 5 Bar</td> <td>77.64</td> <td>60.99</td> </tr> <tr> <td>%H gravimétrico a 10 Bar</td> <td>74.6</td> <td>58.98</td> </tr> <tr> <td>%H gravimétrico a 15 Bar</td> <td>74.43</td> <td>58.90</td> </tr> </tbody> </table>	Muestreo	H1	H2	Da (gr/cc)	0.67	0.70	%ARENAS	78.7	78.7	%ARCILLAS	10	10	%LIMOS	11.3	11.3	CLASE TEXTURAL	AF	AF	Conductividad k10 (m/día)	8.15	6.01	%H gravimétrico a 0Bar	135.12	110.76	%H gravimétrico a 0,3 Bar	83.08	64.65	%H gravimétrico a 1 Bar	80.37	62.68	%H gravimétrico a 5 Bar	77.64	60.99	%H gravimétrico a 10 Bar	74.6	58.98	%H gravimétrico a 15 Bar	74.43	58.90
		Muestreo	H1	H2																																					
		Da (gr/cc)	0.67	0.70																																					
		%ARENAS	78.7	78.7																																					
		%ARCILLAS	10	10																																					
		%LIMOS	11.3	11.3																																					
		CLASE TEXTURAL	AF	AF																																					
		Conductividad k10 (m/día)	8.15	6.01																																					
		%H gravimétrico a 0Bar	135.12	110.76																																					
		%H gravimétrico a 0,3 Bar	83.08	64.65																																					
		%H gravimétrico a 1 Bar	80.37	62.68																																					
		%H gravimétrico a 5 Bar	77.64	60.99																																					
%H gravimétrico a 10 Bar	74.6	58.98																																							
%H gravimétrico a 15 Bar	74.43	58.90																																							
																																									

Calicata S1-12

Coordenadas:	X: 1190084,98	Cobertura: Bosque secundario
	Y: 999622,524	Resultados de Laboratorio:

Sistema de	Magna-Sirgas Oeste
Coordenadas:	

Muestreo	H1	H2
Da (gr/cc)	0.13	0.56
%ARENAS	92.5	74
%ARCILLAS	3.75	6
%LIMOS	3.75	20
CLASE TEXTURAL	FA	AF
Conductividad k10 (m/día)	10.32	5.73
%H gravimétrico a 0Bar	796.86	169.78
%H gravimétrico a 0,3 Bar	452.72	124.90
%H gravimétrico a 1 Bar	429.04	120.38
%H gravimétrico a 5 Bar	402.77	104.38
%H gravimétrico a 10 Bar	381.33	98.41
%H gravimétrico a 15 Bar	357.65	98.00



Calicata S1-13				
Coordenadas:	X: 1191367,86	Cobertura: Bosque secundario		
	Y: 1000734,14	Resultados de Laboratorio:		
Sistema de Coordenadas:	Magna-Sirgas Oeste			
		Muestreo	H1	H2
		Da (gr/cc)	0.59	0.65
		%ARENAS	81.03	77.50
		%ARCILLAS	8.05	7
		%LIMOS	10.92	15.5
		CLASE TEXTURAL	FA	AF
		Conductividad k10 (m/día)	11.64	1.62
		%H gravimétrico a 0Bar	99.49	172.84
		%H gravimétrico a 0,3 Bar	69.57	137.53
		%H gravimétrico a 1 Bar	65.41	130.5
		%H gravimétrico a 5 Bar	63.21	126.57
		%H gravimétrico a 10 Bar	60.98	123.59
%H gravimétrico a 15 Bar	60.29	122.52		



Calicata S1-14

Coordenadas:	X: 1191689,41	Cobertura: Potrero con rastrojo																								
	Y: 1000895,33	Resultados de Laboratorio:																								
Sistema de Coordenadas:	Magna-Sirgas Oeste																									
		<table border="1"> <thead> <tr> <th>Muestreo</th> <th>H1</th> </tr> </thead> <tbody> <tr> <td>Da (gr/cc)</td> <td>0.80</td> </tr> <tr> <td>%ARENAS</td> <td>77.50</td> </tr> <tr> <td>%ARCILLAS</td> <td>8</td> </tr> <tr> <td>%LIMOS</td> <td>14.5</td> </tr> <tr> <td>CLASE TEXTURAL</td> <td>AF</td> </tr> <tr> <td>Conductividad k10 (m/día)</td> <td>12.12</td> </tr> <tr> <td>%H gravimétrico a 0Bar</td> <td>119.64</td> </tr> <tr> <td>%H gravimétrico a 0,3 Bar</td> <td>61.19</td> </tr> <tr> <td>%H gravimétrico a 1 Bar</td> <td>56.07</td> </tr> <tr> <td>%H gravimétrico a 5 Bar</td> <td>53.23</td> </tr> <tr> <td>%H gravimétrico a 10 Bar</td> <td>50.45</td> </tr> </tbody> </table>	Muestreo	H1	Da (gr/cc)	0.80	%ARENAS	77.50	%ARCILLAS	8	%LIMOS	14.5	CLASE TEXTURAL	AF	Conductividad k10 (m/día)	12.12	%H gravimétrico a 0Bar	119.64	%H gravimétrico a 0,3 Bar	61.19	%H gravimétrico a 1 Bar	56.07	%H gravimétrico a 5 Bar	53.23	%H gravimétrico a 10 Bar	50.45
Muestreo	H1																									
Da (gr/cc)	0.80																									
%ARENAS	77.50																									
%ARCILLAS	8																									
%LIMOS	14.5																									
CLASE TEXTURAL	AF																									
Conductividad k10 (m/día)	12.12																									
%H gravimétrico a 0Bar	119.64																									
%H gravimétrico a 0,3 Bar	61.19																									
%H gravimétrico a 1 Bar	56.07																									
%H gravimétrico a 5 Bar	53.23																									
%H gravimétrico a 10 Bar	50.45																									



%H gravimétrico a 15 Bar 49.58

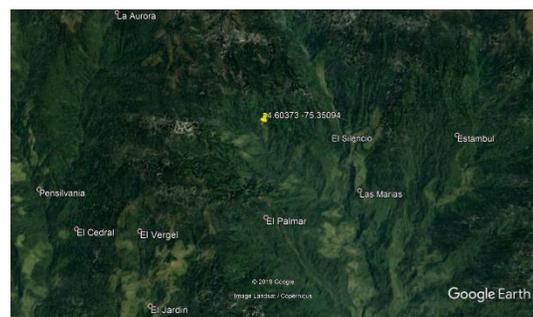


Calicata S1-15

Coordenadas:	X: 1191613,51	Cobertura: Bosque secundario																								
	Y: 1001064,41	Resultados de Laboratorio:																								
Sistema de Coordenadas:	Magna-Sirgas Oeste																									
		<table border="1"> <thead> <tr> <th>Muestreo</th> <th>H1</th> <th>H2</th> </tr> </thead> <tbody> <tr> <td>Da (gr/cc)</td> <td>0.57</td> <td>1.15</td> </tr> <tr> <td>%ARENAS</td> <td>77.5</td> <td>80.5</td> </tr> <tr> <td>%ARCILLAS</td> <td>6</td> <td>6</td> </tr> <tr> <td>%LIMOS</td> <td>16.5</td> <td>13.5</td> </tr> <tr> <td>CLASE TEXTURAL</td> <td>AF</td> <td>AF</td> </tr> <tr> <td>Conductividad k10 (m/día)</td> <td>10.42</td> <td>11.29</td> </tr> <tr> <td>%H gravimétrico a 0Bar</td> <td>91.9</td> <td>79.36</td> </tr> </tbody> </table>	Muestreo	H1	H2	Da (gr/cc)	0.57	1.15	%ARENAS	77.5	80.5	%ARCILLAS	6	6	%LIMOS	16.5	13.5	CLASE TEXTURAL	AF	AF	Conductividad k10 (m/día)	10.42	11.29	%H gravimétrico a 0Bar	91.9	79.36
Muestreo	H1	H2																								
Da (gr/cc)	0.57	1.15																								
%ARENAS	77.5	80.5																								
%ARCILLAS	6	6																								
%LIMOS	16.5	13.5																								
CLASE TEXTURAL	AF	AF																								
Conductividad k10 (m/día)	10.42	11.29																								
%H gravimétrico a 0Bar	91.9	79.36																								



%H gravimétrico a 0,3 Bar	55.52	67.28
%H gravimétrico a 1 Bar	50.01	37.55
%H gravimétrico a 5 Bar	47.06	34.88
%H gravimétrico a 10 Bar	44.47	32.81
%H gravimétrico a 15 Bar	43.71	32.17



Calicata S1-16

Coordenadas:	X: 1191857,28	Cobertura: Bosque secundario		
	Y: 1000793,95	Resultados de Laboratorio:		
Sistema de Coordenadas:	Magna-Sirgas Oeste	Muestreo	H1	H2
		Da (gr/cc)	0.70	0.88
		%ARENAS	80.50	77.5
		%ARCILLAS	6	6
		%LIMOS	13.5	16.5
		CLASE TEXTURAL	AF	AF
		Conductividad k10 (m/día)	8.87	8.23



%H gravimétrico a 0Bar	120.57	92.78
%H gravimétrico a 0,3 Bar	72.19	59.75
%H gravimétrico a 1 Bar	68.02	56.20
%H gravimétrico a 5 Bar	65.06	54.28
%H gravimétrico a 10 Bar	62.76	52.49
%H gravimétrico a 15 Bar	61.96	51.83



Calicata S1-17

Coordenadas:	X: 1191333,05	Cobertura: Bosque secundario		
	Y: 1000437,56		Resultados de Laboratorio:	
Sistema de Coordenadas:	Magna-Sirgas Oeste			
		Muestreo	H1	H2
		Da (gr/cc)	0.73	0.89
		%ARENAS	81.5	82.5
		%ARCILLAS	6	6
		%LIMOS	12.5	11.5



CLASE TEXTURAL	FA	AF
Conductividad k10 (m/día)	11.7	0.22
%H gravimétrico a 0Bar	83.77	76.97
%H gravimétrico a 0,3 Bar	46.87	60.44
%H gravimétrico a 1 Bar	45.41	57.24
%H gravimétrico a 5 Bar	44.13	55.60
%H gravimétrico a 10 Bar	42.50	53.96
%H gravimétrico a 15 Bar	42.45	53.6



Calicata S1-18

Coordenadas:	X: 1191170,07	Cobertura: Bosque												
	Y: 1000807,78	Resultados de Laboratorio:												
Sistema de Coordenadas:	Magna-Sirgas Oeste	<table border="1"> <thead> <tr> <th>Muestreo</th> <th>H1</th> <th>H2</th> </tr> </thead> <tbody> <tr> <td>Da (gr/cc)</td> <td>0.50</td> <td>0.65</td> </tr> <tr> <td>%ARENAS</td> <td>76</td> <td>80</td> </tr> <tr> <td>%ARCILLAS</td> <td>2.2</td> <td>4.20</td> </tr> </tbody> </table>	Muestreo	H1	H2	Da (gr/cc)	0.50	0.65	%ARENAS	76	80	%ARCILLAS	2.2	4.20
Muestreo	H1	H2												
Da (gr/cc)	0.50	0.65												
%ARENAS	76	80												
%ARCILLAS	2.2	4.20												



%LIMOS	21.80	15.80
CLASE TEXTURAL	AF	AF
Conductividad k10 (m/día)	0.14	3.87
%H gravimétrico a 0Bar	163.48	107.83
%H gravimétrico a 0,3 Bar	127.67	63.17
%H gravimétrico a 1 Bar	121.99	59.02
%H gravimétrico a 5 Bar	117.59	56.71
%H gravimétrico a 10 Bar	114.37	54.59
%H gravimétrico a 15 Bar	13.13	51.22



Calicata S1-19

Coordenadas:	X: 1191893,53	Cobertura: Bosque secundario		
	Y: 1000953,35	Resultados de Laboratorio:		
Sistema de Coordenadas:	Magna-Sirgas Oeste	Muestreo	H1	H2
		Da (gr/cc)	0.52	0.62
		%ARENAS	74	73.0



%ARCILLAS	5.2	3.2
%LIMOS	20.8	23.8
CLASE TEXTURAL	AF	AF
Conductividad k10 (m/día)	12.43	15.77
%H gravimétrico a 0Bar	153.97	114.17
%H gravimétrico a 0,3 Bar	107.37	78.18
%H gravimétrico a 1 Bar	101.28	74.94
%H gravimétrico a 5 Bar	97.01	72.06
%H gravimétrico a 10 Bar	93.43	69.89
%H gravimétrico a 15 Bar	92.41	69.04



Calicata S1-20

Coordenadas:	X: 1191910,34	Cobertura: Bosque secundario		
	Y: 1000890,33	Resultados de Laboratorio:		
Sistema de Coordenadas:	Magna-Sirgas Oeste	Muestreo	H1	H2



Da (gr/cc)	0.52	0.64
%ARENAS	75	74
%ARCILLAS	3.2	3.2
%LIMOS	21.8	22.8
CLASE TEXTURAL	AF	AF
Conductividad k10 (m/día)	10.32	1.33
%H gravimétrico a 0Bar	158.41	108.44
%H gravimétrico a 0,3 Bar	137.02	88.28
%H gravimétrico a 1 Bar	94.72	84.9
%H gravimétrico a 5 Bar	91.72	82.69
%H gravimétrico a 10 Bar	89.6	80.5
%H gravimétrico a 15 Bar	88.71	79.66



Calicata S1-21

Coordenadas:	X: 1191741,39	Cobertura: Bosque secundario
	Y: 999687,796	Resultados de Laboratorio:

Sistema de Magna-Sirgas Oeste
 Coordenadas:



Muestreo	H1	H2
Da (gr/cc)	0.45	0.51
%ARENAS	83.75	88
%ARCILLAS	4	4.2
%LIMOS	12.25	7.8
CLASE TEXTURAL	AF	AF
Conductividad k10 (m/día)	8.76	11.48
%H gravimétrico a 0Bar	208.28	185.48
%H gravimétrico a 0,3 Bar	156.02	128.31
%H gravimétrico a 1 Bar	148.75	123.33
%H gravimétrico a 5 Bar	143.43	120.17
%H gravimétrico a 10 Bar	138.08	117.52
%H gravimétrico a 15 Bar	136.73	116.36



Calicata S1-22

Coordenadas: X: 1191831,77 Cobertura: Bosque secundario

Y: 999681,929

Sistema de
Coordenadas: Magna-Sirgas Oeste



Resultados de Laboratorio:

Muestreo	H1	H2
Da (gr/cc)	0.59	0.65
%ARENAS	85	87
%ARCILLAS	3.2	4.2
%LIMOS	11.8	8.80
CLASE TEXTURAL	AF	AF
Conductividad k10 (m/día)	12.59	1.0
%H gravimétrico a 0Bar	161.38	123.86
%H gravimétrico a 0,3 Bar	103.43	98.75
%H gravimétrico a 1 Bar	98.75	95.20
%H gravimétrico a 5 Bar	96.06	93.39
%H gravimétrico a 10 Bar	94.68	60.72
%H gravimétrico a 15 Bar	90.22	60.15



Calicata S1-24

Coordenadas:	X: 1192233,95	Cobertura: Bosque
	Y: 999511,643	Resultados de Laboratorio:
Sistema de Coordenadas:	Magna-Sirgas Oeste	
		Muestreo H1
		Da (gr/cc) 0.60
		%ARENAS 80
		%ARCILLAS 4.2
		%LIMOS 15.8
		CLASE TEXTURAL AF
		Conductividad k10 (m/día) 13.52
		%H gravimétrico a 0Bar 53.48
		%H gravimétrico a 0,3 Bar 36.56
		%H gravimétrico a 1 Bar 33.30
		%H gravimétrico a 5 Bar 31.02
		%H gravimétrico a 10 Bar 29.61
%H gravimétrico a 15 Bar 29.07		
		

Calicata S1-25				
Coordenadas:	X: 1192228,74	Cobertura: Bosque		
	Y: 999463,505	Resultados de Laboratorio:		
Sistema de Coordenadas:	Magna-Sirgas Oeste			
		Muestreo		
		H1	H2	
		Da (gr/cc)	0.29	0.64
		%ARENAS	83.33	84
		%ARCILLAS	5.33	4.2
		%LIMOS	11.33	11.8
		CLASE TEXTURAL	AF	AF
		Conductividad k10 (m/día)	32.25	8.31
		%H gravimétrico a 0Bar	390.60	124.70
		%H gravimétrico a 0,3 Bar	287.93	95.76
		%H gravimétrico a 1 Bar	272.34	93.30
		%H gravimétrico a 5 Bar	263.99	67.27
%H gravimétrico a 10 Bar	256.21	62.82		
%H gravimétrico a 15 Bar	253.85	59.83		



Calicata S2-1

Coordenadas:	X: 1191988,56	Cobertura: Potrero con rastrojo		
	Y: 999762,074	Resultados de Laboratorio:		
Sistema de Coordenadas:	Magna-Sirgas Oeste	Muestreo	H1	H2
		Da (gr/cc)	0.46	0.70
		%ARENAS	78	77
		%ARCILLAS	5	5
		%LIMOS	17	18
		CLASE TEXTURAL	AF	AF
		Conductividad k10 (m/día)	3.97	10.87
		%H gravimétrico a 0Bar	121.91	108.62
		%H gravimétrico a 0,3 Bar	83.28	73.62
		%H gravimétrico a 1 Bar	79.69	69.96
		%H gravimétrico a 5 Bar	70.65	67.76
		%H gravimétrico a 10 Bar	66.52	62.33



%H gravimétrico a 15 Bar 62.92 58.67



Calicata S2-2

Coordenadas:	X: 1192125,12	Cobertura: Potrero con rastrojo		
	Y: 999754,66	Resultados de Laboratorio:		
Sistema de Coordenadas:	Magna-Sirgas Oeste	Muestreo	H1	H2
		Da (gr/cc)	0.53	0.71
		%ARENAS	86	82
		%ARCILLAS	5	6
		%LIMOS	9	12
		CLASE TEXTURAL	FA	FA
		Conductividad k10 (m/día)	4.56	5.01



%H gravimétrico a 0Bar	168.54	108.48
%H gravimétrico a 0,3 Bar	103.26	69.25
%H gravimétrico a 1 Bar	98.9	65.91
%H gravimétrico a 5 Bar	89.24	62.15
%H gravimétrico a 10 Bar	83.31	56.12
%H gravimétrico a 15 Bar	78.95	52.77



Calicata S2-3

Coordenadas:	X: 1192276,17	Cobertura: Potrero con rastrojo		
	Y: 999726,261		Resultados de Laboratorio:	
Sistema de Coordenadas:	Magna-Sirgas Oeste			
		Muestreo	H1	H2
		Da (gr/cc)	0.71	0.79
		%ARENAS	79	77
		%ARCILLAS	5	5
		%LIMOS	16	18
		CLASE TEXTURAL	FA	FA



Conductividad k10 (m/día)	12.04	1.97
%H gravimétrico a 0Bar	106.12	92.09
%H gravimétrico a 0,3 Bar	68.94	58.31
%H gravimétrico a 1 Bar	65.23	55.73
%H gravimétrico a 5 Bar	62.05	29.24
%H gravimétrico a 10 Bar	55.82	24.19
%H gravimétrico a 15 Bar	52.11	21.61



Calicata S2-4

Coordenadas:	X: 1192239,34	Cobertura: Potrero con rastrojo															
	Y: 999808,04																
Sistema de Coordenadas:	Magna-Sirgas Oeste	Resultados de Laboratorio:															
		<table border="1"> <thead> <tr> <th>Muestreo</th> <th>H1</th> <th>H2</th> </tr> </thead> <tbody> <tr> <td>Da (gr/cc)</td> <td>0.65</td> <td>0.80</td> </tr> <tr> <td>%ARENAS</td> <td>76</td> <td>77</td> </tr> <tr> <td>%ARCILLAS</td> <td>5</td> <td>7</td> </tr> <tr> <td>%LIMOS</td> <td>19</td> <td>16</td> </tr> </tbody> </table>	Muestreo	H1	H2	Da (gr/cc)	0.65	0.80	%ARENAS	76	77	%ARCILLAS	5	7	%LIMOS	19	16
Muestreo	H1	H2															
Da (gr/cc)	0.65	0.80															
%ARENAS	76	77															
%ARCILLAS	5	7															
%LIMOS	19	16															



CLASE TEXTURAL	AF	FA
Conductividad k10 (m/día)	1.14	0.47
%H gravimétrico a 0Bar	146.42	106.67
%H gravimétrico a 0,3 Bar	106.10	58.30
%H gravimétrico a 1 Bar	101.87	54.52
%H gravimétrico a 5 Bar	98.7	52.55
%H gravimétrico a 10 Bar	91.12	40.79
%H gravimétrico a 15 Bar	86.88	37.00



Calicata S2-6																																						
Coordenadas:	X: 1192281,85	Cobertura: Potrero con rastrojo																																				
	Y: 999627,591	Resultados de Laboratorio:																																				
Sistema de Coordenadas:	Magna-Sirgas Oeste	<table border="1"> <thead> <tr> <th>Muestreo</th> <th>H1</th> <th>H2</th> </tr> </thead> <tbody> <tr> <td>Da (gr/cc)</td> <td>0.66</td> <td>0.75</td> </tr> <tr> <td>%ARENAS</td> <td>75</td> <td>80</td> </tr> <tr> <td>%ARCILLAS</td> <td>7</td> <td>5</td> </tr> <tr> <td>%LIMOS</td> <td>18</td> <td>15</td> </tr> <tr> <td>CLASE TEXTURAL</td> <td>AF</td> <td>AF</td> </tr> <tr> <td>Conductividad k10 (m/día)</td> <td>1.36</td> <td>4.26</td> </tr> <tr> <td>%H gravimétrico a 0Bar</td> <td>141.09</td> <td>200.49</td> </tr> <tr> <td>%H gravimétrico a 0,3 Bar</td> <td>98.21</td> <td>169.95</td> </tr> <tr> <td>%H gravimétrico a 1 Bar</td> <td>96.12</td> <td>167.78</td> </tr> <tr> <td>%H gravimétrico a 5 Bar</td> <td>86.22</td> <td>117.03</td> </tr> <tr> <td>%H gravimétrico a 10 Bar</td> <td>83.89</td> <td>114.46</td> </tr> </tbody> </table>	Muestreo	H1	H2	Da (gr/cc)	0.66	0.75	%ARENAS	75	80	%ARCILLAS	7	5	%LIMOS	18	15	CLASE TEXTURAL	AF	AF	Conductividad k10 (m/día)	1.36	4.26	%H gravimétrico a 0Bar	141.09	200.49	%H gravimétrico a 0,3 Bar	98.21	169.95	%H gravimétrico a 1 Bar	96.12	167.78	%H gravimétrico a 5 Bar	86.22	117.03	%H gravimétrico a 10 Bar	83.89	114.46
Muestreo	H1	H2																																				
Da (gr/cc)	0.66	0.75																																				
%ARENAS	75	80																																				
%ARCILLAS	7	5																																				
%LIMOS	18	15																																				
CLASE TEXTURAL	AF	AF																																				
Conductividad k10 (m/día)	1.36	4.26																																				
%H gravimétrico a 0Bar	141.09	200.49																																				
%H gravimétrico a 0,3 Bar	98.21	169.95																																				
%H gravimétrico a 1 Bar	96.12	167.78																																				
%H gravimétrico a 5 Bar	86.22	117.03																																				
%H gravimétrico a 10 Bar	83.89	114.46																																				
																																						

		%H gravimétrico a 15 Bar	83.05	107.02																								
																												
Calicata S2-8																												
Coordenadas:	X: 1192564,11	Cobertura: Bosque secundario																										
	Y: 999557,58	Resultados de Laboratorio:																										
Sistema de Coordenadas:	Magna-Sirgas Oeste	<table border="1"> <thead> <tr> <th>Muestreo</th> <th>H1</th> <th>H2</th> </tr> </thead> <tbody> <tr> <td>Da (gr/cc)</td> <td>0.75</td> <td>0.66</td> </tr> <tr> <td>%ARENAS</td> <td>88</td> <td>81</td> </tr> <tr> <td>%ARCILLAS</td> <td>5</td> <td>5</td> </tr> <tr> <td>%LIMOS</td> <td>7</td> <td>14</td> </tr> <tr> <td>CLASE TEXTURAL</td> <td>FA</td> <td>FA</td> </tr> <tr> <td>Conductividad k10 (m/día)</td> <td>15.04</td> <td>1.36</td> </tr> <tr> <td>%H gravimétrico a 0Bar</td> <td>135.72</td> <td>101.67</td> </tr> </tbody> </table>			Muestreo	H1	H2	Da (gr/cc)	0.75	0.66	%ARENAS	88	81	%ARCILLAS	5	5	%LIMOS	7	14	CLASE TEXTURAL	FA	FA	Conductividad k10 (m/día)	15.04	1.36	%H gravimétrico a 0Bar	135.72	101.67
Muestreo	H1	H2																										
Da (gr/cc)	0.75	0.66																										
%ARENAS	88	81																										
%ARCILLAS	5	5																										
%LIMOS	7	14																										
CLASE TEXTURAL	FA	FA																										
Conductividad k10 (m/día)	15.04	1.36																										
%H gravimétrico a 0Bar	135.72	101.67																										



%H gravimétrico a 0,3 Bar	78.40	64.16
%H gravimétrico a 1 Bar	74.96	64.09
%H gravimétrico a 5 Bar	72.24	62.50
%H gravimétrico a 10 Bar	68.76	60.26
%H gravimétrico a 15 Bar	68.66	

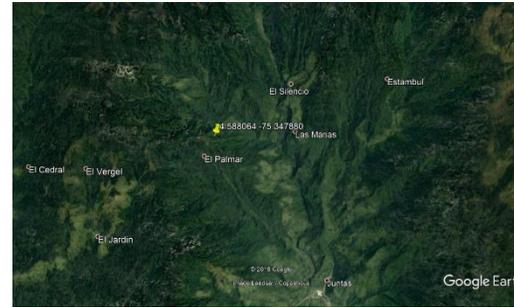


Calicata S2-9

Coordenadas:	X: 1191957,4	Cobertura: Bosque secundario		
	Y: 999332,082	Resultados de Laboratorio:		
Sistema de Coordenadas:	Magna-Sirgas Oeste	Muestreo	H1	H2



Da (gr/cc)	0.53	1.20
%ARENAS	76	78
%ARCILLAS	5	5
%LIMOS	19	17
CLASE TEXTURAL	FA	AF
Conductividad k10 (m/día)	2.31	0.89
%H gravimétrico a 0Bar	87.40	81.50
%H gravimétrico a 0,3 Bar	63.82	64.97
%H gravimétrico a 1 Bar	61.84	62.89
%H gravimétrico a 5 Bar	60.10	61.27
%H gravimétrico a 10 Bar	58.44	59.53
%H gravimétrico a 15 Bar	58.38	59.47

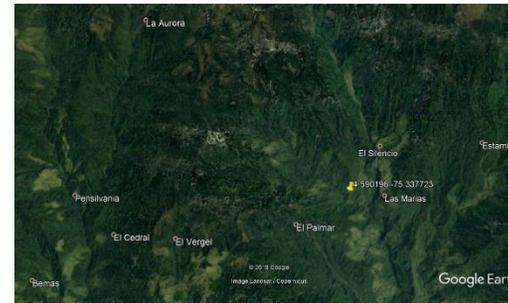


Calicata S2-10

Coordenadas:	X: 1193084,41	Cobertura: Bosque secundario																											
	Y: 999570,681	Resultados de Laboratorio:																											
Sistema de Coordenadas:	Magna-Sirgas Oeste																												
		<table border="1"> <thead> <tr> <th>Muestreo</th> <th>H1</th> <th>H2</th> </tr> </thead> <tbody> <tr> <td>Da (gr/cc)</td> <td>0.52</td> <td>0.59</td> </tr> <tr> <td>%ARENAS</td> <td>87</td> <td>87</td> </tr> <tr> <td>%ARCILLAS</td> <td>5</td> <td>5</td> </tr> <tr> <td>%LIMOS</td> <td>8</td> <td>8</td> </tr> <tr> <td>CLASE TEXTURAL</td> <td>FA</td> <td>FA</td> </tr> <tr> <td>Conductividad k10 (m/día)</td> <td>8.42</td> <td>10.54</td> </tr> <tr> <td>%H gravimétrico a 0Bar</td> <td>88.54</td> <td>46.42</td> </tr> <tr> <td>%H gravimétrico a 0,3 Bar</td> <td>38.13</td> <td>18.74</td> </tr> </tbody> </table>	Muestreo	H1	H2	Da (gr/cc)	0.52	0.59	%ARENAS	87	87	%ARCILLAS	5	5	%LIMOS	8	8	CLASE TEXTURAL	FA	FA	Conductividad k10 (m/día)	8.42	10.54	%H gravimétrico a 0Bar	88.54	46.42	%H gravimétrico a 0,3 Bar	38.13	18.74
Muestreo	H1	H2																											
Da (gr/cc)	0.52	0.59																											
%ARENAS	87	87																											
%ARCILLAS	5	5																											
%LIMOS	8	8																											
CLASE TEXTURAL	FA	FA																											
Conductividad k10 (m/día)	8.42	10.54																											
%H gravimétrico a 0Bar	88.54	46.42																											
%H gravimétrico a 0,3 Bar	38.13	18.74																											



%H gravimétrico a 1 Bar	36.15	16.92
%H gravimétrico a 5 Bar	34.56	15.61
%H gravimétrico a 10 Bar	33.05	13.11
%H gravimétrico a 15 Bar	33.00	12.95



Calicata S3-2

Coordenadas:	X: 1190345	Cobertura: Bosque secundario												
	Y: 999060,033	Resultados de Laboratorio:												
Sistema de Coordenadas:	Magna-Sirgas Oeste	<table border="1"> <thead> <tr> <th>Muestreo</th> <th>H1</th> <th>H2</th> </tr> </thead> <tbody> <tr> <td>Da (gr/cc)</td> <td>0.68</td> <td>0.56</td> </tr> <tr> <td>%ARENAS</td> <td>85</td> <td>83</td> </tr> <tr> <td>%ARCILLAS</td> <td>4</td> <td>4</td> </tr> </tbody> </table>	Muestreo	H1	H2	Da (gr/cc)	0.68	0.56	%ARENAS	85	83	%ARCILLAS	4	4
Muestreo	H1	H2												
Da (gr/cc)	0.68	0.56												
%ARENAS	85	83												
%ARCILLAS	4	4												



%LIMOS	11	13
CLASE TEXTURAL	FA	FA
Conductividad k10 (m/día)	9.79	8.70
%H gravimétrico a 0Bar	104.00	93.92
%H gravimétrico a 0,3 Bar	69.01	55.9
%H gravimétrico a 1 Bar	66.08	52.59
%H gravimétrico a 5 Bar	66.02	42.16
%H gravimétrico a 10 Bar	56.85	35.89
%H gravimétrico a 15 Bar	53.92	32.57



Calicata S3-3

Coordenadas:	X: 1191531,31	Cobertura: Bosque secundario						
	Y: 999660,958	Resultados de Laboratorio:						
Sistema de Coordenadas:	Magna-Sirgas Oeste	<table border="1"> <thead> <tr> <th>Muestreo</th> <th>H1</th> <th>H2</th> </tr> </thead> <tbody> <tr> <td> </td> <td> </td> <td> </td> </tr> </tbody> </table>	Muestreo	H1	H2			
Muestreo	H1	H2						

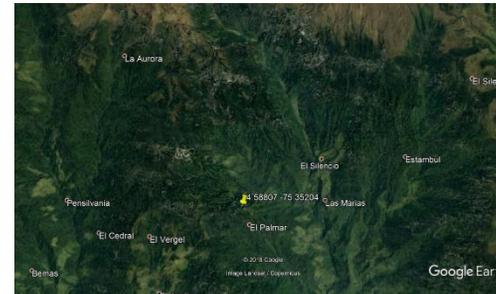


Da (gr/cc)	0.65	0.68
%ARENAS	78	82.35
%ARCILLAS	6	5
%LIMOS	16	12.65
CLASE TEXTURAL	FA	FA
Conductividad k10 (m/día)	2.40	7.60
%H gravimétrico a 0Bar	115.02	153.79
%H gravimétrico a 0,3 Bar	83.06	98.21
%H gravimétrico a 1 Bar	80.08	97.73
%H gravimétrico a 5 Bar	78.85	92.42
%H gravimétrico a 10 Bar	76.29	89.50
%H gravimétrico a 15 Bar	76.26	88.43



Calicata S3-4

Coordenadas:	X: 1191495,58	Cobertura: Bosque secundario		
	Y: 999331,632	Resultados de Laboratorio:		
Sistema de Coordenadas:	Magna-Sirgas Oeste	Muestreo	H1	H2
		Da (gr/cc)	0.37	0.18
		%ARENAS	74	85
		%ARCILLAS	4	4
		%LIMOS	22	11
		CLASE TEXTURAL	AF	FA
		Conductividad k10 (m/día)	0.13	0.11
		%H gravimétrico a 0Bar	212.82	231.37
		%H gravimétrico a 0,3 Bar	176.49	198.73
		%H gravimétrico a 1 Bar	170.09	193.48
		%H gravimétrico a 5 Bar	168.18	184.76
		%H gravimétrico a 10 Bar	150.80	180.18
		%H gravimétrico a 15 Bar	144.80	174.94



Calicata S3-6

Coordenadas:	X: 1192100,67	Cobertura: Potrero con rastrojo		
	Y: 999630,029	Resultados de Laboratorio:		
Sistema de Coordenadas:	Magna-Sirgas Oeste	Muestreo	H1	H2
		Da (gr/cc)	0.63	0.59
		%ARENAS	83.82	86.35
		%ARCILLAS	6.94	5
		%LIMOS	9.24	8.65
		CLASE TEXTURAL	FA	FA



Conductividad k10 (m/día)	0.63	5.5
%H gravimétrico a 0Bar	180.98	112.25
%H gravimétrico a 0,3 Bar	144.77	87.70
%H gravimétrico a 1 Bar	137.45	86.24
%H gravimétrico a 5 Bar	135.54	82.24
%H gravimétrico a 10 Bar	131.66	79.77
%H gravimétrico a 15 Bar	130.90	79.69



Calicata S3-7

Coordenadas:	X: 1192149,88	Cobertura: Potrero con rastrojo																																							
	Y: 999571,181	Resultados de Laboratorio:																																							
Sistema de Coordenadas:	Magna-Sirgas Oeste																																								
		<table border="1"> <thead> <tr> <th>Muestreo</th> <th>H1</th> <th>H2</th> </tr> </thead> <tbody> <tr> <td>Da (gr/cc)</td> <td>0.55</td> <td>0.62</td> </tr> <tr> <td>%ARENAS</td> <td>78</td> <td>77.35</td> </tr> <tr> <td>%ARCILLAS</td> <td>6</td> <td>5</td> </tr> <tr> <td>%LIMOS</td> <td>16</td> <td>17.65</td> </tr> <tr> <td>CLASE TEXTURAL</td> <td>FA</td> <td>FA</td> </tr> <tr> <td>Conductividad k10 (m/día)</td> <td>7.11</td> <td>12.91</td> </tr> <tr> <td>%H gravimétrico a 0Bar</td> <td>152.20</td> <td>127.53</td> </tr> <tr> <td>%H gravimétrico a 0,3 Bar</td> <td>93.52</td> <td>74.88</td> </tr> <tr> <td>%H gravimétrico a 1 Bar</td> <td>88.95</td> <td>71.02</td> </tr> <tr> <td>%H gravimétrico a 5 Bar</td> <td>87.81</td> <td>69.85</td> </tr> <tr> <td>%H gravimétrico a 10 Bar</td> <td>84.99</td> <td>67.84</td> </tr> <tr> <td>%H gravimétrico a 15 Bar</td> <td>84.69</td> <td>67.40</td> </tr> </tbody> </table>	Muestreo	H1	H2	Da (gr/cc)	0.55	0.62	%ARENAS	78	77.35	%ARCILLAS	6	5	%LIMOS	16	17.65	CLASE TEXTURAL	FA	FA	Conductividad k10 (m/día)	7.11	12.91	%H gravimétrico a 0Bar	152.20	127.53	%H gravimétrico a 0,3 Bar	93.52	74.88	%H gravimétrico a 1 Bar	88.95	71.02	%H gravimétrico a 5 Bar	87.81	69.85	%H gravimétrico a 10 Bar	84.99	67.84	%H gravimétrico a 15 Bar	84.69	67.40
		Muestreo	H1	H2																																					
		Da (gr/cc)	0.55	0.62																																					
		%ARENAS	78	77.35																																					
		%ARCILLAS	6	5																																					
		%LIMOS	16	17.65																																					
		CLASE TEXTURAL	FA	FA																																					
		Conductividad k10 (m/día)	7.11	12.91																																					
		%H gravimétrico a 0Bar	152.20	127.53																																					
		%H gravimétrico a 0,3 Bar	93.52	74.88																																					
		%H gravimétrico a 1 Bar	88.95	71.02																																					
		%H gravimétrico a 5 Bar	87.81	69.85																																					
		%H gravimétrico a 10 Bar	84.99	67.84																																					
%H gravimétrico a 15 Bar	84.69	67.40																																							



Calicata S3-8

Coordenadas:	X: 1192056,82	Cobertura: Bosque secundario																																				
	Y: 999538,872	Resultados de Laboratorio:																																				
Sistema de Coordenadas:	Magna-Sirgas Oeste																																					
		<table border="1"> <thead> <tr> <th>Muestreo</th> <th>H1</th> <th>H2</th> </tr> </thead> <tbody> <tr> <td>Da (gr/cc)</td> <td>0.60</td> <td>0.55</td> </tr> <tr> <td>%ARENAS</td> <td>78.95</td> <td>78.95</td> </tr> <tr> <td>%ARCILLAS</td> <td>8.15</td> <td>8.15</td> </tr> <tr> <td>%LIMOS</td> <td>12.90</td> <td>12.90</td> </tr> <tr> <td>CLASE TEXTURAL</td> <td>AF</td> <td>FA</td> </tr> <tr> <td>Conductividad k10 (m/día)</td> <td>6.80</td> <td>8.35</td> </tr> <tr> <td>%H gravimétrico a 0Bar</td> <td>158.88</td> <td>142.21</td> </tr> <tr> <td>%H gravimétrico a 0,3 Bar</td> <td>93.00</td> <td>87.68</td> </tr> <tr> <td>%H gravimétrico a 1 Bar</td> <td>89.63</td> <td>84.47</td> </tr> <tr> <td>%H gravimétrico a 5 Bar</td> <td>88.24</td> <td>83.15</td> </tr> <tr> <td>%H gravimétrico a 10 Bar</td> <td>85.11</td> <td>76.66</td> </tr> </tbody> </table>	Muestreo	H1	H2	Da (gr/cc)	0.60	0.55	%ARENAS	78.95	78.95	%ARCILLAS	8.15	8.15	%LIMOS	12.90	12.90	CLASE TEXTURAL	AF	FA	Conductividad k10 (m/día)	6.80	8.35	%H gravimétrico a 0Bar	158.88	142.21	%H gravimétrico a 0,3 Bar	93.00	87.68	%H gravimétrico a 1 Bar	89.63	84.47	%H gravimétrico a 5 Bar	88.24	83.15	%H gravimétrico a 10 Bar	85.11	76.66
Muestreo	H1	H2																																				
Da (gr/cc)	0.60	0.55																																				
%ARENAS	78.95	78.95																																				
%ARCILLAS	8.15	8.15																																				
%LIMOS	12.90	12.90																																				
CLASE TEXTURAL	AF	FA																																				
Conductividad k10 (m/día)	6.80	8.35																																				
%H gravimétrico a 0Bar	158.88	142.21																																				
%H gravimétrico a 0,3 Bar	93.00	87.68																																				
%H gravimétrico a 1 Bar	89.63	84.47																																				
%H gravimétrico a 5 Bar	88.24	83.15																																				
%H gravimétrico a 10 Bar	85.11	76.66																																				



%H gravimétrico a 15 Bar

85.10

76.12



Calicata S3-9

Coordenadas:	X: 1192069,69	Cobertura: Bosque		
	Y: 999447,079	Resultados de Laboratorio:		
Sistema de Coordenadas:	Magna-Sirgas Oeste	Muestreo	H1	H2
		Da (gr/cc)	0.52	0.60
		%ARENAS	77.57	75.95
		%ARCILLAS	6.64	5.05
		%LIMOS	15.79	19.00
		CLASE TEXTURAL	FA	FA



Conductividad k10 (m/día)	0.04	0.88
%H gravimétrico a 0Bar	149.87	154.46
%H gravimétrico a 0,3 Bar	125.52	118.79
%H gravimétrico a 1 Bar	121.51	114.80
%H gravimétrico a 5 Bar	119.82	112.88
%H gravimétrico a 10 Bar	116.82	108.80
%H gravimétrico a 15 Bar	115.10	107.77

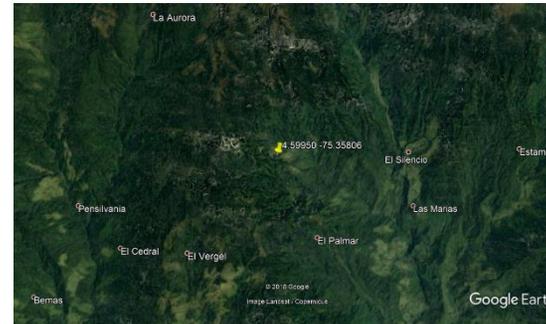


Calicata S4-2

Coordenadas:	X: 1190910,95	Cobertura: Bosque																																							
	Y: 1000538,32	Resultados de Laboratorio:																																							
Sistema de Coordenadas:	Magna-Sirgas Oeste																																								
		<table border="1"> <thead> <tr> <th>Muestreo</th> <th>H1</th> <th>H2</th> </tr> </thead> <tbody> <tr> <td>Da (gr/cc)</td> <td>0.48</td> <td>0.71</td> </tr> <tr> <td>%ARENAS</td> <td>86.95</td> <td>86.95</td> </tr> <tr> <td>%ARCILLAS</td> <td>5.05</td> <td>5.05</td> </tr> <tr> <td>%LIMOS</td> <td>8.00</td> <td>8.00</td> </tr> <tr> <td>CLASE TEXTURAL</td> <td>FA</td> <td>FA</td> </tr> <tr> <td>Conductividad k10 (m/día)</td> <td>4.13</td> <td>9.21</td> </tr> <tr> <td>%H gravimétrico a 0Bar</td> <td>176.27</td> <td>141.44</td> </tr> <tr> <td>%H gravimétrico a 0,3 Bar</td> <td>123.44</td> <td>107.44</td> </tr> <tr> <td>%H gravimétrico a 1 Bar</td> <td>118.07</td> <td>104.87</td> </tr> <tr> <td>%H gravimétrico a 5 Bar</td> <td>116.27</td> <td>103.30</td> </tr> <tr> <td>%H gravimétrico a 10 Bar</td> <td>108.66</td> <td>96.03</td> </tr> <tr> <td>%H gravimétrico a 15 Bar</td> <td>108.29</td> <td>96.02</td> </tr> </tbody> </table>	Muestreo	H1	H2	Da (gr/cc)	0.48	0.71	%ARENAS	86.95	86.95	%ARCILLAS	5.05	5.05	%LIMOS	8.00	8.00	CLASE TEXTURAL	FA	FA	Conductividad k10 (m/día)	4.13	9.21	%H gravimétrico a 0Bar	176.27	141.44	%H gravimétrico a 0,3 Bar	123.44	107.44	%H gravimétrico a 1 Bar	118.07	104.87	%H gravimétrico a 5 Bar	116.27	103.30	%H gravimétrico a 10 Bar	108.66	96.03	%H gravimétrico a 15 Bar	108.29	96.02
		Muestreo	H1	H2																																					
		Da (gr/cc)	0.48	0.71																																					
		%ARENAS	86.95	86.95																																					
		%ARCILLAS	5.05	5.05																																					
		%LIMOS	8.00	8.00																																					
		CLASE TEXTURAL	FA	FA																																					
		Conductividad k10 (m/día)	4.13	9.21																																					
		%H gravimétrico a 0Bar	176.27	141.44																																					
		%H gravimétrico a 0,3 Bar	123.44	107.44																																					
		%H gravimétrico a 1 Bar	118.07	104.87																																					
		%H gravimétrico a 5 Bar	116.27	103.30																																					
		%H gravimétrico a 10 Bar	108.66	96.03																																					
%H gravimétrico a 15 Bar	108.29	96.02																																							
																																									

Calicata S4-3				
Coordenadas:	X: 1191057,59	Cobertura: Bosque		
	Y: 1000495,53	Resultados de Laboratorio:		
Sistema de Coordenadas:	Magna-Sirgas Oeste			
		Muestreo	H1	H2
		Da (gr/cc)	0.37	0.46
		%ARENAS	84.21	79.50
		%ARCILLAS	7.21	5.05
		%LIMOS	8.57	15.45
		CLASE TEXTURAL	AF	AF
		Conductividad k10 (m/día)	4.48	0.20
		%H gravimétrico a 0Bar	204.31	102.61
		%H gravimétrico a 0,3 Bar	138.51	89.48
		%H gravimétrico a 1 Bar	133.38	87.61
		%H gravimétrico a 5 Bar	131.42	86.50
%H gravimétrico a 10 Bar	123.07	81.52		
%H gravimétrico a 15 Bar	122.89	81.51		
				

Calicata S4-4																																									
Coordenadas:	X: 1190824,23	Cobertura: Bosque																																							
	Y: 1000594,54	Resultados de Laboratorio:																																							
Sistema de Coordenadas:	Magna-Sirgas Oeste	<table border="1" style="width: 100%; border-collapse: collapse;"> <thead> <tr> <th style="text-align: center;">Muestreo</th> <th style="text-align: center;">H1</th> <th style="text-align: center;">H2</th> </tr> </thead> <tbody> <tr> <td style="text-align: center;">Da (gr/cc)</td> <td style="text-align: center;">0.23</td> <td style="text-align: center;">0.74</td> </tr> <tr> <td style="text-align: center;">%ARENAS</td> <td style="text-align: center;">79.73</td> <td style="text-align: center;">85.80</td> </tr> <tr> <td style="text-align: center;">%ARCILLAS</td> <td style="text-align: center;">10.95</td> <td style="text-align: center;">5.74</td> </tr> <tr> <td style="text-align: center;">%LIMOS</td> <td style="text-align: center;">9.32</td> <td style="text-align: center;">8.47</td> </tr> <tr> <td style="text-align: center;">CLASE TEXTURAL</td> <td style="text-align: center;">AF</td> <td style="text-align: center;">AF</td> </tr> <tr> <td style="text-align: center;">Conductividad k10 (m/día)</td> <td style="text-align: center;">1.62</td> <td style="text-align: center;">1.11</td> </tr> <tr> <td style="text-align: center;">%H gravimétrico a 0Bar</td> <td style="text-align: center;">302.54</td> <td style="text-align: center;">21.15</td> </tr> <tr> <td style="text-align: center;">%H gravimétrico a 0,3 Bar</td> <td style="text-align: center;">214.64</td> <td style="text-align: center;">11.19</td> </tr> <tr> <td style="text-align: center;">%H gravimétrico a 1 Bar</td> <td style="text-align: center;">208.54</td> <td style="text-align: center;">10.89</td> </tr> <tr> <td style="text-align: center;">%H gravimétrico a 5 Bar</td> <td style="text-align: center;">205.46</td> <td style="text-align: center;">10.72</td> </tr> <tr> <td style="text-align: center;">%H gravimétrico a 10 Bar</td> <td style="text-align: center;">195.11</td> <td style="text-align: center;">9.33</td> </tr> <tr> <td style="text-align: center;">%H gravimétrico a 15 Bar</td> <td style="text-align: center;">194.81</td> <td style="text-align: center;">7.78</td> </tr> </tbody> </table>	Muestreo	H1	H2	Da (gr/cc)	0.23	0.74	%ARENAS	79.73	85.80	%ARCILLAS	10.95	5.74	%LIMOS	9.32	8.47	CLASE TEXTURAL	AF	AF	Conductividad k10 (m/día)	1.62	1.11	%H gravimétrico a 0Bar	302.54	21.15	%H gravimétrico a 0,3 Bar	214.64	11.19	%H gravimétrico a 1 Bar	208.54	10.89	%H gravimétrico a 5 Bar	205.46	10.72	%H gravimétrico a 10 Bar	195.11	9.33	%H gravimétrico a 15 Bar	194.81	7.78
Muestreo	H1	H2																																							
Da (gr/cc)	0.23	0.74																																							
%ARENAS	79.73	85.80																																							
%ARCILLAS	10.95	5.74																																							
%LIMOS	9.32	8.47																																							
CLASE TEXTURAL	AF	AF																																							
Conductividad k10 (m/día)	1.62	1.11																																							
%H gravimétrico a 0Bar	302.54	21.15																																							
%H gravimétrico a 0,3 Bar	214.64	11.19																																							
%H gravimétrico a 1 Bar	208.54	10.89																																							
%H gravimétrico a 5 Bar	205.46	10.72																																							
%H gravimétrico a 10 Bar	195.11	9.33																																							
%H gravimétrico a 15 Bar	194.81	7.78																																							
 <p>The photograph shows a soil sample labeled 'S4-4' next to a white ruler marked in centimeters from 0 to 90. The soil is dark and appears to be a forest floor sample.</p>																																									



Calicata F01

Coordenadas:	X: 1152469,7621	Cobertura: Bosque de galería		
	Y: 1008132,6497	Resultados de Laboratorio:		
Sistema de Coordenadas:	Magna-Sirgas Oeste	Muestreo	H1	H2
		Da (gr/cc)	0.92	0.76
		%ARENAS	73.5	76.5
		%ARCILLAS	11.5	12.5
		%LIMOS	15	11
		CLASE TEXTURAL	AF	AF
		Conductividad k10 (m/día)	151.60	129.14
		%H gravimétrico a 0Bar	75.77	96.82
		%H gravimétrico a 0,3 Bar	58.96	78.93
		%H gravimétrico a 1 Bar	58.92	77.81
		%H gravimétrico a 5 Bar	55.87	72.89



%H gravimétrico a 10 Bar	48.67	62.21
%H gravimétrico a 15 Bar	47.93	60.98



Calicata F02

Coordenadas	X: 1152642,5121	Cobertura: Pastos
	Y: 1008216,7218	Resultados de Laboratorio:
Sistema de Coordenadas:	Magna-Sirgas Oeste	
		Muestreo
		H1
		H2
		Da (gr/cc)
		0.64882515
		0.75308025
		%ARENAS
		75.5
		81.5
		%ARCILLAS
		11.5
		11.5
		%LIMOS
		13
		7
		CLASE TEXTURAL
		AF
		AF
		Conductividad k10 (m/día)
		10.1068741
		0.96613169
		%H gravimétrico a 0Bar
		81.5414625
		75.2429374



%H gravimétrico a 0,3 Bar	66.5198415	66.0706994
%H gravimétrico a 1 Bar	45.9383334	65.3671751
%H gravimétrico a 5 Bar	57.6490524	61.824199
%H gravimétrico a 10 Bar	56.0551702	60.2215194
%H gravimétrico a 15 Bar	52.8334566	57.6220025



Calicata F03

Coordenadas:	X: 1153750,7507	Cobertura: Cultivo de Café		
	Y: 1008358,4911	Resultados de Laboratorio:		
Sistema de Coordenadas:	Magna-Sirgas Oeste	Muestreo	H1	H2
		Da (gr/cc)	0.64994381	0.62777636
		%ARENAS	72.5	78.5
		%ARCILLAS	11.5	9.5
		%LIMOS	16	12
		CLASE TEXTURAL	AF	AF
		Conductividad k10 (m/día)	38.87	1.38



%H gravimétrico a 0Bar	82.52	117.73
%H gravimétrico a 0,3 Bar	77.32	93.53
%H gravimétrico a 1 Bar	76.15	92.07
%H gravimétrico a 5 Bar	72.73	87.06
%H gravimétrico a 10 Bar	61.77	60.59
%H gravimétrico a 15 Bar	60.66	73.21



Calicata F04

Coordenadas:	X: 1153855,3974	Cobertura: Bosque		
	Y: 1008308,3678	Resultados de Laboratorio:		
Sistema de Coordenadas:	Magna-Sirgas Oeste	Muestreo	H1	H2
		Da (gr/cc)	0.58	0.66
		%ARENAS	70.95	80.5
		%ARCILLAS	12.5	7.5
		%LIMOS	16.55	12
		CLASE TEXTURAL	AF	AF



Conductividad k10 (m/día)	7.45	4.40
%H gravimétrico a 0Bar	46.36	217.85
%H gravimétrico a 0,3 Bar	22.63	175.53
%H gravimétrico a 1 Bar	21.68	174.97
%H gravimétrico a 5 Bar	18.26	167.72
%H gravimétrico a 10 Bar	9.42	148.51
%H gravimétrico a 15 Bar	8.25	146.72



Calicata F05

Coordenadas:	X: 1153966,8720	Cobertura: Pastos		
	Y: 1008341,5506	Resultados de Laboratorio:		
Sistema de Coordenadas:	Magna-Sirgas Oeste	Muestreo	H1	H2
		Da (gr/cc)	0.71	0.71
		%ARENAS	74.95	78.95
		%ARCILLAS	7.5	4.5
		%LIMOS	17.55	16.55



%LIMOS	19	16
CLASE TEXTURAL	AF	AF
Conductividad k10 (m/día)	0.15	0.68
%H gravimétrico a 0Bar	78.96	186.16
%H gravimétrico a 0,3 Bar	70.02	157.03
%H gravimétrico a 1 Bar	101.91	156.68
%H gravimétrico a 5 Bar	97.96	148.68
%H gravimétrico a 10 Bar	85.88	132.97
%H gravimétrico a 15 Bar	84.79	131.46



Calicata F07

Coordenadas:	X: 1164017,8535	Cobertura: Pastos, alto de ladera	
	Y: 1010884,9016	Resultados de Laboratorio:	
Sistema de Coordenadas:	Magna-Sirgas Oeste	Muestreo	H1 H2



Da (gr/cc)	0.69	0.48
%ARENAS	76.5	76.5
%ARCILLAS	6.5	6.5
%LIMOS	17	17
CLASE TEXTURAL	AF	AF
Conductividad k10 (m/día)	1.42	5.51
%H gravimétrico a 0Bar	136.53	84.03
%H gravimétrico a 0,3 Bar	127.18	69.54
%H gravimétrico a 1 Bar	126.46	69.36
%H gravimétrico a 5 Bar	122.07	65.96
%H gravimétrico a 10 Bar	108.76	52.91
%H gravimétrico a 15 Bar	107.21	51.88



Calicata F08

Coordenadas:	X: 1164051,4540	Cobertura: Bosque de galería, alto de ladera
	Y: 1010845,7028	Resultados de Laboratorio:

Sistema de
Coordenadas: Magna-Sirgas Oeste



Muestreo	H1	H2
Da (gr/cc)	0.63	0.58
%ARENAS	71.5	77.5
%ARCILLAS	7.5	6.5
%LIMOS	21	16
CLASE TEXTURAL	AF	AF
Conductividad k10 (m/día)	0.11	0.15
%H gravimétrico a 0Bar	117.62	116.63
%H gravimétrico a 0,3 Bar	105.54	102.29
%H gravimétrico a 1 Bar	104.33	101.33
%H gravimétrico a 5 Bar	99.76	97.74
%H gravimétrico a 10 Bar	88.30	86.06
%H gravimétrico a 15 Bar	86.48	84.95



Calicata F09

Coordenadas: X: 1163635,3426

Cobertura: Bosque de galería, pie de ladera

Y: 1010699,5831

Sistema de
Coordenadas: Magna-Sirgas Oeste



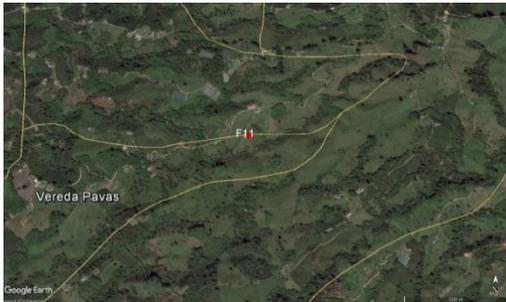
Resultados de Laboratorio:

Muestreo	H1	H2	H3
Da (gr/cc)	0.49	0.48	0.49
%ARENAS	76.5	79.5	77.5
%ARCILLAS	7.5	6.5	7.5
%LIMOS	16	14	15
CLASE TEXTURAL	AF	AF	AF
Conductividad k10 (m/día)	1.28	81.90	2.78
%H gravimétrico a 0Bar	166.61	161.69	176.54
%H gravimétrico a 0,3 Bar	140.73	140.56	149.30
%H gravimétrico a 1 Bar	138.09	138.97	148.83
%H gravimétrico a 5 Bar	131.72	132.44	141.00
%H gravimétrico a 10 Bar	116.18	113.64	121.63
%H gravimétrico a 15 Bar	113.71	111.82	120.22



Calicata F10

Coordenadas:	X: 1154980,9466 Y: 1007669,3605	Cobertura: Pastos, media ladera																																																																	
Sistema de Coordenadas:	Magna-Sirgas Oeste	Resultados de Laboratorio:																																																																	
		<table border="1"> <thead> <tr> <th>Muestreo</th> <th>A1</th> <th>AP</th> <th>BW1</th> <th>BW2</th> </tr> </thead> <tbody> <tr> <td>Da (gr/cc)</td> <td>0.58</td> <td>0.77</td> <td>0.62</td> <td>0.57</td> </tr> <tr> <td>%ARENAS</td> <td>71.5</td> <td>71.5</td> <td>74.5</td> <td>75.5</td> </tr> <tr> <td>%ARCILLAS</td> <td>8.5</td> <td>9.5</td> <td>7.5</td> <td>7.5</td> </tr> <tr> <td>%LIMOS</td> <td>20</td> <td>19</td> <td>18</td> <td>17</td> </tr> <tr> <td>CLASE TEXTURAL</td> <td>AF</td> <td>AF</td> <td>AF</td> <td>AF</td> </tr> <tr> <td>Conductividad k10 (m/día)</td> <td>15.25</td> <td>0.84</td> <td>2.71</td> <td>1.47</td> </tr> <tr> <td>%H gravimétrico a 0Bar</td> <td>129.82</td> <td>82.21</td> <td>110.97</td> <td>176.88</td> </tr> <tr> <td>%H gravimétrico a 0,3 Bar</td> <td>86.61</td> <td>69.87</td> <td>80.82</td> <td>88.26</td> </tr> <tr> <td>%H gravimétrico a 1 Bar</td> <td>69.00</td> <td>45.26</td> <td>37.18</td> <td>43.17</td> </tr> <tr> <td>%H gravimétrico a 5 Bar</td> <td>76.75</td> <td>34.31</td> <td>59.62</td> <td>60.43</td> </tr> <tr> <td>%H gravimétrico a 10 Bar</td> <td>75.44</td> <td>33.21</td> <td>58.24</td> <td>59.02</td> </tr> <tr> <td>%H gravimétrico a 15 Bar</td> <td>73.21</td> <td>31.37</td> <td>56.20</td> <td>56.44</td> </tr> </tbody> </table>	Muestreo	A1	AP	BW1	BW2	Da (gr/cc)	0.58	0.77	0.62	0.57	%ARENAS	71.5	71.5	74.5	75.5	%ARCILLAS	8.5	9.5	7.5	7.5	%LIMOS	20	19	18	17	CLASE TEXTURAL	AF	AF	AF	AF	Conductividad k10 (m/día)	15.25	0.84	2.71	1.47	%H gravimétrico a 0Bar	129.82	82.21	110.97	176.88	%H gravimétrico a 0,3 Bar	86.61	69.87	80.82	88.26	%H gravimétrico a 1 Bar	69.00	45.26	37.18	43.17	%H gravimétrico a 5 Bar	76.75	34.31	59.62	60.43	%H gravimétrico a 10 Bar	75.44	33.21	58.24	59.02	%H gravimétrico a 15 Bar	73.21	31.37	56.20	56.44
		Muestreo	A1	AP	BW1	BW2																																																													
		Da (gr/cc)	0.58	0.77	0.62	0.57																																																													
		%ARENAS	71.5	71.5	74.5	75.5																																																													
		%ARCILLAS	8.5	9.5	7.5	7.5																																																													
		%LIMOS	20	19	18	17																																																													
		CLASE TEXTURAL	AF	AF	AF	AF																																																													
		Conductividad k10 (m/día)	15.25	0.84	2.71	1.47																																																													
		%H gravimétrico a 0Bar	129.82	82.21	110.97	176.88																																																													
		%H gravimétrico a 0,3 Bar	86.61	69.87	80.82	88.26																																																													
		%H gravimétrico a 1 Bar	69.00	45.26	37.18	43.17																																																													
		%H gravimétrico a 5 Bar	76.75	34.31	59.62	60.43																																																													
		%H gravimétrico a 10 Bar	75.44	33.21	58.24	59.02																																																													
%H gravimétrico a 15 Bar	73.21	31.37	56.20	56.44																																																															
																																																																			

Calicata F11						
Coordenadas:	X: 1153262,2234	Cobertura: Pastos				
	Y: 1007042,2197	Resultados de Laboratorio:				
Sistema de Coordenadas:	Magna-Sirgas Oeste	Muestreo	HA1	HAP	HBW1	HBW2
		Da (gr/cc)	0.77	0.72	0.78	0.75
		%ARENAS	68.5	71.5	77.5	79.5
		%ARCILLAS	9.5	7.5	8.5	7.5
		%LIMOS	22	21	14	13
		CLASE TEXTURAL	FA	AF	AF	AF
		Conductividad k10 (m/día)	0.79	0.03	2.08	2.28
		%H gravimétrico a 0Bar	91.19	99.74	93.24	88.14
		%H gravimétrico a 0,3 Bar	76.05	82.09	69.42	65.01
		%H gravimétrico a 1 Bar	50.16	70.56	56.89	51.29
		%H gravimétrico a 5 Bar	70.04	77.87	65.40	62.14
%H gravimétrico a 10 Bar	67.33	74.24	64.23	60.61		
%H gravimétrico a 15 Bar	64.84	70.44	62.09	58.57		
						

Calicata F12					
Coordenadas:	X: 1153156,0601	Cobertura: Bosque de galería			
	Y: 1006959,4940	Resultados de Laboratorio:			
Sistema de Coordenadas:	Magna-Sirgas Oeste				
		Muestreo	HA	HBW	HC
		Da (gr/cc)	0.69	0.85	0.78
		%ARENAS	69.5	73.5	77.5
		%ARCILLAS	12.5	11.5	9.5
		%LIMOS	18	15	13
		CLASE TEXTURAL	FA	AF	AF
		Conductividad k10 (m/día)	9.66	1.09	0.19
		%H gravimétrico a 0Bar	105.52	82.17	92.48
		%H gravimétrico a 0,3 Bar	80.61	68.16	76.41
		%H gravimétrico a 1 Bar	60.26	54.82	41.95
		%H gravimétrico a 5 Bar	71.29	62.32	56.73
		%H gravimétrico a 10 Bar	69.78	60.76	55.67
		%H gravimétrico a 15 Bar	64.54	58.14	54.05



Calicata F13

Coordenadas:	X: 1152385,2458	Cobertura: Pastos				
	Y: 1004737,6439	Resultados de Laboratorio:				
Sistema de Coordenadas:	Magna-Sirgas Oeste	Muestreo	HAP	HAB	HBW1	HBW2
		Da (gr/cc)	0.71	0.58	0.57	0.57
		%ARENAS	73.5	77.5	77.5	85.5
		%ARCILLAS	9.5	7.5	8.5	6.5
		%LIMOS	17	15	14	8
		CLASE TEXTURAL	AF	AF	AF	AF
		Conductividad k10 (m/día)	0.12	3.50	1.69	6.91
		%H gravimétrico a 0Bar	96.41	139.36	138.00	172.17
		%H gravimétrico a 0,3 Bar	84.24	119.48	121.99	147.89
		%H gravimétrico a 1 Bar	66.55	62.05	65.79	77.93
		%H gravimétrico a 5 Bar	64.89	59.34	63.03	74.89
		%H gravimétrico a 10 Bar	61.48	54.62	57.53	69.12
		%H gravimétrico a 15 Bar	60.30	53.19	56.04	67.27



Calicata F14

Coordenadas:	X: 1155052,0744	Cobertura: Cultivo de Café				
	Y: 1005826,8818	Resultados de Laboratorio:				
Sistema de Coordenadas:	Magna-Sirgas Oeste	Muestreo	HAP	HAB	HBW1	HBW2
		Da (gr/cc)	0.62	0.80	0.90	0.81
		%ARENAS	77.5	84.5	69.5	82.5
		%ARCILLAS	7.5	6.5	6.5	5.5
		%LIMOS	15	9	24	12
		CLASE TEXTURAL	A	AF	FA	AF
		Conductividad k10 (m/día)	28.88	10.99	0.74	0.02
		%H gravimétrico a 0Bar	106.64	86.48	76.49	85.06



%H gravimétrico a 0,3 Bar	91.30	75.11	69.31	77.25
%H gravimétrico a 1 Bar	67.80	58.25	55.45	66.38
%H gravimétrico a 5 Bar	65.40	56.37	53.71	64.52
%H gravimétrico a 10 Bar	64.78	53.08	50.93	61.18
%H gravimétrico a 15 Bar	60.38	51.89	49.79	59.88



Calicata F15

Coordenadas:	X: 1155971,6026	Cobertura: Pastos				
	Y: 1007174,2265	Resultados de Laboratorio:				
Sistema de Coordenadas:	Magna-Sirgas Oeste	Muestreo	HA1	HAP	HAB	HBW
		Da (gr/cc)	0.63	0.60	0.65	0.67
		%ARENAS	84.5	70.5	69.5	81.5
		%ARCILLAS	8.5	9.5	6.5	7.5
		%LIMOS	7	20	24	11
		CLASE TEXTURAL	AF	AF	FA	AF
		Conductividad k10 (m/día)	5.14	0.39	2.35	2.53



%H gravimétrico a 0Bar	121.50	172.50	127.70	105.46
%H gravimétrico a 0,3 Bar	111.86	138.23	108.36	94.38
%H gravimétrico a 1 Bar	98.59	122.970016	73.86	69.19
%H gravimétrico a 5 Bar	96.32	119.92	71.12	65.99
%H gravimétrico a 10 Bar	92.99	116.66	65.76	61.63
%H gravimétrico a 15 Bar	91.47	114.96	64.28	60.18



Calicata F16

Coordenadas:	X: 1161188,0145	Cobertura: Pastos				
	Y: 1010158,1950	Resultados de Laboratorio:				
Sistema de Coordenadas:	Magna-Sirgas Oeste	Muestreo	HA1	HAP	HBW1	HBW2
		Da (gr/cc)	0.45	0.57	0.47	0.42
		%ARENAS	67.5	81.5	79.5	84.5
		%ARCILLAS	10.5	7.5	7.5	6.5
		%LIMOS	22	11	13	9



CLASE TEXTURAL	FA	AF	AF	AF
Conductividad k10 (m/día)	15.63	4.13	18.42	8.18
%H gravimétrico a 0Bar	169.54	124.27	181.70	206.14
%H gravimétrico a 0,3 Bar	138.90	108.54	156.41	122.86
%H gravimétrico a 1 Bar	96.94	89.23	109.41	112.23
%H gravimétrico a 5 Bar	92.55	87.36	103.80	108.20
%H gravimétrico a 10 Bar	87.74	85.42	97.02	
%H gravimétrico a 15 Bar	85.99	83.96	94.80	104.98



Calicata F17

Coordenadas:	X: 1161156,1753	Cobertura: Bosque																				
	Y: 1010205,1415																					
Sistema de Coordenadas:	Magna-Sirgas Oeste	Resultados de Laboratorio:																				
		<table border="1"> <thead> <tr> <th>Muestreo</th> <th>HA</th> <th>HBW1</th> <th>HBW2</th> <th>HBW3</th> </tr> </thead> <tbody> <tr> <td>Da (gr/cc)</td> <td>0.63</td> <td>0.54</td> <td>0.56</td> <td>0.51</td> </tr> <tr> <td>%ARENAS</td> <td>79.5</td> <td>79.5</td> <td>80.5</td> <td>85.5</td> </tr> <tr> <td>%ARCILLAS</td> <td>7.5</td> <td>8.5</td> <td>6.5</td> <td>5.5</td> </tr> </tbody> </table>	Muestreo	HA	HBW1	HBW2	HBW3	Da (gr/cc)	0.63	0.54	0.56	0.51	%ARENAS	79.5	79.5	80.5	85.5	%ARCILLAS	7.5	8.5	6.5	5.5
Muestreo	HA	HBW1	HBW2	HBW3																		
Da (gr/cc)	0.63	0.54	0.56	0.51																		
%ARENAS	79.5	79.5	80.5	85.5																		
%ARCILLAS	7.5	8.5	6.5	5.5																		



%LIMOS	13	12	13	9
CLASE TEXTURAL	AF	AF	AF	AF
Conductividad k10 (m/día)	3.86	88.43	3.40	
%H gravimétrico a 0Bar	133.75	118.39	154.32	181.06
%H gravimétrico a 0,3 Bar	110.04	93.11	108.51	123.81
%H gravimétrico a 1 Bar	103.82	89.22	97.55	116.88
%H gravimétrico a 5 Bar	102.71	86.33	92.93	112.17
%H gravimétrico a 10 Bar				
%H gravimétrico a 15 Bar	97.36	83.98	96.09	108.87

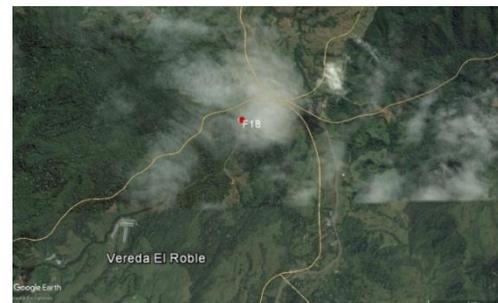


Calicata F18

Coordenadas:	X: 1163276,6633	Cobertura: Rastrojo, antigua pinera			
	Y: 1008728,2726		Resultados de Laboratorio:		
Sistema de Coordenadas:	Magna-Sirgas Oeste				
		Muestreo	HA	HAC	HC
		Da (gr/cc)	1.01	1.25	0.94
		%ARENAS	72.5	82.5	81.5



%ARCILLAS	10.5	6.5	6.5
%LIMOS	17	11	12
CLASE TEXTURAL	AF	AF	AF
Conductividad k10 (m/día)	2.66	13.29	1.05
%H gravimétrico a 0Bar	67.76	48.24	69.34
%H gravimétrico a 0,3 Bar	40.51	27.75	29.29
%H gravimétrico a 1 Bar	37.71	22.00	42.88
%H gravimétrico a 5 Bar	36.00	19.97	41.06
%H gravimétrico a 10 Bar			
%H gravimétrico a 15 Bar	34.50	18.76	39.67



Calicata F19

Coordenadas:	X: 1162797,2099	Cobertura: Rastrojo alto			
	Y: 1008028,1639	Resultados de Laboratorio:			
Sistema de Coordenadas:	Magna-Sirgas Oeste	Muestreo	HAP	HBW1	HBW2



Da (gr/cc)	0.94	0.66	0.73
%ARENAS	80.95	85.95	86.95
%ARCILLAS	7.05	7.05	9.05
%LIMOS	12	7	4
CLASE TEXTURAL	AF	A	A
Conductividad k10 (m/día)	8.68	9.28	0.49
%H gravimétrico a 0Bar	104.82	112.41	99.56
%H gravimétrico a 0,3 Bar	58.57	90.523	85.54
%H gravimétrico a 1 Bar	78.56	72.38	69.34
%H gravimétrico a 5 Bar	76.14	70.00	66.52
%H gravimétrico a 10 Bar			
%H gravimétrico a 15 Bar	74.25	68.01	64.43



Calicata F20

Coordenadas:	X: 1162274,6782	Cobertura: Bosque, reserva forestal
	Y: 1008559,2595	Resultados de Laboratorio:

Sistema de
Coordenadas: Magna-Sirgas Oeste



Muestreo	HA1	HA2	HBW1	HBW2
Da (gr/cc)	0.51	0.57	0.57	0.53
%ARENAS	81.95	79.95	84.95	89.95
%ARCILLAS	7.05	6.05	6.05	5.05
%LIMOS	11	14	9	5
CLASE TEXTURAL	AF	AF	AF	A
Conductividad k10 (m/día)	35.09	4.51	0.93	1.26
%H gravimétrico a 0Bar	125.43	153.70	142.97	148.07
%H gravimétrico a 0,3 Bar	92.98	87.50	96.16	105.45
%H gravimétrico a 1 Bar	86.79	80.74	90.61	99.45
%H gravimétrico a 5 Bar	83.04	76.17	86.78	95.28
%H gravimétrico a 10 Bar	80.52	72.44	83.37	93.19
%H gravimétrico a 15 Bar	79.81	71.40	82.70	092.25



Calicata F21

Coordenadas: X: 1159753,0387

Cobertura: Bosque El Silencio

Y: 1005129,5835

Sistema de
Coordenadas: Magna-Sirgas Oeste

Resultados de Laboratorio:

Muestreo	HA1	HA2	HBW
Da (gr/cc)	0.52	0.61	0.58
%ARENAS	85.95	83.95	85.95
%ARCILLAS	7.05	7.05	5.05
%LIMOS	7	9	9
CLASE TEXTURAL	A	AF	AF
Conductividad k10 (m/día)	6.32	15.81	6.72
%H gravimétrico a 0Bar	101.93	96.70	73.23
%H gravimétrico a 0,3 Bar	79.21	66.27	57.67
%H gravimétrico a 1 Bar	60.1344236	56.39	54.56
%H gravimétrico a 5 Bar	57.12	53.94	49.88
%H gravimétrico a 10 Bar			
%H gravimétrico a 15 Bar	55.22	52.16	50.49



Calicata F22

Coordenadas:	X: 1156476,3793	Cobertura: Cultivo de Café			
	Y: 1003383,8959	Resultados de Laboratorio:			
Sistema de Coordenadas:	Magna-Sirgas Oeste	Muestreo	HA1	HA2	HAP
		Da (gr/cc)	0.69	0.67	0.73
		%ARENAS	76.95	76.95	76.95
		%ARCILLAS	7.05	5.05	8.05
		%LIMOS	16	18	15
		CLASE TEXTURAL	AF	AF	AF
		Conductividad k10 (m/día)	0.57	0.28	3.47
		%H gravimétrico a 0Bar	102.74	109.47	123.39
		%H gravimétrico a 0,3 Bar	78.94	80.89	94.73
		%H gravimétrico a 1 Bar	73.55	73.67	86.06
		%H gravimétrico a 5 Bar	70.29	71.38	82.01
		%H gravimétrico a 10 Bar		71.61	80.33
		%H gravimétrico a 15 Bar	69.00	67.92	79.58
					

Calicata F23

Coordenadas:	X: 1156910,3400	Cobertura: Cultivo de Café
	Y: 1003172,3769	Resultados de Laboratorio:

Sistema de Coordenadas:	Magna-Sirgas Oeste
----------------------------	--------------------



Muestreo	HA1	HAP	HBW
Da (gr/cc)	0.73	0.65	0.90
%ARENAS	79.95	77.95	86.2
%ARCILLAS	8.05	6.05	6.05
%LIMOS	12	16	7.75
CLASE TEXTURAL	AF	AF	A
Conductividad k10 (m/día)	2.19	9.24	0.10
%H gravimétrico a 0Bar	104.01	107.93	69.68
%H gravimétrico a 0,3 Bar	70.50	64.56	54.61
%H gravimétrico a 1 Bar	66.51	58.82	50.93
%H gravimétrico a 5 Bar	63.44	52.56	48.76
%H gravimétrico a 10 Bar	60.99	52.17	47.29
%H gravimétrico a 15 Bar	60.53	51.71	46.84



Calicata F24

Coordenadas:		X: 1155917,9591	Cobertura: Cultivo de Café y Guadua			
		Y: 1002323,6512	Resultados de Laboratorio:			
Sistema de Coordenadas:	Magna-Sirgas Oeste		Muestreo	HA1	HAP	HBW
			Da (gr/cc)	0.71	0.60	0.56
			%ARENAS	76.2	75.2	83.2
			%ARCILLAS	7.05	8.05	5.05
			%LIMOS	16.75	16.75	11.75
			CLASE TEXTURAL	AF	AF	AF
			Conductividad k10 (m/día)	11.76	28.79	6.46
			%H gravimétrico a 0Bar	130.53	103.88	124.19
			%H gravimétrico a 0,3 Bar	68.17	66.61	72.19
			%H gravimétrico a 1 Bar	58.83	62.26	68.09
			%H gravimétrico a 5 Bar	55.05	59.19	64.56
			%H gravimétrico a 10 Bar	49.82	55.93	61.87
			%H gravimétrico a 15 Bar	48.72	55.51	61.12



Calicata F26

Coordenadas:	X: 1145883,7729	Cobertura: Potrero, pastos			
	Y: 951200,42226	Resultados de Laboratorio:			
Sistema de Coordenadas:	Magna-Sirgas Oeste	Muestreo	H1	H2	H3
		Da (gr/cc)	0.79	1.05	1.15
		%ARENAS	70.00	66.00	69.50
		%ARCILLAS	7.00	9.00	7.00
		%LIMOS	23.00	25.00	23.50
		CLASE TEXTURAL	FA	FA	FA
		Conductividad k10 (m/día)	0.92	0.94	0.71
		%H gravimétrico a 0Bar	74.85	51.29	48.06



%H gravimétrico a 0,3 Bar	59.01	33.44	33.91
%H gravimétrico a 1 Bar	51.74	28.28	30.36
%H gravimétrico a 5 Bar	50.67	27.41	29.57
%H gravimétrico a 10 Bar	28.64	9.24	13.52
%H gravimétrico a 15 Bar	26.22	7.10	11.43



Calicata F27

Coordenadas:	X: 1145866,6700	Cobertura: Bosque
	Y: 951133,4751	Resultados de Laboratorio:
Sistema de Coordenadas:	Magna-Sirgas Oeste	
		Muestreo
		H0
		Da (gr/cc) 0.89
		%ARENAS 82.50
		%ARCILLAS 7.00
		%LIMOS 10.50
		CLASE TEXTURAL FA
		Conductividad k10 (m/día) 2.44



%H gravimétrico a 0Bar	65.07
%H gravimétrico a 0,3 Bar	35.01
%H gravimétrico a 1 Bar	29.61
%H gravimétrico a 5 Bar	28.31
%H gravimétrico a 10 Bar	12.35
%H gravimétrico a 15 Bar	9.39



Calicata F28

Coordenadas:	X: 1146927,2858	Cobertura: Bosque El Jardín, reserva forestal CRQ		
	Y: 951926,4349	Resultados de Laboratorio:		
Sistema de Coordenadas:	Magna-Sirgas Oeste			
		Muestreo	H1	H2
		Da (gr/cc)	0.94	1.00
		%ARENAS	76.50	85.50
		%ARCILLAS	7.00	7.00
		%LIMOS	16.50	7.50
		CLASE TEXTURAL	AF	FA



Conductividad k10 (m/día)	1.89	5.72
%H gravimétrico a 0Bar	77.73	60.81
%H gravimétrico a 0,3 Bar	43.26	36.70
%H gravimétrico a 1 Bar	37.33	31.87
%H gravimétrico a 5 Bar	36.29	30.77
%H gravimétrico a 10 Bar	18.40	13.61
%H gravimétrico a 15 Bar	15.40	11.22



Calicata F29

Coordenadas:	X: 1146621,0263	Cobertura: Bosque El Jardín, reserva forestal CRQ																																							
	Y: 952036,4213	Resultados de Laboratorio:																																							
Sistema de Coordenadas:	Magna-Sirgas Oeste																																								
		<table border="1"> <thead> <tr> <th>Muestreo</th> <th>H1</th> <th>H2</th> </tr> </thead> <tbody> <tr> <td>Da (gr/cc)</td> <td>0.38</td> <td>0.40</td> </tr> <tr> <td>%ARENAS</td> <td>85.50</td> <td>77.50</td> </tr> <tr> <td>%ARCILLAS</td> <td>7.00</td> <td>7.00</td> </tr> <tr> <td>%LIMOS</td> <td>7.50</td> <td>15.50</td> </tr> <tr> <td>CLASE TEXTURAL</td> <td>AF</td> <td>AF</td> </tr> <tr> <td>Conductividad k10 (m/día)</td> <td>4.34</td> <td>3.94</td> </tr> <tr> <td>%H gravimétrico a 0Bar</td> <td>168.33</td> <td>181.90</td> </tr> <tr> <td>%H gravimétrico a 0,3 Bar</td> <td>90.16</td> <td>102.07</td> </tr> <tr> <td>%H gravimétrico a 1 Bar</td> <td>79.06</td> <td>88.65</td> </tr> <tr> <td>%H gravimétrico a 5 Bar</td> <td>77.51</td> <td>86.79</td> </tr> <tr> <td>%H gravimétrico a 10 Bar</td> <td>50.22</td> <td>52.41</td> </tr> <tr> <td>%H gravimétrico a 15 Bar</td> <td>44.81</td> <td>46.89</td> </tr> </tbody> </table>	Muestreo	H1	H2	Da (gr/cc)	0.38	0.40	%ARENAS	85.50	77.50	%ARCILLAS	7.00	7.00	%LIMOS	7.50	15.50	CLASE TEXTURAL	AF	AF	Conductividad k10 (m/día)	4.34	3.94	%H gravimétrico a 0Bar	168.33	181.90	%H gravimétrico a 0,3 Bar	90.16	102.07	%H gravimétrico a 1 Bar	79.06	88.65	%H gravimétrico a 5 Bar	77.51	86.79	%H gravimétrico a 10 Bar	50.22	52.41	%H gravimétrico a 15 Bar	44.81	46.89
		Muestreo	H1	H2																																					
		Da (gr/cc)	0.38	0.40																																					
		%ARENAS	85.50	77.50																																					
		%ARCILLAS	7.00	7.00																																					
		%LIMOS	7.50	15.50																																					
		CLASE TEXTURAL	AF	AF																																					
		Conductividad k10 (m/día)	4.34	3.94																																					
		%H gravimétrico a 0Bar	168.33	181.90																																					
		%H gravimétrico a 0,3 Bar	90.16	102.07																																					
		%H gravimétrico a 1 Bar	79.06	88.65																																					
		%H gravimétrico a 5 Bar	77.51	86.79																																					
		%H gravimétrico a 10 Bar	50.22	52.41																																					
		%H gravimétrico a 15 Bar	44.81	46.89																																					



Calicata F30

Coordenadas:	X: 1146552,1859	Cobertura: Potrero, pastos		
	Y: 952359,2864	Resultados de Laboratorio:		
Sistema de Coordenadas:	Magna-Sirgas Oeste	Muestreo	H1	H2
		Da (gr/cc)	0.51	0.58
		%ARENAS	76.00	63.00
		%ARCILLAS	10.00	8.00
		%LIMOS	14.00	29.00
		CLASE TEXTURAL	FA	FA
		Conductividad k10 (m/día)	5.26	6.34
		%H gravimétrico a 0Bar	137.36	101.42
		%H gravimétrico a 0,3 Bar	59.88	75.58



%H gravimétrico a 1 Bar	47.44	66.44
%H gravimétrico a 5 Bar	45.93	64.99
%H gravimétrico a 10 Bar	25.35	36.69
%H gravimétrico a 15 Bar	20.93	33.21



Calicata F31

Coordenadas:	X: 1145854,9708	Cobertura: Bosque en recuperación												
	Y: 953224,7474	Resultados de Laboratorio:												
Sistema de Coordenadas:	Magna-Sirgas Oeste	<table border="1"> <thead> <tr> <th>Muestreo</th> <th>H1</th> <th>H2</th> </tr> </thead> <tbody> <tr> <td>Da (gr/cc)</td> <td>0.79</td> <td>0.65</td> </tr> <tr> <td>%ARENAS</td> <td>83.00</td> <td>65.00</td> </tr> <tr> <td>%ARCILLAS</td> <td>7.00</td> <td>13.00</td> </tr> </tbody> </table>	Muestreo	H1	H2	Da (gr/cc)	0.79	0.65	%ARENAS	83.00	65.00	%ARCILLAS	7.00	13.00
Muestreo	H1	H2												
Da (gr/cc)	0.79	0.65												
%ARENAS	83.00	65.00												
%ARCILLAS	7.00	13.00												



%LIMOS	10.00	22.00
CLASE TEXTURAL	FA	AF
Conductividad k10 (m/día)	0.41	1.39
%H gravimétrico a 0Bar	103.52	116.00
%H gravimétrico a 0,3 Bar	62.26	75.28
%H gravimétrico a 1 Bar	55.35	68.04
%H gravimétrico a 5 Bar	53.16	66.45
%H gravimétrico a 10 Bar	42.88	58.97
%H gravimétrico a 15 Bar	39.42	54.39



Calicata F32

Coordenadas:	X: 1144486,6588	Cobertura: Cultivo de plátano, aguacate y café		
	Y: 954899,5274	Resultados de Laboratorio:		
Sistema de Coordenadas:	Magna-Sirgas Oeste	Muestreo	H1	H2
		Da (gr/cc)	1.34	1.16
		%ARENAS	66.00	70.00
		%ARCILLAS	10.00	7.00
		%LIMOS	24.00	23.00
		CLASE TEXTURAL	FA	FA
		Conductividad k10 (m/día)	6.01	6.87
		%H gravimétrico a 0Bar	38.09	50.45
		%H gravimétrico a 0,3 Bar	26.53	30.23



%H gravimétrico a 1 Bar	21.50	26.59
%H gravimétrico a 5 Bar	21.28	26.19
%H gravimétrico a 10 Bar	19.37	23.42
%H gravimétrico a 15 Bar	17.42	20.77



Calicata F33

Coordenadas:	X: 1144040,0014	Cobertura: Cultivo de café			
	Y: 954093,9986	Resultados de Laboratorio:			
Sistema de Coordenadas:	Magna-Sirgas Oeste	Muestreo	H1	H2	H3
		Da (gr/cc)	1.13	1.27	1.23
		%ARENAS	59.00	60.00	65.00
		%ARCILLAS	18.65	18.65	18.65



%LIMOS	22.35	21.35	16.35
CLASE TEXTURAL	FA	FA	FA
Conductividad k10 (m/día)	1.10	0.58	0.42
%H gravimétrico a 0Bar	47.45	53.25	55.24
%H gravimétrico a 0,3 Bar	32.97	33.45	32.82
%H gravimétrico a 1 Bar	29.19	29.47	28.35
%H gravimétrico a 5 Bar	28.35	28.39	26.80
%H gravimétrico a 10 Bar	24.44	24.57	21.88
%H gravimétrico a 15 Bar	22.13	22.26	19.23



Calicata F34

Coordenadas:	X: 1143764,6324	Cobertura: Potrero, pastos	
	Y: 954875,1050	Resultados de Laboratorio:	
Sistema de Coordenadas:	Magna-Sirgas Oeste	Muestreo	H1 H2



Da (gr/cc)	1.29	1.65
%ARENAS	73.00	71.35
%ARCILLAS	10.65	14.65
%LIMOS	16.35	14.00
CLASE TEXTURAL	FA	FA
Conductividad k10 (m/día)	0.08	0.26
%H gravimétrico a 0Bar	44.34	22.86
%H gravimétrico a 0,3 Bar	33.31	11.30
%H gravimétrico a 1 Bar	29.46	8.20
%H gravimétrico a 5 Bar	28.30	7.72
%H gravimétrico a 10 Bar	22.65	5.60
%H gravimétrico a 15 Bar	20.83	4.21



Calicata F35

Coordenadas:		X: 1142945,3857	Cobertura: Bocatoma Acueducto Génova, bosque
		Y: 955828,0855	Resultados de Laboratorio:
Sistema de Coordenadas:	Magna-Sirgas Oeste		
			Muestreo
			H0
			Da (gr/cc)
			1.25
			%ARENAS
			77.35
			%ARCILLAS
			11.65
			%LIMOS
			11.00
			CLASE TEXTURAL
			FA
			Conductividad k10 (m/día)
			5.21
			%H gravimétrico a 0Bar
			29.24
			%H gravimétrico a 0,3 Bar
			24.91
			%H gravimétrico a 1 Bar
			16.36
			%H gravimétrico a 5 Bar
			15.73
			%H gravimétrico a 10 Bar
			13.29
			%H gravimétrico a 15 Bar
			11.97



Calicata F36

Coordenadas:	X: 1151585,5348 Y: 971795,6322	Cobertura: Bosque																					
Sistema de Coordenadas:	Magna-Sirgas Oeste	Resultados de Laboratorio:																					
		<table border="1"> <thead> <tr> <th>Muestreo</th> <th>H1</th> <th>H2</th> </tr> </thead> <tbody> <tr> <td>Da (gr/cc)</td> <td>1.49</td> <td>0.88</td> </tr> <tr> <td>%ARENAS</td> <td>72.35</td> <td>83.35</td> </tr> <tr> <td>%ARCILLAS</td> <td>11.65</td> <td>11.65</td> </tr> <tr> <td>%LIMOS</td> <td>16.00</td> <td>5.00</td> </tr> <tr> <td>CLASE TEXTURAL</td> <td>FA</td> <td>FA</td> </tr> <tr> <td>Conductividad k10 (m/día)</td> <td>7.09</td> <td>2.52</td> </tr> </tbody> </table>	Muestreo	H1	H2	Da (gr/cc)	1.49	0.88	%ARENAS	72.35	83.35	%ARCILLAS	11.65	11.65	%LIMOS	16.00	5.00	CLASE TEXTURAL	FA	FA	Conductividad k10 (m/día)	7.09	2.52
Muestreo	H1	H2																					
Da (gr/cc)	1.49	0.88																					
%ARENAS	72.35	83.35																					
%ARCILLAS	11.65	11.65																					
%LIMOS	16.00	5.00																					
CLASE TEXTURAL	FA	FA																					
Conductividad k10 (m/día)	7.09	2.52																					



%H gravimétrico a 0 Bar	32.54	45.48
%H gravimétrico a 0,3 Bar	17.33	28.25
%H gravimétrico a 1 Bar	16.95	28.15
%H gravimétrico a 5 Bar	16.85	27.88
%H gravimétrico a 10 Bar	14.99	25.83
%H gravimétrico a 15 Bar	12.76	22.96



Calicata F37

Coordenadas:	X: 1151514,8584	Cobertura: Potrero, pastos
	Y: 972566,5826	Resultados de Laboratorio:

Sistema de Magna-Sirgas Oeste
 Coordenadas:



Muestreo	H1	H2
Da (gr/cc)	0.83	1.24
%ARENAS	79.35	70.35
%ARCILLAS	16.65	9.65
%LIMOS	4.00	20.00
CLASE TEXTURAL	FA	FA
Conductividad k10 (m/día)	3.26	5.48
%H gravimétrico a 0Bar	21.23	53.00
%H gravimétrico a 0,3 Bar	11.87	36.76
%H gravimétrico a 1 Bar	11.64	36.31
%H gravimétrico a 5 Bar	11.40	35.88
%H gravimétrico a 10 Bar	9.71	33.65
%H gravimétrico a 15 Bar	8.16	31.21



Calicata F38

Coordenadas:	X: 1154314,0633	Cobertura: Bosque riveraño
	Y: 970848,6593	Resultados de Laboratorio:
Sistema de Coordenadas:	Magna-Sirgas Oeste	
		Muestreo
		H0
		Da (gr/cc)
		1.44
		%ARENAS
		70.35
		%ARCILLAS
		9.65
		%LIMOS
		20.00
		CLASE TEXTURAL
		FA
		Conductividad k10 (m/día)
		0.43
		%H gravimétrico a 0Bar
		29.27
		%H gravimétrico a 0,3 Bar
		17.40
		%H gravimétrico a 1 Bar
		17.19
		%H gravimétrico a 5 Bar
		17.15
		%H gravimétrico a 10 Bar
		15.62
		%H gravimétrico a 15 Bar
		13.72



Calicata F39

Coordenadas:	X: 1154416,1017	Cobertura: Potrero, pastos																					
	Y: 970729,8264	Resultados de Laboratorio:																					
Sistema de Coordenadas:	Magna-Sirgas Oeste	<table border="1"> <thead> <tr> <th>Muestreo</th> <th>H1</th> <th>H2</th> </tr> </thead> <tbody> <tr> <td>Da (gr/cc)</td> <td>0.94</td> <td>1.16</td> </tr> <tr> <td>%ARENAS</td> <td>80.35</td> <td>78.35</td> </tr> <tr> <td>%ARCILLAS</td> <td>10.65</td> <td>11.65</td> </tr> <tr> <td>%LIMOS</td> <td>9.00</td> <td>10.00</td> </tr> <tr> <td>CLASE TEXTURAL</td> <td>FA</td> <td>FA</td> </tr> <tr> <td>Conductividad k10 (m/día)</td> <td>1.80</td> <td>3.76</td> </tr> </tbody> </table>	Muestreo	H1	H2	Da (gr/cc)	0.94	1.16	%ARENAS	80.35	78.35	%ARCILLAS	10.65	11.65	%LIMOS	9.00	10.00	CLASE TEXTURAL	FA	FA	Conductividad k10 (m/día)	1.80	3.76
Muestreo	H1	H2																					
Da (gr/cc)	0.94	1.16																					
%ARENAS	80.35	78.35																					
%ARCILLAS	10.65	11.65																					
%LIMOS	9.00	10.00																					
CLASE TEXTURAL	FA	FA																					
Conductividad k10 (m/día)	1.80	3.76																					



%H gravimétrico a 0 Bar	29.29	29.73
%H gravimétrico a 0,3 Bar	17.71	19.99
%H gravimétrico a 1 Bar	17.07	19.60
%H gravimétrico a 5 Bar	16.10	18.56
%H gravimétrico a 10 Bar	13.12	15.92
%H gravimétrico a 15 Bar	11.36	14.10



Calicata F40

Coordenadas:	X: 1154623,8968	Cobertura: Potrero, pastos
	Y: 970342,1754	Resultados de Laboratorio:

Sistema de Magna-Sirgas Oeste
 Coordenadas:



Muestreo	H1	H2
Da (gr/cc)	0.73	0.67
%ARENAS	80.35	70.35
%ARCILLAS	9.65	13.65
%LIMOS	10.00	16.00
CLASE TEXTURAL	FA	FA
Conductividad k10 (m/día)	5.72	1.14
%H gravimétrico a 0Bar	57.68	82.33
%H gravimétrico a 0,3 Bar	36.43	48.16
%H gravimétrico a 1 Bar	35.89	48.16
%H gravimétrico a 5 Bar	35.45	47.49
%H gravimétrico a 10 Bar	32.40	44.63
%H gravimétrico a 15 Bar	28.98	40.65



Calicata F41

Coordenadas: X: 1155013,0890

Cobertura: Bosque riverero

Y: 970520,0933

Sistema de
Coordenadas: Magna-Sirgas Oeste



Resultados de Laboratorio:

Muestreo	H0
Da (gr/cc)	1.59
%ARENAS	70.35
%ARCILLAS	23.65
%LIMOS	6.00
CLASE TEXTURAL	FArA
Conductividad k10 (m/día)	6.66
%H gravimétrico a 0Bar	91.64
%H gravimétrico a 0,3 Bar	58.97
%H gravimétrico a 1 Bar	58.62
%H gravimétrico a 5 Bar	58.48
%H gravimétrico a 10 Bar	55.46
%H gravimétrico a 15 Bar	51.54



Calicata F42

Coordenadas:	X: 1150967,2898 Y: 971676,1644	Cobertura: Bosque de alta montaña																										
Sistema de Coordenadas:	Magna-Sirgas Oeste	Resultados de Laboratorio:																										
		<table border="1"> <thead> <tr> <th>Muestreo</th> <th>H0</th> </tr> </thead> <tbody> <tr> <td>Da (gr/cc)</td> <td>1.71</td> </tr> <tr> <td>%ARENAS</td> <td>70.35</td> </tr> <tr> <td>%ARCILLAS</td> <td>21.65</td> </tr> <tr> <td>%LIMOS</td> <td>8.00</td> </tr> <tr> <td>CLASE TEXTURAL</td> <td>FArA</td> </tr> <tr> <td>Conductividad k10 (m/día)</td> <td>1.11</td> </tr> <tr> <td>%H gravimétrico a 0Bar</td> <td>21.15</td> </tr> <tr> <td>%H gravimétrico a 0,3 Bar</td> <td>11.19</td> </tr> <tr> <td>%H gravimétrico a 1 Bar</td> <td>10.89</td> </tr> <tr> <td>%H gravimétrico a 5 Bar</td> <td>10.72</td> </tr> <tr> <td>%H gravimétrico a 10 Bar</td> <td>9.33</td> </tr> <tr> <td>%H gravimétrico a 15 Bar</td> <td>7.78</td> </tr> </tbody> </table>	Muestreo	H0	Da (gr/cc)	1.71	%ARENAS	70.35	%ARCILLAS	21.65	%LIMOS	8.00	CLASE TEXTURAL	FArA	Conductividad k10 (m/día)	1.11	%H gravimétrico a 0Bar	21.15	%H gravimétrico a 0,3 Bar	11.19	%H gravimétrico a 1 Bar	10.89	%H gravimétrico a 5 Bar	10.72	%H gravimétrico a 10 Bar	9.33	%H gravimétrico a 15 Bar	7.78
		Muestreo	H0																									
		Da (gr/cc)	1.71																									
		%ARENAS	70.35																									
		%ARCILLAS	21.65																									
		%LIMOS	8.00																									
		CLASE TEXTURAL	FArA																									
		Conductividad k10 (m/día)	1.11																									
		%H gravimétrico a 0Bar	21.15																									
		%H gravimétrico a 0,3 Bar	11.19																									
		%H gravimétrico a 1 Bar	10.89																									
		%H gravimétrico a 5 Bar	10.72																									
		%H gravimétrico a 10 Bar	9.33																									
%H gravimétrico a 15 Bar	7.78																											
																												

Calicata F43

Coordenadas:	X: 1151202,1612	Cobertura: Potrero, pastos
	Y: 972582,1679	Resultados de Laboratorio:

Sistema de Coordenadas:	Magna-Sirgas Oeste
----------------------------	--------------------



Muestreo	H1	H2
Da (gr/cc)	0.84	0.95
%ARENAS	82.35	80.35
%ARCILLAS	10.65	10.65
%LIMOS	7.00	9.00
CLASE TEXTURAL	FA	FA
Conductividad k10 (m/día)	0.45	6.81
%H gravimétrico a 0Bar	26.51	85.01
%H gravimétrico a 0,3 Bar	15.29	68.46
%H gravimétrico a 1 Bar	14.07	68.01
%H gravimétrico a 5 Bar	13.94	67.59
%H gravimétrico a 10 Bar	13.37	65.26
%H gravimétrico a 15 Bar	11.38	62.12



Calicata F44

Coordenadas:		X: 1151077,3093	Cobertura: Bosque de pino		
		Y: 971375,7186	Resultados de Laboratorio:		
Sistema de Coordenadas:	Magna-Sirgas Oeste		Muestreo	H1	H2
			Da (gr/cc)	1.04	1.07
			%ARENAS	83.35	78.35
			%ARCILLAS	6.65	11.65
			%LIMOS	10.00	10.00
			CLASE TEXTURAL	FA	FA
			Conductividad k10 (m/día)	0.25	0.14
			%H gravimétrico a 0Bar	70.51	55.23
			%H gravimétrico a 0,3 Bar	54.84	41.46
			%H gravimétrico a 1 Bar	54.13	41.10
			%H gravimétrico a 5 Bar	53.60	40.99
			%H gravimétrico a 10 Bar	50.98	39.19
			%H gravimétrico a 15 Bar	47.57	36.57



 Universidad del Tolima	PROCEDIMIENTO DE FORMACIÓN DE USUARIOS	Página 1 de 2
	AUTORIZACIÓN DE PUBLICACIÓN EN EL REPOSITORIO INSTITUCIONAL	Código: GB-P04-F03
		Versión: 04
		Fecha Aprobación: 04/03/2019

Los autores:

Nombre Completo	Identificación N°
Jaime Izquierdo Bautista	12.138.277

Manifiesto (an) la voluntad de:

Autorizar

No Autorizar Motivo: _____

La consulta en físico y la virtualización de mi OBRA, con el fin de incluirlo en el repositorio institucional de la Universidad del Tolima. Esta autorización se hace sin ánimo de lucro, con fines académicos y no implica una cesión de derechos patrimoniales de autor.

Manifestamente que se trata de una OBRA original y como de la autoría de LA OBRA y en relación a la misma, declara que la UNIVERSIDAD DEL TOLIMA, se encuentra, en todo caso, libre de todo tipo de responsabilidad, sea civil, administrativa o penal (incluido el reclamo por plagio).

Por su parte la UNIVERSIDAD DEL TOLIMA se compromete a imponer las medidas necesarias que garanticen la conservación y custodia de la obra tanto en espacios físico como virtual, ajustándose para dicho fin a las normas fijadas en el Reglamento de Propiedad Intelectual de la Universidad, en la Ley 23 de 1982 y demás normas concordantes.

La publicación de:

Trabajo de grado

Producto de la actividad académica/científica/cultural en la Universidad del Tolima, para que con fines académicos e investigativos, muestre al mundo la producción intelectual de la Universidad del Tolima. Con todo, en mi condición de autor me reservo los derechos morales de la obra antes citada con arreglo al artículo 30 de la Ley 23 de 1982. En concordancia suscribo este documento en el momento mismo que hago entrega del trabajo final a la Biblioteca Rafael Parga Cortes de la Universidad del Tolima.

 Universidad del Tolima	PROCEDIMIENTO DE FORMACIÓN DE USUARIOS	Página ² de 2
	AUTORIZACIÓN DE PUBLICACIÓN EN EL REPOSITORIO INSTITUCIONAL	Código: GB-P04-F03
		Versión: 04
		Fecha Aprobación: 04/03/2019

De conformidad con lo establecido en la Ley 23 de 1982 en los artículos 30 “...**Derechos Morales. El autor tendrá sobre su obra un derecho perpetuo, inalienable e irrenunciable**” y 37 “...**Es lícita la reproducción por cualquier medio, de una obra literaria o científica, ordenada u obtenida por el interesado en un solo ejemplar para su uso privado y sin fines de lucro**”. El artículo 11 de la Decisión Andina 351 de 1993, “**los derechos morales sobre el trabajo son propiedad de los autores**” y en su artículo 61 de la Constitución Política de Colombia.

- Identificación del documento:

Título completo:	DESARROLLO DE FUNCIONES DE EDAFOTRANSFERENCIA PARA SUELOS ANDINOS NEOTROPICALES.
Trabajo de grado presentado para optar al título de:	Doctor En Planificación Y Manejo Ambiental De Cuencas Hidrográficas.

Quienes a continuación autentican con su firma la autorización para la digitalización e inclusión en el repositorio digital de la Universidad del Tolima, el día 30 del mes 09 del año 2020.

Nombre Completo	Firma	Identificación N°.
Jaime Izquierdo Bautista		12.138.277

El autor y/o autores certifican que conocen las derivadas jurídicas que se generan en aplicación de los principios del derecho de autor.