

EVALUACIÓN Y DESARROLLO DE FUNCIONES DE PEDOTRANSFERENCIA Y REDES NEURONALES ARTIFICIALES PARA LA ESTIMACIÓN DE HUMEDAD A SATURACIÓN

Josué Trejo-Alonso¹; Sebastián Fuentes²; Nami Morales-Durán³; Carlos Chávez^{2*}

¹Facultad de Ingeniería. Universidad Autónoma de Querétaro. C.U. Cerro de las Campanas, C.P. 76010, Querétaro, México.

²Centro de Investigaciones del Agua, Departamento de Ingeniería de Riego y Drenaje, Universidad Autónoma de Querétaro. Cerro de las Campanas SN, Col. Las Campanas, C.P. 76010, Querétaro, México.

chagcarlos@uaq.mx - +52-442-192-1200 (ext 6036) (*Autor de correspondencia)

³Facultad de Ciencias Químicas. Universidad Autónoma de Nuevo León, San Nicolás de los Garza, C.P. 66451, Nuevo León, México.

Resumen

La modelación del riego y drenaje en la agricultura requiere del conocimiento de las propiedades hidráulicas del suelo. Sin embargo, la incertidumbre en la medición directa del contenido de humedad a saturación (θ_s) ha generado diversas metodologías para su estimación tales como las Funciones de Pedotransferencia (PTFs) y/o las Redes Neuronales Artificiales (ANN). En este trabajo se desarrollaron ocho PTFs diferentes para la estimación de θ_s , las cuales se relacionan con la proporción de arena y arcilla, la densidad aparente (BD) así como la conductividad hidráulica a saturación (K_s). Además, se desarrollaron ANN con diferentes combinaciones de capas de entrada y ocultas para la estimación de θ_s . Los resultados mostraron valores de $0.9046 \leq R^2 \leq 0.9877$ para las ocho PTF diferentes, mientras que con las ANN se obtuvieron valores de $R^2 \geq 0.9891$. Por último, se obtuvo el error cuadrático medio (RMSE) para cada configuración de ANN, con resultados que oscilaron entre $0.0245 \leq RMSE \leq 0.0262$. Se encontró que con determinados parámetros característicos del suelo (% Arcilla, % Arena, % Limo, BD y K_s), se obtiene una estimación precisa de θ_s . Con el desarrollo de estos modelos, se obtuvieron altos valores de R^2 para 10 de las 12 clases texturales.

Palabras claves: Propiedades hidráulicas del suelo, inteligencia artificial, humedad a saturación.

Introducción

Los parámetros físicos del suelo son esenciales en diferentes estudios de modelación, como la predicción del crecimiento y el rendimiento de los cultivos y la representación de la relación entre el suelo, el agua, la planta y la atmósfera (e.g. Sheila et al. 2018, Tian et al. 2019).

La gestión sustentable del recurso hídrico ha motivado el constante desarrollo de modelos cada vez más sofisticados para describir el flujo de agua y el transporte de solutos en suelos no saturados (Schaap, 1998). Estos modelos se basan principalmente en la solución de la ecuación de Richards (Richards, 1931) a partir de la curva de conductividad hidráulica $K(\psi)$ y la curva de retención $\theta(\psi)$, ambas funciones del potencial hídrico del suelo (ψ). Estas dos propiedades hidráulicas del suelo son entradas clave para la mayoría de los modelos que tratan de modelar la transferencia de agua para diversos fines (Balland y Pollacco, 2008; Wösten et al. 2013). El parámetro θ_s es el que cuenta con un mayor grado de dificultad para su estimación, un método cualitativo para determinarlo consiste en evaluar una muestra de suelo con el tacto, utilizando el método del tacto y apariencia (Liang y Wang, 2019).

Los sensores en campo proporcionan una estimación precisa de la humedad del suelo a diferentes profundidades (Warrick et al. 1998), sin embargo, las mediciones in situ son tardadas y requieren de equipo especializado que pueden generar un alto costo económico en la estimación de la humedad del suelo.

Mientras que las Funciones de Pedotransferencia (PTFs, por sus siglas en inglés) han sido ampliamente utilizadas para estimar las propiedades de los suelos en diferentes regiones de estudio, en respuesta a la falta de datos sobre los suelos, así como el laborioso y lento proceso de determinación de las propiedades hidráulicas del suelo (e.g. Chávez y Fuentes, 2019). Por lo cual se hace necesario desarrollar PTFs para estimar la humedad tomando en cuenta la mayor cantidad de parámetros relacionados con el suelo, y obtener modelos que se ajusten con la mayor precisión posible a las condiciones in situ presentadas en la mayoría de las parcelas de cultivos agrícolas.

Adicionalmente, en los últimos años, con el creciente progreso de la inteligencia artificial, se ha explorado otra alternativa de las PTF: Las ANN (e.g. Trejo-Alonso et al. 2021). Se han desarrollado redes neuronales que tienen como parámetro de entrada el logaritmo natural de ψ ; con ello, es posible calcular el contenido de humedad deseado ψ , que varía con el tiempo (Haghverdi, 2012).

Los objetivos de este estudio son: a) desarrollar PTFs para estimar la humedad a saturación del suelo a partir de redes neuronales y b) comparar los modelos desarrollados con los de la literatura en diferentes texturas del suelo.

Materiales y Métodos

Área de estudio

La base de datos utilizada en este estudio fue desarrollada en una superficie de 11,048 ha. Mediante muestreos en 900 parcelas del Distrito de Riego 023 ubicado entre los municipios de San Juan del Río y Pedro Escobedo en el estado de Querétaro, México.

Texturas del Suelo

La textura del suelo es un indicador de la cantidad de agua que el suelo puede almacenar y, en consecuencia, el intervalo de riego con el que deben regarse los cultivos. La Figura 1 muestra la textura obtenida en el laboratorio y clasificada según el triángulo de texturas propuesto por el USDA utilizando el paquete R "soil texture" (Moeys, 2018). Esta textura está determinada por la proporción de arena, limo y arcilla y según el triángulo.

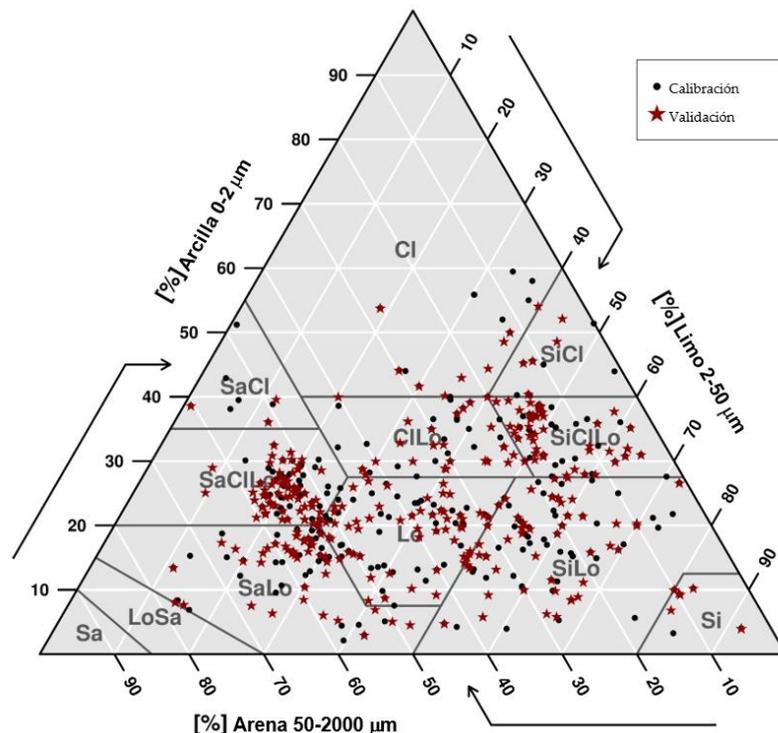


Figura 1. Distribución de las texturas del suelo para los datos de calibración (450 puntos) y validación (450 puntos). Las abreviaturas son las siguientes: arcilla (Cl), arena (Sa), limo (Si), Limo (Lo), arcillo arenoso (SaCl), arcillo limoso (SiCl), franco arcilloso arenoso (SaClLo), franco arcilloso (CILo), franco arcilloso limoso (SiClLo), franco arenoso (SaLo), franco limoso (SiLo) y areno limoso (LoSa).

Desarrollo de las PTFs y ANNs

Basándose en el estudio de Trejo-Alonso et al. (2020), se desarrollaron ocho nuevas PTF basadas en los resultados de un Análisis de Componentes Principales (PCA). Esta

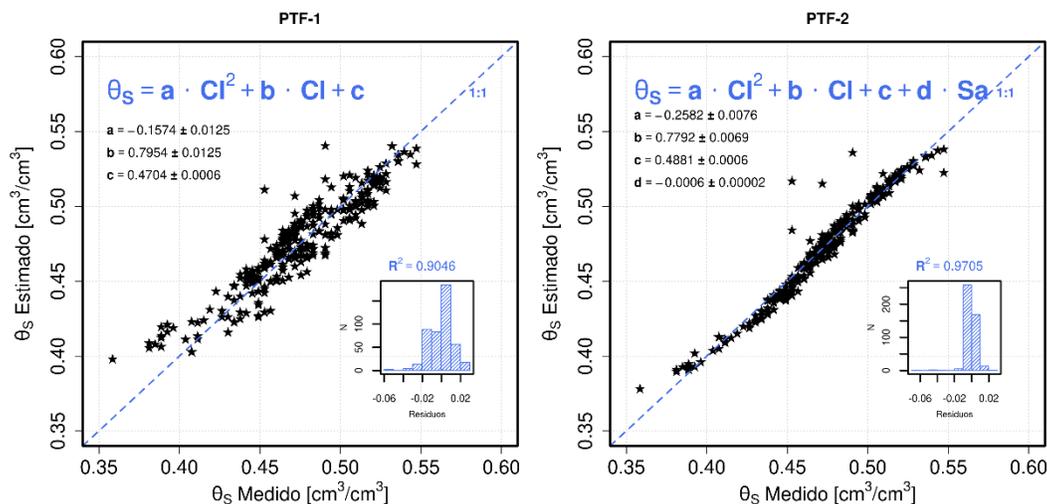
decisión se tomó debido al hecho de que sólo se pudo probar el PTF publicado por Vereecken et al. (1989) y la falta de PTFs para θ_s en la literatura. Para los nuevos PTFs, sólo debemos considerar las siguientes variables de la base de datos: % Arcilla, % Arena, BD y K_s . Las PTF y los gráficos de este trabajo se construyeron utilizando el software R (R Core Team, 2022), y se utilizan 450 valores aleatorios para la calibración y 450 para la validación. Para las ANN, se utilizaron el paquete "neuralnet" (Fritsch et al. 2019) y el paquete "caret" (Kuhn, 2022), proporcionados por el software R, con un 75% de la muestra para el entrenamiento y un 25% para la validación. Se construyeron dos ANN diferentes, la primera con cuatro neuronas como datos de entrada (% Arcilla, % limo, BD y K_s) y la segunda con cinco neuronas de entrada (% arcilla, % limo, % arena, BD y K_s). En ambas ANN se mantuvieron dos capas ocultas, y el número de neuronas en cada capa varía de 2 a 10. Este proceso dio lugar a 81 configuraciones de ANN y, finalmente, se seleccionaron las dos mejores configuraciones.

Resultados y Discusión

PTFs

La textura de suelo dominante en esta región es SiClLo (18.11%), seguida de SiLo (16.11%), lo que puede observarse en la Figura 1. Con la determinación de esta propiedad del suelo, es posible detectar las parcelas en las que las profundidades y los tiempos de riego fueron excesivos (Chávez y Fuentes, 2019).

La Figura 2 muestra los nuevos PTFs construidos en este estudio y las expresiones matemáticas que las describen, así como los valores de cada constante. También se probaron modelos con datos de porcentaje de limo, pero con resultados peores o muy similares. Esto ya lo indicaba el PCA.



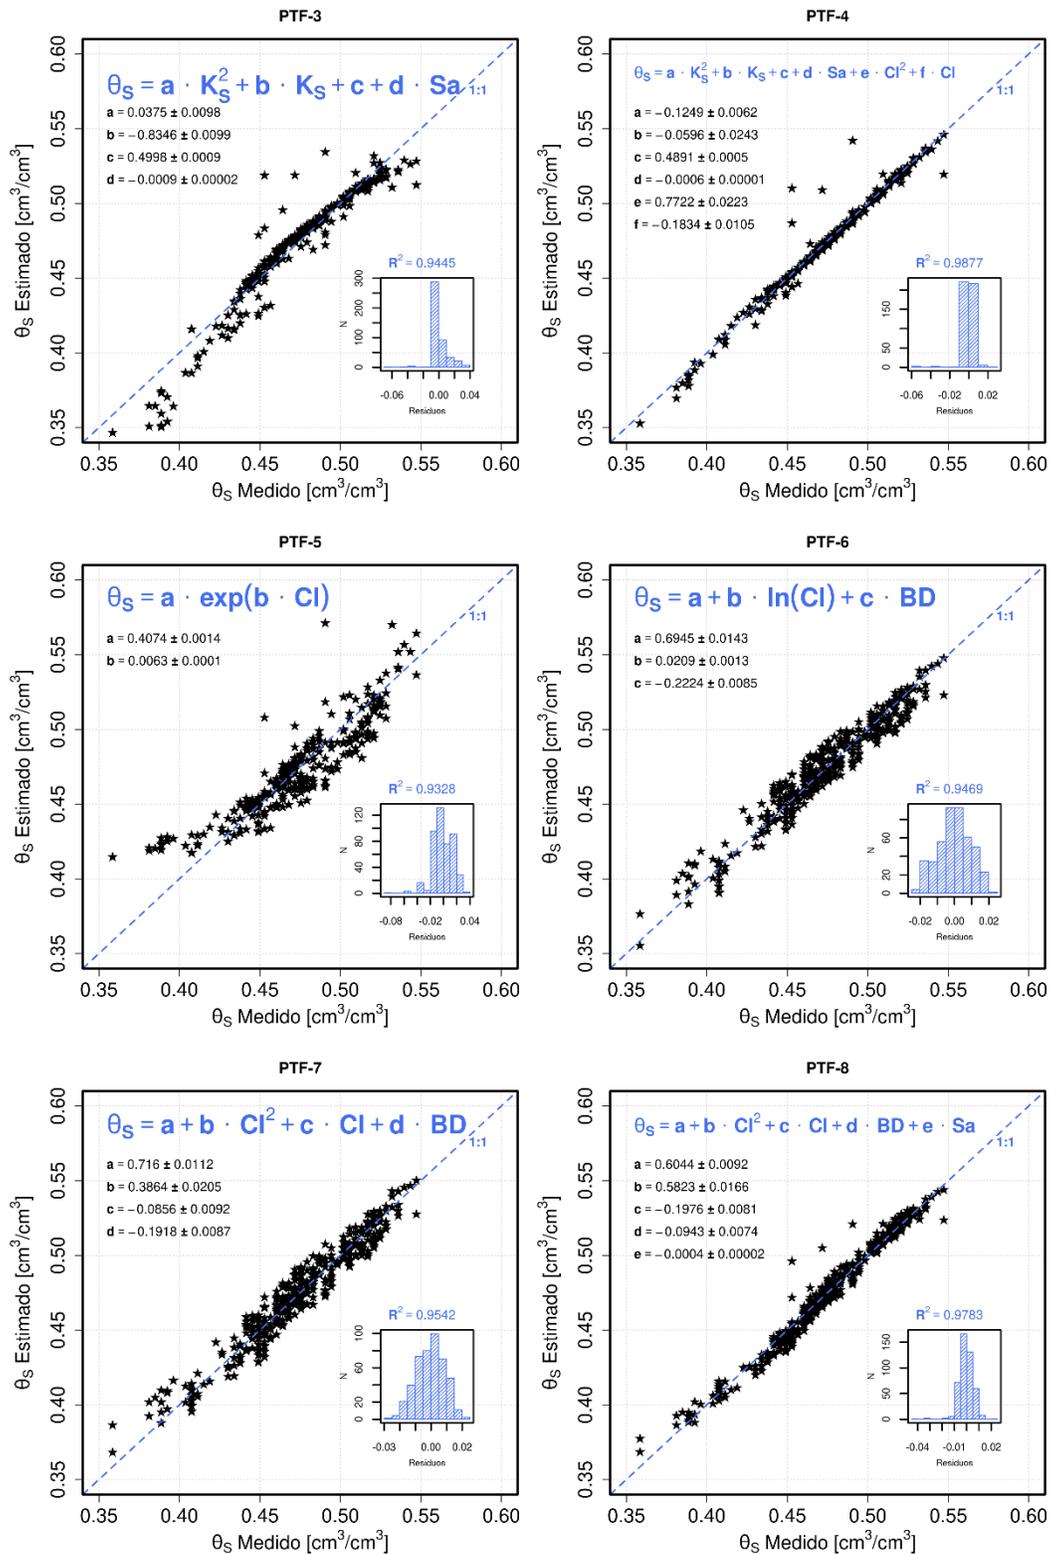
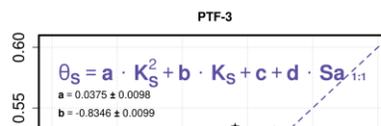


Figura 2. Resultados de las PTFs construidas en este trabajo.



ANNs

La mejor configuración para la ANN con cuatro capas de entrada fue 4-9-10-1, lo que significa cuatro entradas, nueve neuronas en la primera capa oculta, diez neuronas en la segunda capa oculta y una salida. Para las cinco capas de entrada, se implementó una configuración 5-10-10-1. Los principales resultados de estas dos ANNs se resumen en la Cuadro 1. Los resultados obtenidos proporcionaron un R^2 elevado, que puede considerarse satisfactorio si se compara con otros estudios (Vereecken et al. 1989; Wösten et al. 2001).

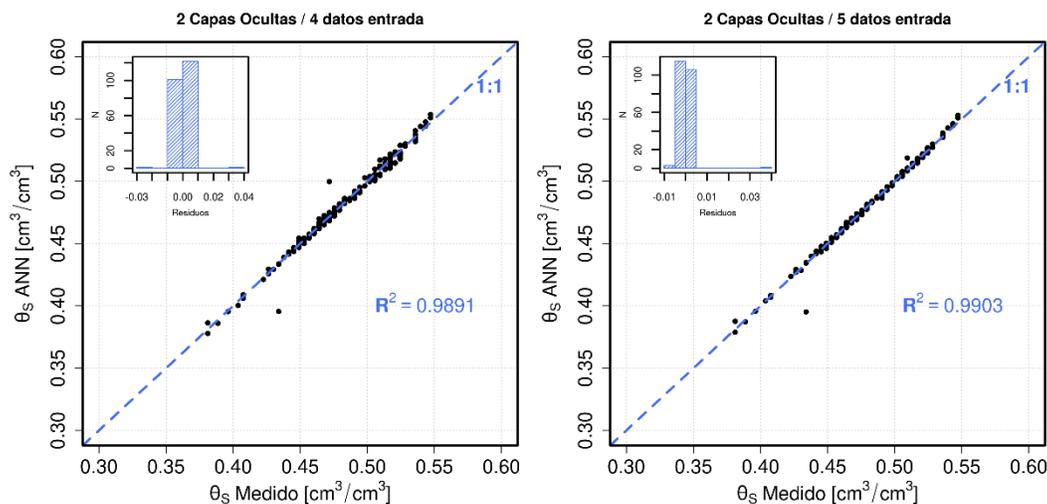


Figura 3. Resultados para las configuraciones 4-9-10-1 (izquierda) y 5-10-10-1 (derecha) de las ANNs aplicadas a los datos de validación.

Cuadro 1. Resultados de las ANN desarrolladas

ANN	RMSE	R^2	ME
4-9-10-1	0.0182	0.9891	0.0091
5-10-10-1	0.0195	0.9903	0.0095

Conclusiones

En este trabajo se encontraron ocho nuevas PTFs que demostraron ser más precisas en comparación con los encontrados en la literatura para el cálculo de θ_s . Los modelos aquí desarrollados presentan la ventaja de tener un alto valor de R^2 y la característica de sólo requerir tres variables primarias del suelo como parámetro de entrada, que son el contenido de arcilla y arena, así como K_s en dos de las ocho funciones o BD en tres de las ocho funciones desarrolladas.

Además, con el desarrollo de ANNs, con los mismos cuatro parámetros de entrada, se demuestra que se puede reducir el error obtenido en las PTFs. Por lo tanto, se ha

comprobado que las ANNs son más precisas que las PTFs en el modelado de θ_s con mejores valores en R^2 incluso con para la ANN más simple (4 entradas).

El desarrollo de PTFs es una herramienta útil que puede ser aplicada principalmente en riego (aspersión, goteo o superficie), así como en drenaje agrícola, para estimar parámetros de suelo que son de difícil acceso. Son fáciles de evaluar y dependen del número de variables a aplicar. Sin embargo, las ANNs son una alternativa cuando se busca una aproximación más exacta siempre que el equipamiento informático (hardware y software) no sea un inconveniente.

Referencias Bibliográficas

- Shelia, V.; Šim° unek, J.; Boote, K.; Hoogenboom, G. Coupling DSSAT and HYDRUS-1D for Simulations of SoilWater Dynamics in the Soil-Plant-Atmosphere System. *J. Hydrol. Hydromech.* 2018, 66, 232–245.
- Tian, H.; Huang, N.; Niu, Z.; Qin, Y.; Pei, J.; Wang, J. Mapping Winter Crops in China with Multi-Source Satellite Imagery and Phenology-Based Algorithm. *Remote Sens.* 2019, 11, 820.
- Schaap, M. Using Neural Networks to Predict SoilWater Retention and Soil Hydraulic Conductivity. *Soil Tillage Res.* 1998, 47, 37–42.
- Richards, L.A. Capillary Conduction of Liquids through Porous Mediums. *Physics* 1931, 1, 318–333.
- Balland, V.; Pollacco, J.A.P.; Arp, P.A. Modeling Soil Hydraulic Properties for a Wide Range of Soil Conditions. *Ecol. Model.* 2008, 219, 300–316
- Wösten, J.H.M.; Verzandvoort, S.J.E.; Leenaars, J.G.B.; Hoogland, T.; Wesseling, J.G. Soil Hydraulic Information for River Basin Studies in Semi-Arid Regions. *Geoderma* 2013, 195–196, 79–86.
- Liang, S.; Wang, J. *Advanced Remote Sensing: Terrestrial Information Extraction and Applications*; Academic Press: Cambridge, MA, USA, 2019; ISBN 978-0-12-815826-5.
- Warrick, A.W.; Wierenga, P.J.; Young, M.H.; Musil, S.A. Diurnal Fluctuations of Tensiometric Readings Due to Surface Temperature Changes. *Water Resour. Res.* 1998, 34, 2863–2869.
- Chávez, C.; Fuentes, C. Design and Evaluation of Surface Irrigation Systems Applying an Analytical Formula in the Irrigation District 085, La Begoña, Mexico. *Agric. Water Manag.* 2019, 221, 279–285.
- Trejo-Alonso, J.; Fuentes, C.; Chávez, C.; Quevedo, A.; Gutierrez-Lopez, A.; González-Correa, B. Saturated Hydraulic Conductivity Estimation Using Artificial Neural Networks. *Water* 2021, 13, 705.
- Haghverdi, A.; Cornelis, W.M.; Ghahraman, B. A Pseudo-Continuous Neural Network Approach for Developing Water Retention Pedotransfer Functions with Limited Data. *J. Hydrol.* 2012, 442–443, 46–54.
- Moeys, J. *Soiltexture: Functions for Soil Texture Plot, Classification and Transformation*. 2018. Available online: <https://CRAN.Rproject.org/package=soiltexture> (accessed on 27 December 2022).

- Trejo-Alonso, J.; Quevedo, A.; Fuentes, C.; Chávez, C. Evaluation and Development of Pedotransfer Functions for Predicting Saturated Hydraulic Conductivity for Mexican Soils. *Agronomy* 2020, 10, 1516.
- Vereecken, H.; Maes, J.; Feyen, J.; Darius, P. Estimating the soil moisture retention characteristic from texture, bulk density, and carbon content. *Soil Sci.* 1989, 148, 389–403.
- R Core Team. R: A Language and Environment for Statistical Computing; R Foundation for Statistical Computing: Vienna, Austria. 2022. Available online: <https://www.R-project.org/> (accessed on 27 December 2022).
- Fritsch S.; Guenther, F.; Wright, M.N. Neuralnet: Training of Neural Networks. R Package Version 1.44.2. 2019. Available online: <https://CRAN.R-project.org/package=neuralnet> (accessed on 27 December 2022).
- Kuhn, M. Caret: Classification and Regression Training. R Package Version 6.0-93. 2022. Available online: <https://CRAN.Rproject.org/package=caret> (accessed on 27 December 2022).
- Wösten, J.H.M.; Pachepsky, Ya.A.; Rawls, W.J. Pedotransfer Functions: Bridging the Gap between Available Basic Soil Data and Missing Soil Hydraulic Characteristics. *J. Hydrol.* 2001, 251, 123–150.