

TRABAJO DE GRADO  
*PASANTÍA DE INVESTIGACIÓN*  
*GRUPOS GIREH (UN) - GPH (UIS)*

**DETERMINACIÓN DE LA CURVA DE RETENCIÓN DE  
AGUA DE SUELOS GRANULARES USANDO REDES  
NEURONALES ARTIFICIALES**

ALBA ANDREA GÓMEZ CASTRO

UNIVERSIDAD INDUSTRIAL DE SANTANDER  
FACULTAD DE INGENIERÍAS FÍSICO - MECÁNICAS  
ESCUELA DE INGENIERÍA CIVIL  
BUCARAMANGA  
2009

TRABAJO DE GRADO  
*PASANTÍA DE INVESTIGACIÓN*  
*GRUPOS GIREH (UN) – GPH (UIS)*

**DETERMINACIÓN DE LA CURVA DE RETENCIÓN DE  
AGUA DE SUELOS GRANULARES USANDO REDES  
NEURONALES ARTIFICIALES**

ALBA ANDREA GÓMEZ CASTRO

Trabajo de grado presentado como requisito para obtener el título de Ingeniero  
Civil

Director  
MARIO GARCÍA SOLANO  
Profesor Universidad Industrial de Santander

Co-director  
LEONARDO DAVID DONADO GARZÓN  
Profesor Universidad Nacional de Colombia

UNIVERSIDAD INDUSTRIAL DE SANTANDER  
FACULTAD DE INGENIERÍAS FÍSICO - MECÁNICAS  
ESCUELA DE INGENIERÍA CIVIL  
BUCARAMANGA  
2009

## CONTENIDO

	Pag.
1 INTRODUCCIÓN	1
2 CURVA DE RETENCION DE AGUA	3
2.1 INTRODUCCIÓN	3
2.2 LA CURVA DE RETENCIÓN DE AGUA, CRA	3
2.2.1 Succión o Potencial Mátrico	5
2.2.2 Efectos de las Propiedades del Suelo	6
2.3 MÉTODOS DE DETERMINACIÓN	8
2.3.1 Embudo de Büchner	9
2.3.2 Plato Poroso De Succión	11
2.3.3 Plato Extractor de Presión	11
3 REDES NEURONALES ARTIFICIALES RNA	13
3.1 INTRODUCCIÓN	13
3.2 QUÉ ES UNA RNA	13
3.3 CARACTERIZACIÓN DE LAS REDES NEURONALES	17
3.3.1 Arquitectura	17
3.3.2 Algoritmo	19
3.3.3 Funciones De Activación	20
3.4 ALGORITMO BACKPROPAGATION BP	22
3.4.1 Arquitectura	23
3.4.2 Algoritmo	24
4 ANÁLISIS DE LOS DATOS Y DESARROLLO DEL MODELO DE RED NEURONAL ARTIFICIAL	26
4.1 INTRODUCCIÓN	26
4.2 ENSAYOS DE LABORATORIO	26
4.2.1 Determinación De Las Curvas De Humedad En El Laboratorio	28
4.3 DEFINICIÓN DE PARÁMETROS DE LAS RNA	31
4.3.1 Arquitectura RNA para la curva AFU	36
4.3.2 Arquitectura RNA para la curva AMU	37
4.3.3 Arquitectura RNA para la curva ADTP	38
5 RESULTADOS Y DISCUSIÓN	39

5.1	INTRODUCCIÓN	39
5.2	RESULTADOS DE LA RED ENTRENADA PARA AFU	39
5.2.1	Modelo De La RNA Con Los Datos Medidos En El Laboratorio	39
5.2.2	Modelo De La RNA Con Los Datos De La Curva Teórica Propuesta Por Fredlund y Xing	41
5.3	RESULTADOS DE LA RED ENTRENADA PARA AMU	42
5.3.1	Modelo De La RNA Con Los Datos Medidos En El Laboratorio	42
5.3.2	Modelo De La RNA Con Los Datos De La Curva Teórica Propuesta Por Fredlund y Xing	44
5.4	RESULTADOS DE LA RED ENTRENADA PARA ADTP	46
5.4.1	Modelo De La RNA Con Los Datos Medidos En El Laboratorio	46
5.4.2	Modelo De La RNA Con Los Datos De La Curva Teórica Propuesta Por Fredlund y Xing	47
6	CONCLUSIONES Y RECOMENDACIONES	49
7	REFERENCIAS BIBLIOGRAFICAS	51
	ANEXOS	53
A.	ANEXOS	54

## LISTA DE FIGURAS

	Pag.
Figura 2.1 Perfil vertical de agua en el suelo, Bear (1972).....	3
Figura 2.2. Regiones típicas de la curva característica, Pérez (2008).....	5
Figura 2.3. Proceso de drenaje en un suelo, Burland (1996) .....	7
Figura 2.4. Curvas características para suelos con diferentes texturas, Pérez (2006).....	8
Figura 2.5. Esquema del embudo de Büchner, Pérez (2008) .....	10
Figura 2.6. Vista de una sección del plato de cerámica del plato extractor de presión .....	12
Figura 2.7. Vista general de los aditamentos del plato extractor de presión .....	12
Figura 3.1. Representación esquemática de la arquitectura de una RNA y el sistema nervioso humano, Shrestha (2003).....	15
Figura 3.2. Representación esquemática de una neurona, Fausett (1994) .....	16
Figura 3.3. Red tipo Perceptrón, Fausett (1994), .....	18
Figura 3.4. Red de Hopfield, Fausett (1994).....	18
Figura 3.5. Representación esquemática de la arquitectura de una RNA multicapa, Fausett (1994) .....	19
Figura 3.6. Red de Kohonen, Delgado (1998).....	20
Figura 3.7. Función idéntica .....	20
Figura 3.8. Función logística, Fausett (1994).....	21
Figura 3.9. Función tangente hiperbólica, Fausett (1994) .....	22
Figura 3.10. Red neuronal Backpropagation con dos capas ocultas, Fausett (1994) .....	23
Figura 3.11. Red neuronal de tipo Backpropagation con una capa oculta, Fausett (1994). .....	24
Figura 4.1. Distribución granulométrica de los suelos en estudio, Donado (2004) .....	27
Figura 4.2. Ensayo de olla de presión, Barrera y Muñoz (2003) .....	29
Figura 4.3. Ensayo mesa de succión, Barrera y Muñoz (2003).....	29
Figura 4.4. Datos experimentales de la curva de retención en arenas finas uniformes. ....	30

Figura 4.5. Datos experimentales de la curva de retención en arenas medias uniformes.....	30
Figura 4.6. Datos experimentales de la curva de retención en arenas diferentes tamaños de partícula .....	31
Figura 4.7. Datos experimentales AFU escalados usados para entrenar la red.....	33
Figura 4.8. Datos experimentales AMU escalados usados para entrenar la red .....	33
Figura 4.9. Datos experimentales ADTP escalados usados para entrenar la red.....	34
Figura 4.10. Arquitectura RNA para datos AFU.....	36
Figura 4.11. Grafica del entrenamiento del la red para AFU .....	36
Figura 4.12. Arquitectura RNA para datos AMU .....	37
Figura 4.13. Grafica del entrenamiento del la red para AMU.....	37
Figura 4.14. Arquitectura RNA para datos ADTP.....	38
Figura 4.15. Grafica del entrenamiento del la red para ADTP .....	38
Figura 5.1 CRA datos medidos en laboratorio .....	40
Figura 5.2 CRA datos estimados por RNA .....	40
Figura 5.3 CRA para AFU medidos en el laboratorio y estimados por la red.....	40
Figura 5.4 Diagrama de dispersión de datos para la CRA en AFU. Ilustra la precisión en la estimación de la RNA .....	40
Figura 5.5 CRA generada con el modelo teórico.....	41
Figura 5.6 CRA datos estimados por la RNA para el modelo teórico .....	41
Figura 5.7 CRA para AFU según modelo teórico de Fredlund Y Xing y estimación del modelo por la red .....	41
Figura 5.8 Dispersión de datos para la CRA teórica en AFU. Ilustra la precisión en la estimación de la RNA.....	42
Figura 5.9 CRA para AFU todos los métodos de determinación .....	42
Figura 5.10 CRA datos medidos en laboratorio .....	43
Figura 5.11 CRA datos estimados por la RNA.....	43

Figura 5.12 CRA para AMU medidos en el laboratorio y estimados por la red .....	43
Figura 5.13 Diagrama de dispersión de datos para la CRA en AMU. Ilustra la precisión en la estimación de la RNA .....	44
Figura 5.14 CRA generada con el modelo teórico.....	44
Figura 5.15 CRA datos estimados por la RNA modelo teórico.....	44
Figura 5.16 CRA para AMU según modelo teórico de Fredlund Y Xing y estimación del modelo por la red .....	45
Figura 5.17 Diagrama de dispersión de datos para la CRA en AMU. Ilustra la precisión en la estimación de la RNA .....	45
Figura 5.18 CRA para AMU todos los métodos de determinación .....	46
Figura 5.19 CRA datos medidos en laboratorio .....	46
Figura 5.20 CRA datos estimados por la RNA.....	46
Figura 5.21 CRA para ADTP medidos en el laboratorio y estimados por la red.....	47
Figura 5.22 Diagrama de dispersión de datos para la CRA en ADTP. Ilustra la precisión en la estimación de la RNA .....	47
Figura 5.23 CRA generada con el modelo teórico.....	48
Figura 5.24 CRA datos estimados por la RNA para el modelo teórico .....	48
Figura 5.25 CRA para ADTP según modelo teórico de Fredlund Y Xing y estimación del modelo por la red .....	48

INDICE DE TABLAS

	Pag.
Tabla 2-1 Factores de conversión para la engría de agua en el suelo, Townend (2000) .....	6
Tabla 2-2. Métodos de determinación de las curvas de retención, adaptado Townend (2000).....	9
Tabla 4-1. Distribución granulométrica de los suelos en estudio, Donado (2004) .....	27
Tabla 4-2. Relación de vacíos y porosidad de los suelos en estudio, Barrera y Muñoz (2003).....	28
Tabla 4-3. Contenido volumétrico de agua en condición saturada, Barrera y Muñoz (2003) .....	28

## RESUMEN.

TITULO: DETERMINACIÓN DE LA CURVA DE RETENCIÓN DE AGUA DE SUELOS GRANULARES USANDO REDES NEURONALES ARTIFICIALES\*

AUTORA: GÓMEZ CASTRO, Alba Andrea\*\*

PALABRAS CLAVES: Curvas de retención de agua, redes neuronales artificiales, algoritmo Backpropagation.

### RESUMEN

La determinación de las curvas de retención de agua en los suelos es fundamental para el estudio de la movilidad del agua subterránea, sin embargo, obtener mediciones de ésta de manera directa es difícil tanto en el campo como en el laboratorio; y los modelos teóricos propuestos hasta ahora generan incertidumbres, debido a que contienen parámetros empíricos o son estimaciones basadas en otros parámetros más fáciles de medir en el suelo.

La implementación de las redes neuronales artificiales, se propone como una alternativa para determinar curvas de retención de agua, ya que son sistemas de procesamiento de información basados en datos, que modelan relaciones entre los datos de entrada y salida si importar el tipo de relación que exista entre estos, no requieren una matemática compleja.

Usando el algoritmo Backpropagation se diseñaron las arquitecturas de las redes neuronales, que aproximan el comportamiento de las curvas de retención tomadas en el laboratorio para tres tipos de suelo, arena fina uniforme (AFU), arena media uniforme (AMU) y arena de diferentes tamaños de partícula (ADTP). Se pudo observar que el adecuado comportamiento de una red depende en gran medida de la calidad y cantidad de datos con los que se cuenta para el entrenamiento.

---

\* Proyecto de Grado

\*\* Facultad de Ingenierías Físico-Mecánicas. Escuela de Ingeniería Civil. Director: Mario García Solano. Codirector: Leonardo David Donado Garzón.

## ABSTRACT

TITLE: DETERMINATION OF WATER RETENTION CURVE IN SANDY SOIL USING ARTIFICIAL NEURAL NETWORKS\*

AUTHOR: GOMEZ CASTRO, Alba Andrea\*\*

KEYWORDS: Soil water retention curve, artificial neural networks, backpropagation algorithm.

### ABSTRACT

The Determination of soil water retention curve is essential to study the mobility of the groundwater, and this study has a lot of applications in ecology, agronomy and engineering, and others. But it's direct measurement is complicated as much in the field as in the laboratory, and the proposed theoretical models allow uncertainties as contain empirical parameters, or are estimates based on other parameters more easily measured in the soil. For its part of the laboratory measurements take time and require special equipment.

The artificial neural networks, sets out like an alternative to determine water retention curves, because they are systems of processing of information based on data, that model relations between input and output data regardless of whether that type of relationship exists these, do not require a complex mathematical model.

This paper presents the develop of neural networks, with backpropagation algorithm that approximate the behavior of the retention curves taken in the laboratory for three types of sandy soil, fine sand uniform AFU, sand average uniform AMU and sand of different sizes particle ADTP. It was observed that the proper behavior of a network depends largely on the quality and quantity of data which are available for training.

---

\* Undergraduate Final Project

\*\* Faculty of Physical-Mechanical Engineering, School of Civil Engineering. Adviser: Mario García Solano. Co-adviser: Leonardo David Donado Garzón

## 1 INTRODUCCIÓN

Muchos estudios de flujo de agua y transporte de solutos en la zona vadosa requieren la estimación de las propiedades hidráulicas del suelo, tales como la curva de retención de agua y conductividad hidráulica. Las aplicaciones de este conocimiento se encuentran enmarcadas dentro de ciencias como la hidrogeología, la agronomía, la ecología, la ingeniería entre otras.

Dentro de las utilidades del conocimiento y predicción del comportamiento del suelo en estado parcialmente saturado se encuentran los análisis problemas hidrogeológicos en relación con obras civiles tales como presas y embalses; en estudios geotécnicos y de minería.

En la caracterización de los acuíferos subterráneos es determinante la evaluación de la curva de retención de agua en suelos, que tiene como consecuencia la gestión y explotación racional de los acuíferos para abastecimiento, así como la determinación y protección de zonas de recarga.

Las curvas de retención de agua sirven para evaluar la respuesta de un suelo frente a cambios en el contenido de agua. Se puede aplicar este conocimiento a los fenómenos de retracción y agrietamiento en suelos arcillosos pueden estar asociados a periodos prolongados de sequía, explotación de agua subterránea, a presencia de árboles de alta demanda hídrica y en muchos casos afectan de manera importante a obras civiles apoyadas sobre ellos, cuyas deformaciones excesivas inciden en la funcionalidad de las estructuras e incluso pueden llevarlas al colapso.

Desafortunadamente y pese a la gran cantidad de aplicaciones, la determinación de la curva de retención de agua en suelo no es sencilla, es costosa, consume tiempo y requiere de un equipo específico con el que no se cuenta en todo los casos.

Por esa razón muchos investigadores se han dado a la tarea de proponer modelos alternativos para su estimación indirecta basados en características más sencillas de medir en el suelo, tales como ecuaciones analíticas tales como la propuesta por van Genuchten (1980) o la de Brooks y Corey (1964) o las funciones de pedotransferencia (Rajkai et al., 2004). Pero este tipo de metodologías requieren suposiciones para llegar a las soluciones debido a que son metodologías empíricas y pueden inducir a errores.

Se debe entonces buscar un método que aproxime las curvas de retención sin introducir incertidumbres, o por lo menos con la menor cantidad de ellas. Este es el propósito de esta investigación, proponer un método que se aproxime a la realidad mejor o por lo menos de la misma forma que los métodos propuestos hasta ahora.

Las redes neuronales artificiales (RNA) aparecen como una solución alternativa a los métodos de aproximación usados hasta ahora, ya que se basan en los datos medidos y no requieren de una matemática compleja independientemente del tipo de relación que

exista entre los datos (Pachepsky et al., 1996). No requieren de parámetros empíricos, ni de asumir relaciones con otros parámetros que no incidan directamente en el proceso. Su aproximación al modelo depende únicamente de los datos experimentales de entrada y salida de la función o proceso que se desee modelar ya que a partir de ellos y después de su entrenamiento, la red evalúa y pondera los datos de entrada aprendiendo las relaciones existentes entre los datos para generar las salidas correctas.

Este documento contiene una revisión general de los conceptos básicos respecto a las curvas de retención de agua en suelos y las redes neuronales artificiales, que tiene como objetivo contextualizar al lector sobre la temática y la naturaleza del problema a tratar y el enfoque que tiene la solución propuesta. Después de esta introducción, se presenta el procedimiento y la metodología usada para desarrollar el modelo de redes neuronales de las curvas de retención. Finalmente se discuten los resultados obtenidos con la aplicación de este método.

De forma más discriminada este documento se encuentra dividido de la siguiente manera. En el numeral dos encontramos un marco teórico sobre las curvas de retención de agua en suelos, sus principales características y métodos de determinación. En el numeral tres se habla de las redes neuronales artificiales, su funcionamiento, los algoritmos y arquitecturas más comunes y se hace un análisis un poco más detallado del algoritmo llamado "backpropagation". El desarrollo del modelo se encuentra en el capítulo cuatro, allí se encuentran también las metodologías usadas para determinar los datos de entrenamiento del modelo. En el capítulo cinco se hace un análisis y una breve discusión sobre los resultados obtenidos en esta investigación, y finalmente en el capítulo seis se presentan las conclusiones y algunas recomendaciones resultado de éste proyecto.

## 2 CURVA DE RETENCION DE AGUA

### 2.1 INTRODUCCIÓN

La curva de retención de agua en suelos describe la relación que existe entre el contenido agua de un suelo y la fuerza con la que ésta es retenida. Es una propiedad muy importante de los suelos y es muy útil para caracterizar la capacidad de un suelo en particular para almacenar agua, lo que directamente está relacionado con la cantidad de plantas que éste puede soportar y el porcentaje de aireación que puede tolerar.

Esté capítulo habla más a fondo sobre las curvas de retención, describiendo las propiedades físicas que las determinan y algunos métodos para su estimación.

### 2.2 LA CURVA DE RETENCIÓN DE AGUA, CRA

Los suelos son un medio particulado y poroso. Se definen como un material constituido por una fase sólida o matriz y unos espacios, intersticios o poros, los cuales pueden ser ocupados por fluidos ya sean en estado líquido o gaseoso, siendo los más comunes el agua y el aire respectivamente. El flujo a través de estos medios porosos es el tópico que se desarrollará a través de este capítulo; La Figura 2.1 muestra la zonificación generada en el suelo por las condiciones de dicho flujo.




Figura 2.1 Perfil vertical de agua en el suelo, Bear (1972)

La zona saturada se encuentra limitada superiormente por el nivel freático y es donde permanentemente todos los poros del suelo se encuentran llenos de agua y por lo tanto en condiciones de presión positiva (Bear, 1972). La zona parcialmente saturada o de presiones intersticiales negativas también llamada zona vadosa, se encuentra entre la superficie del suelo y el nivel freático y se puede subdividir en tres subzonas: La primera corresponde a la zona radicular o de raíces del suelo, está comprendida entre la

superficie del terreno y los extremos de las raíces de la vegetación; allí existen una mayor cantidad de aire, bacterias e intersticios. La segunda es la intermedia, está ubicada debajo de la zona radicular y no presenta formaciones radiculares. Por último se tiene la zona de ascenso capilar en la cual los poros se hallan saturados pero el agua de poros presenta una succión (presión inferior a la atmosférica) por efecto del ascenso capilar desde la zona saturada (cuya superficie se encuentra a presión atmosférica). El límite entre las subzonas capilar e intermedia puede ser o no claramente apreciable dependiendo de las características del suelo (Donado, 2004).

El proceso de flujo de agua a través de esta zona puede ser descrito de la siguiente manera: Durante la precipitación el agua que llega al suelo se infiltra, si la lluvia es copiosa alcanza a llenar todos los poros del suelo desalojando el aire que se encuentra en él, y lo satura. Esta situación es un estado pasajero ya que al cesar la lluvia los poros gruesos drenan rápidamente, proceso producido por gravedad, permitiendo la circulación del agua hacia la zona saturada, este primer proceso tiene una alta velocidad. A medida que el agua va desapareciendo de los poros de mayor tamaño solo van quedando saturados los de menor tamaño y en consecuencia la velocidad del flujo va disminuyendo (Taboada et al., 2002) hasta llegar a un punto casi estable, esto hace que haya una cantidad de agua que tarda mucho tiempo en dejar el suelo. Esta agua de circulación lenta es utilizable por las plantas ya que existe suficiente aireación y la fuerza con la que el agua es retenida es relativamente pequeña, lo cual facilita la labor de las raíces. En este punto se considera que el volumen ocupado por el aire equivale al volumen de los macroporos o los poros de mayor tamaño, en tanto que el contenido de humedad del suelo en este punto puede usarse para determinar el volumen de los microporos, siempre que se trate de un suelo no expansivo (Townend et al., 2000). En este punto el suelo se encuentra a capacidad de campo.

Si la situación continua sin que el suelo vuelva a ser humedecido llega un momento en que el agua deja de sufrir los efectos gravitacionales y cesa el flujo lento con el que venía, y sólo la evaporación del agua o la succión de ella por las raíces puede conseguir eliminarla, finalmente la energía de retención del agua por parte del suelo se hace tan alta que ya las raíces no son capaces de extraer agua, entonces se ha alcanzado el punto de marchitamiento permanente, la cantidad de agua que aun es retenida por el suelo es muy pequeña y de difícil extracción.

El proceso mencionado anteriormente describe la relación entre el contenido de humedad de un suelo y la fuerza con que el agua es retenida en él, y la curva de retención de agua en suelos es la forma de representar esta relación. Una curva de retención de agua típica de un suelo en proceso de drenaje se muestra en la Figura 2.2.




Figura 2.2. Regiones típicas de la curva característica, Pérez (2008)

Las regiones en las que se encuentra dividida la curva de retención determinan cambios importantes en el proceso de drenaje. La zona capilar es aquella en la cual el suelo se mantiene en un estado de saturación, y termina en el valor de entrada de aire (Fredlund, 1999), el cual está definido como el valor que debe de exceder la succión mátrica, antes que el aire empiece a entrar en los macroporos del suelo. En la zona de desaturación, el agua es desplazada por aire, por tanto la fuerza con la que el agua se encuentra adherida a las partículas del suelo se incrementa a medida que el suelo pierde más agua. Al finalizar esta zona, el agua se encuentra en un estado discontinuo. En la zona residual hay una disminución sustancial de la tasa de drenaje de la fase líquida y un incremento de succión no genera un cambio importante en el contenido de agua. En esta región los valores de succión son muy altos (Pérez, 2008).

### 2.2.1 Succión o Potencial Mátrico

El agua presente en un suelo parcialmente saturado está sometida a fuerzas de gravedad, evaporación y adsorción por parte de las raíces de las plantas. Las cuales tienden a remover el agua de la matriz de suelo. La fuerza de unión entre la fase sólida del suelo y la fase líquida se llama "potencial mátrico" y se representa con la letra  $\Psi$ . Dado que es una fuerza por unidad de superficie esta expresada en unidades de presión, comúnmente en atmósferas, bares o kPa y tiene signo negativo porque se opone al movimiento del agua. Cuando el suelo encuentra su capacidad máxima, la mayor parte del agua se encuentra retirada de las partículas de suelo, así que se dice que el suelo está en equilibrio y por definición en este punto el potencial mátrico es cero (Townend et al., 2000). El agua comienza a ser removida del suelo por los poros más grandes. A medida de que el suelo drena, el agua va quedando atrapada en los poros más pequeños por atracción capilar entre el agua y las partículas de suelo, el potencial mátrico va creciendo y la energía requerida para seguir removiendo agua de

los poros más pequeños se va incrementando, así que el drenaje progresivo tiene como consecuencia un incremento en los valores del potencial mátrico. En este proceso no solo se van drenando poros de menor tamaño sino que también las películas de agua que recubren las partículas de suelo van disminuyendo su espesor.

Los mecanismos mediante los cuales el suelo retiene el agua en su interior pueden ser de naturaleza electroquímica o física. Estos mecanismos serán discutidos en la siguiente sección.

El termino succión o succión mátrica también es usado para representar este fenómeno, representa la misma cantidad pero es de signo positivo. En la Tabla 2-1 podemos ver las diferentes unidades usadas para medir la succión. Schofield (1935) propuso la escala pF, la cual es el logaritmo de la succión expresada en cm de agua. Esta escala es análoga a la del pH y es diseñada para evitar números largos, pero no ha sido universalmente adoptada (Townend et al., 2000).

Tabla 2-1 Factores de conversión para la engría de agua en el suelo, Townend (2000)

-1 kPa	-1 J/kg
	-0.01 bar
	-10 hPa
	-10.2 cm H <sub>2</sub> O a 20°C
	-0.75 cm Hg
pF	Log <sub>10</sub> (-cm H <sub>2</sub> O a 20°C)

### 2.2.2 Efectos de las Propiedades del Suelo

La curva de retención de agua es una propiedad que está fuertemente influenciada por las propiedades del suelo como la textura, la estructura y el tipo.

La cantidad de agua retenida a bajas succiones depende básicamente de los efectos de capilaridad y de la distribución del tamaño de poros, y por lo tanto es fuertemente afectada por la estructura del suelo (Townend et al., 2000). En un suelo arenoso que está drenando, los poros más gruesos son los primeros en liberar el agua, permitiendo la entrada de aire, lo cual genera un desbalance dinámico en las fuerzas de cohesión de las moléculas de agua que permanecen en el suelo, ya que dentro del líquido las moléculas experimentan vectores de fuerza iguales en todos los sentidos, mientras que en la superficie en contacto con la fase gaseosa, se produce una resultante de fuerza hacia el interior del líquido, produciendo meniscos en la superficie del agua que está en contacto con el sólido. La consecuencia de este proceso es la tendencia del suelo a succionar o retener el agua. Este proceso está orientado a explicar la influencia que la capilaridad y la distribución de tamaños de poros tienen sobre la curva de retención.

La discusión preliminar sugiere, que en el proceso de drenaje de suelos parcialmente saturados, los poros más grandes drenan primero, mientras que las fracciones de poros más pequeños mantienen el estado de saturación total con meniscos actuando en sus límites (Burland y Ridley, 1996). El proceso de drenaje según Burland puede ser ilustrado por la Figura 2.3.

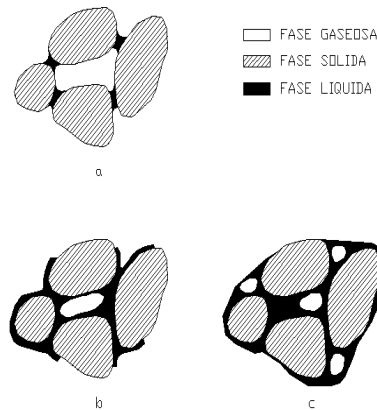


Figura 2.3. Proceso de drenaje en un suelo, Burland (1996)

La retención de agua a succiones altas se incrementa debido a los fenómenos de adsorción, y por lo tanto ésta más afectada por la textura del suelo y la superficie específica, en comparación con la estructura del suelo (Jain et al., 2004).

El proceso electro-químico de retención en las arcillas se presenta debido a la característica de poseer, en la mayoría de los casos, cargas eléctricas negativas en su superficie. Ésta carga, aunque débil, induce a las moléculas de agua, que son dipolares, a situarse a su alrededor y a orientarse con la carga positiva hacia la partícula sólida. La partícula ahora recubierta por una cohorte de moléculas de agua, es una esfera de mayor radio que la anterior cargada de la misma manera, pero con un potencial eléctrico menor debido al aumento de superficie; esta nueva esfera atrae más moléculas de agua y va formando cada vez esferas de mayor tamaño con una carga superficial menor. De este modo las partículas de suelo vecinas van quedando unidas por esta lámina de agua en cuya intersección se forma un menisco motivado por la tensión superficial del agua. Las moléculas más alejadas de la partícula de suelo están atraídas con una fuerza menor que las moléculas más cercanas, pero aun así estas fuerzas son más altas que las que intervienen en el proceso de drenaje de un suelo arenoso.

La mineralogía de la arcilla también es importante. Por ejemplo la montmorillonita con gran capacidad de intercambio catiónico y gran superficie específica tiene una mayor adsorción que la caolinita (Lambooy, 1984). El contenido de materia orgánica incrementa la cantidad de agua retenida, especialmente a bajas succiones, pero a succiones altas los suelos ricos en materia orgánica liberan el agua rápidamente. La presencia de óxidos de hierro libres y carbonatos de calcio también han mostrado afectar la curva característica (Stakman y Bishay, 1976; Williams et al. 1983), aunque los efectos del hierro libre son difíciles de separar de los efectos de altos contenidos

de arcilla y buenas condiciones estructurales con los cuales es asociado con frecuencia (Prebble and Stirk, 1959).

La discusión anterior nos indica que las arenas, por contener grandes poros, generalmente liberan el agua mucho más rápido y a bajas succiones mientras que los suelos arcillosos liberan pequeñas cantidades de agua a bajas succiones y cuando la succión se incrementa el contenido de agua decrece solo gradualmente. La Figura 2.4 muestra las curvas características, para cada tipo de suelo.




Figura 2.4. Curvas características para suelos con diferentes texturas, Pérez (2006)

Como conclusión se puede decir que el factor más importante, en el comportamiento de la retención de agua en una arena es el efecto de capilaridad, consecuencia de la tensión superficial (Tindall y Kunkel, 1999); la cual está vinculada directamente con el tamaño y la distribución de poros. Mientras en las arcillas el factor determinante en el comportamiento de la retención corresponde a efectos electro-químicos.

### 2.3 MÉTODOS DE DETERMINACIÓN

Existen tres métodos distintos para obtener las curvas de retención de un suelo. El procedimiento usual consiste en equilibrar muestras en un intervalo específico de potenciales y entonces determinar su contenido de humedad (someter muestras a diferentes presiones y determinar la humedad de equilibrio bajo estas presiones). Las mesas de presión, platos de presión y desecadores de vacío son algunos ejemplos de este método. En el segundo procedimiento, se permite que las muestras se sequen progresivamente y su potencial y contenido de humedad son medidos directamente (consiste en someter muestras a drenaje, para medir el contenido de humedad y la succión matricial al mismo tiempo y de manera directa). La tercera opción se refiere a modelos teóricos de curvas de retención de humedad, basados otros en parámetros medidos en los suelos, tales como distribución de tamaños de partículas y dimensión fractal obtenida del análisis de imágenes de muestras de suelo impregnadas con resinas

(Townend et al., 2000). En la Tabla 2-2 se encuentran discriminados diferentes métodos de medición de la curva de retención.

Tabla 2-2. Métodos de determinación de las curvas de retención, adaptado Townend (2000)

<b>Métodos Para Suelos Equilibrados a Un Potencial Mátrico Conocido</b>	<b>Succiones 0-1500 kPa</b>	Métodos de succión	<i>Embudo de Büchner</i>
			<i>Plato de poros de succión</i>
			<i>Tabla de succión de arenas</i>
		Métodos de presión de gas	<i>Plato extractor de presión</i>
	<i>Aparato de membrana de presión</i>		
	<b>Succiones &gt;1500 kPa</b>	<i>Membrana de presión</i>	
		<i>Transferencia de vapor</i>	
<b>Otros métodos de laboratorio</b>	<i>Osmosis</i>		
	<i>Consolidación</i>		
<b>Métodos de Medición Directa</b>	<i>Papel de filtro</i>		
	<i>Psicrómetro</i>		
	<i>Métodos de campo</i>		
<b>Métodos basados en modelos</b>	<i>Funciones De Pedotransferencia</i>		
	<i>Modelos fractales de la estructura del suelo</i>		

Se presenta a continuación una breve descripción de algunos de estos métodos.

### 2.3.1 Embudo de Büchner

Es la aplicación más simple del principio de succión. El aparato, fue introducido por Bouyoucos (1929) y más tarde adaptado por Haines (1930) para demostrar los efectos de histéresis, esta instalación aún se conoce como el aparato de Haines, (Russell, 1941; Burket et al., 1986; Danielson and Sutherland, 1986).

Un tipo de instalación está ilustrada en la Figura. 2.5. Consideremos una muestra de suelo que está en contacto con un disco de cerámica o un papel filtro que permite el paso de fluido, pero no de suelo. Este el disco se conecta a una bureta flexible mediante un tubo de PVC, que es conectado en un extremo a la base del embudo y en el otro extremo a la bureta abierta. La tubería debe ser flexible pero resistente a las deformaciones para evitar errores de medida. La tubería y el embudo se llenan con agua de manera que el nivel en la bureta sea el mismo que se tiene en la superficie del suelo, logrando así su condición saturada. La muestra de suelo saturada es puesta en contacto con el papel filtro o el plato cerámico. El nivel de agua en la bureta se mantiene al nivel de la superficie del suelo mientras esté saturado,

luego se procede a registrar el volumen en la bureta. Una succión,  $h$  cm de agua, puede ser aplicada si se cambia la posición de la bureta a una posición más baja. Existirá un gradiente entre el nivel del agua en la muestra de suelo y el nivel del agua en la bureta, lo que trae como consecuencia flujo de agua del suelo hacia la bureta, proceso que termina hasta que exista un equilibrio. El agua que fluye fuera de la muestra en respuesta a la succión aplicada, puede ser medida por un incremento en el volumen de agua en la bureta después de que el nivel de agua ha dejado de aumentar (Pérez, 2008).

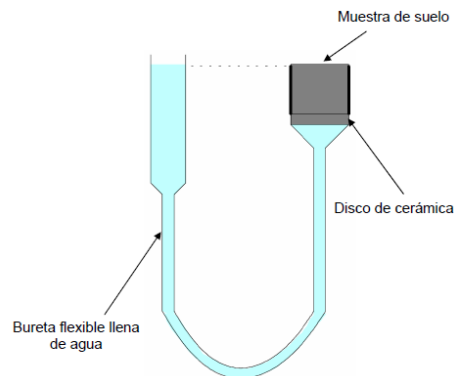


Figura 2.5. Esquema del embudo de Büchner, Pérez (2008)

Cambios no detectables en el nivel de agua en la bureta alrededor de 6 horas se toma como una definición satisfactoria de equilibrio (Vomocil, 1965), pero un periodo más corto sin cambios puede ser aceptable. Pequeñas pérdidas por evaporación a través del extremo abierto de la bureta pueden ser suprimidas adicionando unas pocas gotas de parafina líquida en el agua. Pérdidas por evaporación de la muestra pueden ser minimizadas cubriendo el extremo abierto del embudo. Repitiendo el ejercicio a incrementando la succión sucesivamente, una curva de retención característica puede ser graficada, calculando hacia atrás desde el contenido de humedad final de la muestra (determinado gravimétricamente) usando los volúmenes de agua extraídos entre dos succiones sucesivas.

Usando un papel filtro, la succión máxima que puede ser aplicada es solo de 50 a 70 cm de columna de agua antes de que ocurran entradas de aire alrededor de los lados del papel; pero usando un disco de cerámica porosa, la succión máxima alcanzable es mucho mayor, dependiendo de la presión de entrada de aire del disco. En la práctica, la máxima succión aplicada usando una inserción de cerámica está restringida por la distancia a la cual el nivel de la bureta puede ser bajado con respecto al embudo (i.e., típicamente  $< 200$  cm de agua).

La técnica del embudo de Buchner, además de ser muy conveniente para la enseñanza, es libre de problemas de costo y operación. Incluso con las limitaciones del uso del papel filtro, una curva puede ser obtenida. El volumen de agua extraído de algunos suelos entre succiones sucesivas podría ser muy pequeño y difícil de medir con precisión en la bureta. Una alternativa, posible si es usado el disco de cerámica porosa en el embudo de Buchner, es determinar el contenido de agua de la

muestra de suelo gravimétricamente después de que cada equilibrio sucesivo es alcanzado (Burke et al., 1986). Dado que el método del embudo de Büchner requiere un conjunto armazón por cada muestra de suelo, esto reduce la técnica a pequeñas investigaciones o laboratorios de enseñanza, donde normalmente no son analizadas un gran número de muestras. Sin embargo el método no debe ser rechazado para otras situaciones, su precisión y su bajo costo en material son algunas de sus bondades.

El problema más importante de aplicación de esta técnica de se refiere a la acumulación de aire disuelto debajo de los elementos separadores de presiones de fluido. Este fenómeno, conlleva a la progresiva pérdida de continuidad en la transferencia de la fase líquida debido a la acumulación de aire debajo de la cerámica.

### 2.3.2 Plato Poroso De Succión

Es una modificación del método anterior, que soporta más de una muestra de suelo al tiempo. Consiste en una placa de cerámica porosa metida dentro de un contenedor de acrílico transparente lleno de agua y con salida. El espacio entre la placa y el contenedor es mantenido lleno de agua, las burbujas de aire atrapado que se forman bajo plato pueden ser fácilmente vistas y removidas. Una cubierta para el conjunto reduce pérdidas por evaporación, y dependiendo del tamaño de la placa se pueden montar varias muestras al mismo tiempo. La succión se aplica generando, como en el caso anterior, un gradiente entre el nivel de agua en la muestra de suelo y el nivel de agua en una bureta conectada al sistema. La determinación del contenido de humedad en las muestras, para una succión dada, se hace gravimétricamente cuando estas ya han alcanzado la condición de equilibrio. Recuperar el contacto hidráulico entre las muestras y la placa después de ser pesadas, puede ser un problema. Este puede ser superado fijando una capa fina de yeso de París en la parte inferior de la muestra para proporcionar una base plana que pueda hacer buen contacto hidráulico con la placa, también se puede usar una fina capa de arena sobre la placa pero se debe tener cuidado de no remover arena adherida a la muestra cuando esta se va a pesar. Para succiones mayores a 10kPa se comienzan a presentar problemas con la acumulación de aire disuelto debajo de los elementos separadores de presiones de fluido. Este fenómeno conlleva a la progresiva pérdida de continuidad en la transferencia de la fase líquida debido a la acumulación de aire debajo de la cerámica y requiere de un sistema adecuado de control de este fenómeno. Quizás éste es el motivo que limita la adopción de este sistema.

### 2.3.3 Plato Extractor de Presión

Este método se compone de una olla o cámara que, cerrada herméticamente, recibe presión de aire o un gas inerte (N) desde un compresor. Ver Figuras 2.6 y 2.7. De esta manera, aplicando una presión se simula la condición de succión a la cual se ve sometida el agua en el suelo. Por el principio de translación de ejes, si se garantiza presión de agua igual a cero, la presión de aire (presión del gas) aplicada será igual a la succión matricial del suelo (50 kPa de presión de aire aplicada, son -50 kPa de succión matricial) (Townend et al., 2000).

La olla de presión, o plato de presión, está compuesta por un plato de cerámica poroso, cuya cara inferior está cubierta por un delgado diafragma de neopreno, con una red interna entre el plato y el diafragma que permite el flujo de agua. Un tubo interno comunica este conducto con un tubo de flujo externo que conecta la olla con la atmósfera, lo que permite la salida del agua, Figura 2.6. Sobre los platos de cerámica porosa, se colocan las muestras de suelo, las cuales deben saturarse durante varias horas. Los poros del plato permiten que se forme una continuidad líquida con los poros del suelo analizado para así poder evacuar el agua que es desplazada desde el suelo por la presión ejercida por el aire comprimido. El agua desplazada corresponde a aquella fracción del suelo que no es capaz de retener a una presión dada. De igual forma el agua que se queda retenida por el suelo a una determinada tensión. Una vez equilibradas las muestras a una presión determinada, se secan y se determina su contenido de agua (Espinoza, 2005). El sistema externo de operación se muestra en la Figura 2.7.




Figura 2.6. Vista de una sección del plato de cerámica del plato extractor de presión

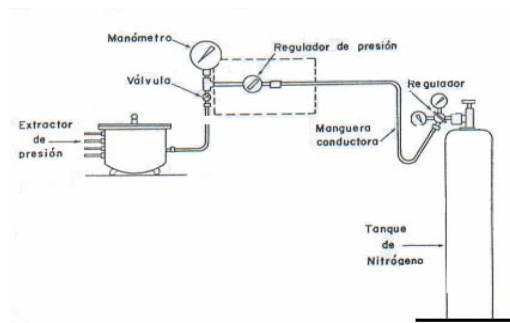


Figura 2.7. Vista general de los aditamentos del plato extractor de presión

### 3 REDES NEURONALES ARTIFICIALES RNA

#### 3.1 INTRODUCCIÓN

Desde su aparición en los años sesenta, las redes neuronales han tenido un gran desarrollo, y en los últimos años se han encontrado numerosas aplicaciones de estas en campos en los que no se creía que tuviesen utilidad. Esto ha hecho que cada vez se desarrollen más investigaciones alrededor de este campo, convirtiendo las redes neuronales en un concepto transversal, que puede atravesar muchos campos diferentes.

De forma general las redes neuronales son modelos matemáticos de procesamiento de información. Proveen un método para representar relaciones entre variables sin importar su naturaleza. Ya que las redes neuronales no ejecutan una secuencia de instrucciones, las redes neuronales reaccionan, aprenden y se auto-organizan.

Las aplicaciones más usuales de las RNA son en el campo de procesamiento de señales, robótica y matemática aplicada. Las RNA son una herramienta muy poderosa para modelar situaciones en las cuales la forma explícita de la relación entre ciertas variables aún es desconocida.

En la actualidad las redes neuronales se están usando en la predicción de caudales, modelos de series de tiempo, modelos de la relación lluvia-escorrentía en las cuencas y muchas otras aplicaciones, enmarcadas dentro de la hidroinformática.

Las redes neuronales no requieren diseño de un modelo matemático que relacione las variables que intervienen en el proceso. Ellas pueden aprender basadas en la experiencia o asociar patrones similares dentro de los datos, incluso si la información es difusa con ruido o inconsistente.

En este capítulo se presentarán algunas nociones básicas sobre redes neuronales, tales como su manera de funcionamiento, caracterización y algunos tipos. Se ahondará un poco en un tipo de red de especial interés para este trabajo llamada "Backpropagation".

#### 3.2 QUÉ ES UNA RNA

Una Red Neuronal artificial es un sistema de procesamiento de información que emula el proceso de aprendizaje del cerebro humano. El proceso de aprendizaje del cerebro humano se basa en unidades fundamentales llamadas neuronas, las cuales están interconectadas formando una red que genera el proceso de pensamiento (Fausett, 1994).

Los seres humanos tienen la habilidad de aprender de experiencias. A medida que éstas se acumulan sobre un tema en particular, se aprende a evaluar y ponderar de manera eficiente diferentes entradas que la situación pueda tener y así responder de manera cada vez más asertiva. Otro método de aprendizaje que posee el cerebro humano, el cual es

muy estudiado últimamente, es el de asociación. Los sonidos y los olores evocan momentos específicos, el cerebro asocia gente, lugares, situaciones, objetos y sensaciones para generar diferentes respuestas. De la misma manera las RNA (Redes Neuronales Artificiales) usan unidades fundamentales llamadas neuronas o nodos, interconectadas de diferentes maneras para procesar información usando ejemplos (experiencias) o asociaciones. Las RNA han sido desarrolladas como una generalización de los modelos matemáticos de la cognición humana o biología neuronal, basados en las siguientes presunciones (Fausett, 1994):

1. El procesamiento de la información se realiza a través de unidades fundamentales llamadas neuronas.
2. Las señales pasan entre neuronas a través de conexiones.
3. A cada conexión se asocia un peso, el cual, en una red neuronal típica, amplifica la señal transmitida.
4. Cada neurona aplica una función de activación (usualmente no lineal) a las entradas de la red (suma ponderada de las señales de entrada) para determinar las señales de salida.

Existe una alta analogía entre la estructura de una neurona biológica y la de un elemento de procesamiento (neurona artificial) (Delgado, 1998). A grandes rasgos una neurona biológica tiene 3 partes principales: El soma, las dendritas y el axón. Las dendritas son unas estructuras ramificadas dedicadas a recibir señales de otras neuronas. Las señales que envían las neuronas son impulsos eléctricos que se transmiten a través de conexiones sinápticas, estos impulsos se generan por un proceso químico. A través de las dendritas la acción de los neurotransmisores modifica la señal de entrada (generalmente escalando la frecuencia de las señales que son recibidas). El soma es el cuerpo de la neurona y es el encargado de sumar las señales que entran; cuando recibe suficientes entradas la célula se enciende, esto significa que transmite una señal a través de su axón a otras células. Muchas de las características de las RNA son ilustradas por las propiedades de las neuronas biológicas. Los elementos de procesamiento reciben muchas señales, las cuales pueden ser modificadas por los pesos de la sinapsis, dentro del elemento de procesamiento se suman las entradas ponderadas y bajo las circunstancias apropiadas (entradas suficientes) la neurona genera una señal de salida que puede ser transmitida a muchas otras neuronas a través de las ramas de los axones (Fausett, 1994). En la Figura 3.1 hay un esquema de una neurona biológica con algunas conexiones.




Figura 3.1. Representación esquemática de la arquitectura de una RNA y el sistema nervioso humano, Shrestha (2003)

Las Redes Neuronales Artificiales también están constituidas por elementos fundamentales llamados neuronas, o nodos. Cada neurona tiene un estado interno llamado activación (nivel de actividad), el cual es una función de las entradas que ha recibido. Ésta envía su estado de activación como una señal a otras neuronas a través de conexiones y cada conexión tiene asociado un peso. Los pesos son la información que la red usa (ajustándola) para resolver un problema. Generalmente, una neurona envía su activación como una señal a otras neuronas. Es importante notar que una neurona puede enviar solo una señal al tiempo, aunque esa señal es transmitida a varias neuronas.

La Figura 3.2 muestra una neurona artificial. Los nodos  $X_1$ ,  $X_2$  y  $X_3$  son quienes reciben los datos de entrada  $x_1$ ,  $x_2$  y  $x_3$ , para transmitirlos, sin ninguna alteración, a través de las conexiones a la neurona  $Y$ . Cada una de estas conexiones tienen asociado un peso, estos pesos o factores son ajustados durante su proceso de aprendizaje. La entrada a la neurona  $Y$  está dada por la suma de las entradas ponderadas

$$y_{input} = \sum_{i=1}^3 w_i \cdot x_i \quad 3-1$$




Figura 3.2. Representación esquemática de una neurona, Fausett (1994)

Al interior de la neurona se define una función de activación. La neurona aplica ésta función a la suma ponderada de las entradas  $y_{input}$ . Éste es el valor adoptado a la salida de la neurona.

$$s = f(y_{input}) = f\left(\sum_{i=1}^3 w_i \cdot x_i\right) \quad 3-2$$

En redes o neuronas cuyo entrenamiento es supervisado el algoritmo compara el valor a la salida de la neurona  $S$  contra un valor preestablecido (un valor deseado)  $T$  y calcula el error

$$e = S - T \quad 3-3$$

Este error sirve para ajustar los pesos de la neurona  $w_i$ .

Este es el funcionamiento básico de una neurona. Con estas simples operaciones y ajustando los pesos una red neuronal, ésta puede aprender y generalizar cualquier tipo de relación existente entre los patrones de entrada y salida. Al final del entrenamiento, cuando la serie de datos que se desea enseñar a la neurona ha sido presentada varias veces, esta ha ajustado los pesos hasta alcanzar un error admisible el cual es determinado por el diseñador de la red, se dice que la red ha sido entrenada así que al presentarle datos que no conocía se obtendrán respuestas correctas.

### 3.3 CARACTERIZACIÓN DE LAS REDES NEURONALES

Basadas en el mismo principio se han desarrollado diversos tipos de RNA para la solución de diferentes problemas. Es necesario conocer las características más importantes de las RNA para determinar su comportamiento y definir la adecuada para el problema que se desea solucionar. Según Laurene Faucett (1994), las características más importantes de una RNA son:

1. Arquitectura: El patrón o tipo de conexiones existentes entre las neuronas.
2. Algoritmo: Es el método o la forma de determinar los pesos en las neuronas.
3. Funciones de activación: Son también conocidas como funciones de transferencia.

#### 3.3.1 Arquitectura

Podemos definir una RNA como un arreglo de neuronas individuales ordenadas por capas. Generalmente las neuronas que se encuentran en la misma capa se comportan de la misma forma. Dentro de cada capa, las neuronas tienen la misma función de activación y el mismo patrón de conexiones con otras neuronas, es decir, todas las neuronas dentro de una misma capa pueden estar interconectadas entre sí o no estarlo, en cuyo caso estarían conectadas con las de la siguiente capa.

Lo que se conoce como la arquitectura de una red se refiere al arreglo de las neuronas dentro de las capas, el número de capas y los patrones de conexión que existen dentro y entre capas. Es importante aclarar que muchas de las redes neuronales tienen una capa de entrada en la cual la función de activación de cada unidad es igual a la señal de entrada externa de esa unidad. Esta capa no se cuenta como capa al definir la arquitectura de la red.

Según el número de capas las Redes Neuronales se pueden clasificar en Redes neuronales multicapa y Redes neuronales de una capa. En esta clasificación la capa de entrada no cuenta como capa cuando no genera ningún cálculo.

##### 3.3.1.1 Redes Neuronales De Una Capa

Las RNA de una capa se caracterizan por tener una sola capa de neuronas que generan cálculos computacionales (que computan datos), pueden tener o no unidades de entrada. Las redes neuronales de una capa, como la mostrada en la Figura 3.3, tienen una sola capa (conjunto o vector) de pesos, las unidades de entrada que transmiten los patrones de entrada presentados a la red y una capa de salida que es la que hace todo el trabajo.

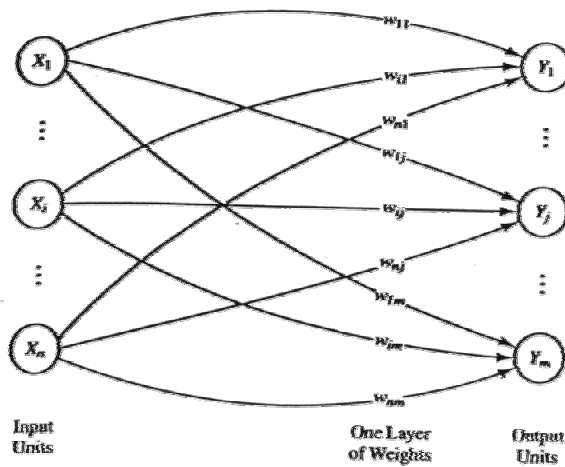


Figura 3.3. Red tipo Perceptrón, Fausett (1994),

Existen otros tipos de Redes neuronales de una capa, donde las unidades de entrada son las mismas unidades de salida Figura 3.4 (Fausett, 1994).




Figura 3.4. Red de Hopfield, Fausett (1994)

Las redes neuronales de una capa tienen una importante limitación y es que son competentes únicamente en la solución de problemas separables linealmente (Delgado, 1998).

### 3.3.1.2 Redes Neuronales Multicapa

Debido a la importante limitación que presentan las RN de una capa se desarrollan, posterior a estas, las Redes Neuronales Multicapa. Una RN multicapa consiste básicamente en un arreglo de varias capas de neuronas las cuales están interconectadas. La primera capa es la capa de entrada. La última capa es la capa de salida. Las otras son las capas llamadas ocultas, las cuales contienen las neuronas que hacen el cómputo de

los datos (Feng y Hong, 2007). La estructura de una RNA multicapas es mostrada en la Figura 3.5.




Figura 3.5. Representación esquemática de la arquitectura de una RNA multicapa, Fausett (1994)

Las RN multicapa son capaces de solucionar problemas más complejos que las RN de una capa. Funahashi demostró matemáticamente que una red neuronal multicapa puede aproximar cualquier función no lineal o mapa no lineal multivariable,  $f(x): \mathcal{R}^n \rightarrow \mathcal{R}^m$ . Este teorema es de existencia, pues prueba que la red existe pero no indica cómo construirla (Delgado, 1998).

### 3.3.2 Algoritmo

Además de la arquitectura, la forma en la que la red determina los pesos es fundamental para determinar el comportamiento de ésta. El método que la red usa para determinar sus pesos es lo que llamamos algoritmo de entrenamiento. Se pueden diferenciar dos grandes categorías de entrenamiento para una neurona o para una red neuronal, los algoritmos supervisados y los algoritmos no supervisados.

#### 3.3.2.1 Entrenamiento Supervisado

Los algoritmos de entrenamiento supervisado, quizás las más comunes (Salas, 2004) requieren presentar a la red una secuencia de patrones de entrada-salida deseados, es decir, que se presenta a la red la salida deseada para cada una de las entradas. En un proceso iterativo donde los pesos son ajustados según el algoritmo de entrenamiento. La red aprende cuando la salida de la red es aceptablemente cercana a los patrones de salida presentados.

### 3.3.2.2 Entrenamiento No Supervisado

En los algoritmos de entrenamiento no supervisado se presentan a la red una secuencia de patrones de entrada, no las salidas, y la red neuronal artificial agrupa los patrones similares, sin necesidad de indicarle a qué grupo pertenece cada patrón de entrada. La red neuronal extrae las características de las entradas y modifica los pesos de modo que vectores de entradas similares son asignados a un mismo grupo y a una misma salida. Las RN no supervisadas forman mapas o regiones. En la Figura 3.6 se muestra una red de Kohonen, la cual es una red de una capa con entrenamiento no supervisado (Delgado, 1998).




Figura 3.6. Red de Kohonen, Delgado (1998)

### 3.3.3 Funciones De Activación

Como fue mencionado anteriormente en este capítulo las operaciones básicas de una neurona artificial son la suma ponderada de sus entradas y la aplicación de una función de activación, también llamada de transferencia. Existen varios tipos de estas funciones que se describirán a continuación.

En las unidades o neuronas de entrada la función de activación es la función idéntica, ya que las unidades de entrada toman los patrones de entrada presentados a la red y los transmiten a las neuronas de las capas siguientes sin modificarlos:

$$f(x) = x$$

donde  $x$ : patrón de entrada a la neurona

3-4




Figura 3.7. Función idéntica

La mayoría de redes neuronales de una capa usan funciones de activación de tipo limitador duro también llamadas escalón o umbral, las cuales convierten variables continuas de entrada en una salida binaria (1 o 0) ó una salida bipolar:

$$f(x) = \begin{cases} 1, & y \geq 0 \\ 0, & y < 0 \end{cases} \quad 3-5$$

$$f(x) = \begin{cases} 1, & y \geq 0 \\ -1, & y < 0 \end{cases} \quad 3-6$$

donde  $y$  es la entrada en la neurona  $y = \sum_{i=1}^n (w_i \times x_i + w_0)$

Las funciones de activación con forma de S son usadas generalmente para entrenar redes neuronales multicapas, tales como la función logística y la función tangente hiperbólica (Fausett, 1994):

Función logística:

$$f(y) = \frac{1}{1 + e^{-y}} \quad 3-7$$

donde  $y$  es la entrada en la neurona  $y = \sum_{i=1}^n (w_i \times x_i + w_0)$




Figura 3.8. Función logística, Fausett (1994).

Función tangente hiperbólica:

$$f(y) = \frac{1 - e^{(-2y)}}{1 + e^{(-2y)}} \quad 3-8$$

donde  $y$  es la entrada en la neurona  $y = \sum_{i=1}^n (w_i \times x_i + w_0)$




Figura 3.9. Función tangente hiperbólica, Fausett (1994)

Las funciones de activación usadas en el entrenamiento de redes multicapa deben ser monotónicas, derivables y continuas (Hecht y Nielson, 1990)

### 3.4 ALGORITMO BACKPROPAGATION BP

El algoritmo de Backpropagation es ampliamente usado para modelar fenómenos naturales, ya que ajusta muy bien las relaciones entre los datos de entrada y los de salida sin importar la naturaleza de los datos, así como tampoco la relación que exista entre ellos (Delgado, 1998). Estos tipos de redes funcionan muy bien en casos de relaciones no lineales entre los datos de entrada y salida por ser redes de tipo multicapa y de paso adelante (Muzachiodi y Aranguren, 2003), lo que indica que las neuronas de una misma capa comparten las mismas conexiones de entrada y salida pero no están interconectadas entre ellas mismas, lo que indica que la información fluye hacia delante, de la capa de entrada hacia las capas ocultas y de las capas ocultas a la capa de salida no tiene conexiones hacia atrás ni conexiones paralelas dentro de una capa de neuronas. En la Figura 3.10 se muestra un esquema de una red de este tipo. El entrenamiento es del tipo supervisado, así que la red requiere que se le presenten patrones entrada - salida, para que ajuste sus pesos. Las funciones de activación usadas en este tipo de redes deben cumplir con lo especificado en la sección anterior. Como es el caso de la mayoría de las redes neuronales, el objetivo es entrenar una red para que alcance un adecuado balance entre la habilidad de responder correctamente a los patrones de entrada usados para entrenar la red (memoria) y la habilidad de dar respuestas razonablemente buenas a entradas similares, pero no idénticas, a las usadas en el entrenamiento (generalización) (Fausett, 1994).

El algoritmo de propagación inversa BP, fue desarrollado a partir de la ley general de aprendizaje basada en el gradiente, el cual toma un vector de pesos inicial  $w_k$ , calcula una función error y su gradiente, y luego obtiene un nuevo vector de pesos  $w_{k+1}$ , modificando el vector de pesos inicial en dirección opuesta al gradiente de la función error, por lo general la función error es el error cuadrático, aunque existen otras. El proceso se repite hasta que el error se encuentra en un límite determinado (Delgado, 1998). La ley general del aprendizaje basada en el gradiente se muestra a continuación:

$$w_{k+1} = w_k + \alpha \cdot (-\nabla_k)$$

3-9

El entrenamiento de una red usando BP emplea un ciclo de propagación – adaptación: primero se aplica un patrón de entrada como estímulo para la primera capa de las neuronas de la red, se va propagando a través de todas las capas hasta generar una salida. Seguidamente se compara el resultado obtenido en las neuronas de salida con los valores deseados o patrones de salida y se calcula un error para cada neurona en la capa de salida, luego se propaga el error hacia atrás, partiendo de la capa de salida, hacia todas las neuronas de la capa intermedia que contribuyan directamente a la capa de salida, recibiendo el porcentaje de error aproximado a la participación de la neurona intermedia en la salida original. Repitiéndose este proceso capa por capa hasta que todas las neuronas de la red hayan recibido un error que describa la aportación relativa al error total. Basándose en el valor del error recibido, se ajustan los pesos de conexión de cada neurona, de manera que la siguiente vez que se presente el mismo patrón, la salida se encuentre mas cercana a la deseada; es decir que el error disminuye (Aranguren y Muzachiodi, 2003).




Figura 3.10. Red neuronal Backpropagation con dos capas ocultas, Fausett (1994)

Después del entrenamiento, el uso de la red implica solamente el cálculo del paso adelante (feedforward), es decir, la aplicación del estímulo y su propagación hasta obtener una salida. Aunque el entrenamiento de las redes de tipo BP es generalmente lento, una red ya entrenada produce salidas de forma muy rápida. Existen muchas variaciones del algoritmo backpropagation, que han sido desarrolladas para incrementar la velocidad del proceso de entrenamiento (Fausett, 1994).

### 3.4.1 Arquitectura

Una red neuronal de tipo BP con una capa de unidades ocultas  $Z_j$  se muestra en la Figura 3.11. Las unidades de salida  $Y_k$  y las unidades de la capa oculta  $Z_j$  tienen

asociados los umbrales. El umbral en una unidad de salida típica  $Y_k$  se denota por  $w_{0k}$ ; el umbral en una unidad oculta típica  $Z_j$  se denota como  $v_{0j}$ . Estos umbrales actúan como pesos en conexiones cuyas unidades tienen una salida única de valor 1. Estas unidades se muestran en la Figura 3.11 pero generalmente no se muestra explícitamente. En la figura se muestra la dirección del flujo de información solo en el ciclo de paso adelante (feedforward). Durante la propagación inversa del error, las señales son enviadas en la dirección reversa (Fausett, 1994).




Figura 3.11. Red neuronal de tipo Backpropagation con una capa oculta, Fausett (1994).

### 3.4.2 Algoritmo

A continuación se describe el proceso de cálculo la red neuronal de la Figura 3.11. Para ver el algoritmo de entrenamiento paso a paso ver el Anexo A.1.

En el paso adelante, cada unidad de entrada  $X_i$  recibe un impulso o patrón de entrada y lo transmite a cada una de las unidades en la capa oculta  $Z_1 \dots Z_p$ . Cada unidad en la capa oculta pondera sus entradas, le aplica la función de activación y envía esta señal  $z_j$  a cada unidad de salida. Cada unidad de salida  $Y_k$  computa sus datos de entrada, como lo hacen los nodos de la capa oculta, y genera la respuesta de la red  $y_k$  para un patrón de entrada dado.

Ahora cada unidad de salida compara su salida  $y_k$  con el valor esperado, patrón de salida,  $t_k$  para determinar el error asociado para ese patrón con esa unidad. Basados en este error, se calcula el factor  $\delta_k$  ( $k = 1, \dots, m$ ) que es la función del error, generalmente el error cuadrático.  $\delta_k$  es usado para distribuir el error de las unidades de salida  $Y_k$  hacia atrás, es decir, hacia a todas las unidades en la capa anterior (las unidades de la capa oculta que están interconectadas a  $Y_k$ ). También es usado para actualizar los pesos entre la salida y la capa oculta. De manera similar se calcula el factor  $\delta_j$  ( $j = 1, \dots, p$ ) para cada unidad de la capa oculta  $Z_j$ , este valor incluye información de  $\delta_k$ . No es necesario propagar el error hasta la capa de entrada, ya que  $\delta_j$  será usado para actualizar los pesos entre la capa oculta y la capa de entrada.

Después de que todos los factores  $\delta$  han sido determinados, los pesos para todas las capas son ajustados de manera simultánea. Las actualizaciones de los pesos  $w_{jk}$ , de las unidades de la capa oculta  $Z_j$  hacia las unidades de la capa de salida  $Y_k$ , se basan en los factores  $\delta_k$  y las señales  $z_j$ , de la capa oculta  $Z_j$ . Las actualizaciones de los pesos  $v_{ij}$ , de las unidades de la capa de entrada  $X_i$  hacia las unidades ocultas  $Z_j$ , se basan en los factores  $\delta_j$  y las señales  $x_i$ , de la capa de entrada  $X_i$ .

## 4 ANÁLISIS DE LOS DATOS Y DESARROLLO DEL MODELO DE RED NEURONAL ARTIFICIAL

### 4.1 INTRODUCCIÓN

Al generar un modelo de redes neuronales que represente de manera adecuada determinado fenómeno o proceso natural, es básico el análisis de los datos a usar. Dependiendo de la calidad y cantidad de estos se hace el desarrollo posterior. Es necesario tener una base de datos para generar el modelo de redes neuronales que represente determinado fenómeno. Para el desarrollo de los modelos de curvas de retención usando redes neuronales artificiales se usaron los datos de curvas de retención tomadas en laboratorio en el proyecto de investigación “Estudio Del Comportamiento Mecánico De Suelos Parcialmente Saturados”, desarrollado en la Universidad Nacional De Colombia. Los datos corresponden a curvas de retención en suelos granulares en etapa de secado.

Dependiendo de la cantidad y calidad de los datos, y conociendo el modelo conceptual que rige el proceso se puede proponer una RNA adecuada para el objetivo. El presente trabajo pretende entrenar una red neuronal que modele la curva de retención de humedad a partir de los datos medidos en el laboratorio. Se propone el uso de una red tipo backpropagation, esta determinación será sustentada en la sección 4.3.

En este capítulo se describe como fueron obtenidos los datos con los que se va a trabajar, así como también la metodología usada en la determinación de los parámetros y la arquitectura de las redes diseñadas.

### 4.2 ENSAYOS DE LABORATORIO

Como se mencionó anteriormente, el conjunto de datos usados para modelar las curvas de retención proviene de los ensayos realizados en la Universidad Nacional de Colombia por Barrera y Muñoz en 2003. Las consideraciones que se evaluaron para determinar que los suelos en estudio fueran arenas limpias, con diferentes granulometrías que varían entre tamaños de 0.84 mm, tamiz retiene #30, y 0.074 mm, tamiz retiene #200 se pueden encontrar en el Anexo A.2. Se trabajo con tres diferentes granulometrías, teniendo en cuenta dos variables: la primera, el tamaño de los poros, y, la segunda su organización o distribución (Donado, 2004). Las granulometrías ensayadas se describen a continuación:

1. *Arena uniformemente gradada de grano fino AFU*: Retenido por el tamiz número 100 (0.15mm) y pasa tamiz número 80 (0.18mm).
2. *Arena uniformemente gradada de grano medio AMU*: Retenido por el tamiz número 30 (0.6mm) y pasa tamiz número 40 (0.42mm).
3. *Arena de diferentes tamaños de partícula ADTP*: Se buscó llegar a la formación de una arena bien gradada, cumpliendo con los requisitos mostrados en el anexo A.3

La Tabla 4-1 corresponde a las gradaciones de los 3 suelos estudiados y la Figura 4.1 ilustra y complementa la tabla 3.

Tabla 4-1. Distribución granulométrica de los suelos en estudio, Donado (2004)

Tamiz	Tamaño de partícula (mm)	% que pasa		
		Arena de diferentes tamaños de partícula ADTP	Arena uniforme Grano medio AMU	Arena uniforme Grano fino AFU
20	0,84	100,00	100,0	100,0
30	0,6	60,00	0,0	100,0
40	0,425	30,00	0,0	100,0
50	0,3	20,00	0,0	100,0
60	0,25	17,00	0,0	100,0
70	0,21	14,00	0,0	100,0
80	0,18	13,00	0,0	100,0
100	0,15	10,00	0,0	0,0
200	0,074	0,00	0,0	0,0

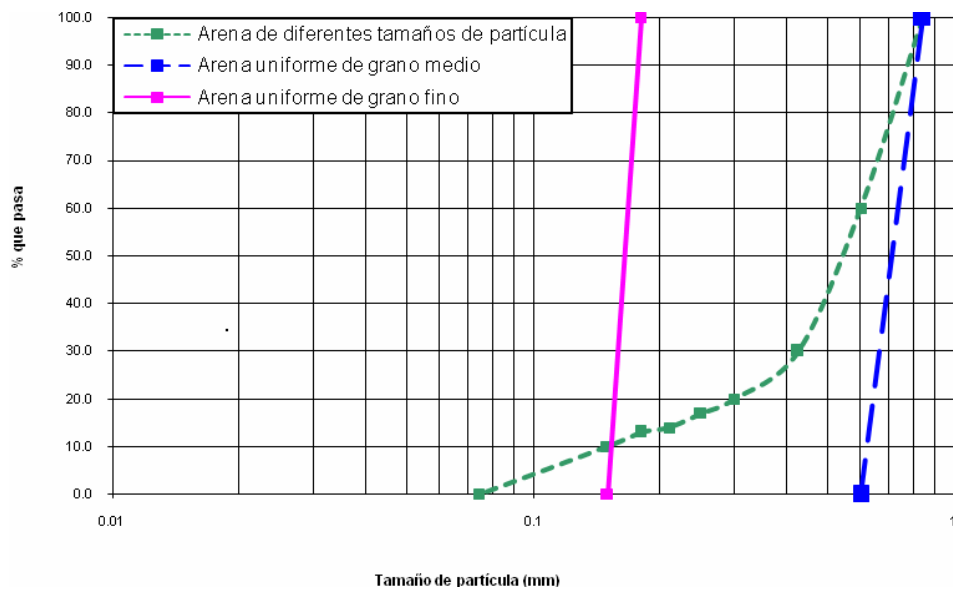


Figura 4.1. Distribución granulométrica de los suelos en estudio, Donado (2004)

El método de preparación de muestras usado fue el llenado a mano que garantiza la reproducibilidad en todos los resultados de los ensayos, los análisis realizados para la determinación de este método correcto para la preparación de muestras se encuentran en

el Anexo A.4. Se evaluaron la porosidad y la relación de vacíos. La Tabla 4 muestra los valores para cada tipo de suelo estudiado. En el Anexo A.5 se encuentran los detalles sobre esta evaluación.

Tabla 4-2. Relación de vacíos y porosidad de los suelos en estudio, Barrera y Muñoz (2003)

Arena	Relación de vacíos	Porosidad (%)
Uniforme grano medio	0.66	40 %
Uniforme grano fino	0.85	46 %
De diferentes tamaños de partícula	0.60	37 %

Finalmente se determinó la humedad de equilibrio en condición saturada, la cual se refiere a la cantidad máxima de agua que se puede almacenar dentro de los espacios vacíos de la matriz del suelo ( $S= 100\%$ ). En las curvas de retención de humedad, este valor se encuentra, cuando el suelo saturado presenta a un valor de succión igual a cero. Para el presente proyecto, la determinación de la humedad de equilibrio se realizó mediante dos métodos. En el Anexo A.6 se encuentra la información sobre estos ensayos, en la Tabla 4-3 se muestran los resultados conseguidos en laboratorio.

Tabla 4-3. Contenido volumétrico de agua en condición saturada, Barrera y Muñoz (2003)

ARENA	CONTENIDO VOLUMÉTRICO DE AGUA EN	
	CONDICIÓN SATURADA $\theta_s$	
	SEGÚN METODO DIRECTO	SEGÚN METODO INDIRECTO
Uniforme de grano fino	47,26%	46,05%
Uniforme de grano Medio	25,64%	41,20%
Diferentes tamaños de partícula	32,40%	37,36%

#### 4.2.1 Determinación De Las Curvas De Humedad En El Laboratorio

A continuación se presenta una breve descripción de los procedimientos experimentales usados para la obtención del conjunto de datos de la curva de retención de agua en las arenas a modelar mediante RNA. El conjunto de datos para entrenar las redes consiste en las parejas entrada – salida necesarias para entrenar la red, que en este caso, corresponden al contenido volumétrico de humedad y succión matricial respectivamente. La curva de retención de agua en el suelo describe la relación que existe entre un determinado contenido de agua y la fuerza con la que es atraída por la matriz de suelo. Cuando un suelo saturado se somete a una succión determinada, se inicia un proceso de drenaje; cuando el suelo deja de drenar, para un valor de succión dado, en el suelo persiste un contenido de humedad que está asociado a esta succión llamado humedad de equilibrio. Usando métodos para suelos equilibrados a un potencial mátrico conocido, sección 2, se obtiene el contenido de humedad de equilibrio para diferentes valores de succión.

Para la medición de las propiedades de retención de los suelos en estudio se usaron dos métodos. El primero es las ollas de presión (Figura 4.2), y el segundo es la mesa de succión (Figura 4.3); ambos métodos fueron explicados en la sección 2.3. El método de ollas de presión se usó para medir las succiones en un rango entre 1 y 15 kPa. Para los valores de succión menores o iguales a 1kPa se usó la mesa de succión. El procedimiento detallado de preparación de muestras y montajes se puede ver en el anexo A.7.



Figura 4.2. Ensayo de olla de presión, Barrera y Muñoz (2003)




Figura 4.3. Ensayo mesa de succión, Barrera y Muñoz (2003)



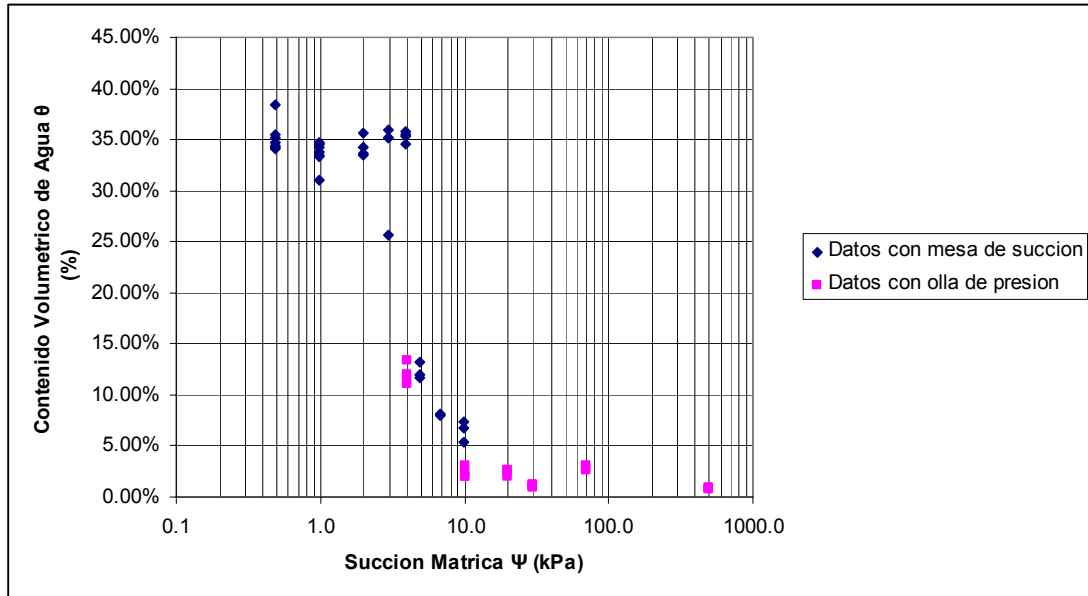


Figura 4.6. Datos experimentales de la curva de retención en arenas diferentes tamaños de partícula

### 4.3 DEFINICIÓN DE PARÁMETROS DE LAS RNA

Para modelar las curvas de retención de agua para los suelos granulares ensayados, AFU, AMU y ADTP se propone usar una red de tipo BP para cada uno de los tipos de suelo. Según Hsu et al., (1995), una red neuronal de feedforward puede ser usada para modelar satisfactoriamente relaciones funcionales del mundo real (Jain et al., 2004) y la naturaleza del problema analizado encaja en esta definición. Para definir la arquitectura de la red es necesario determinar el número de neuronas en la capa de entrada, en la capa de salida y en cada capa oculta, al igual que el número de capas ocultas.

Con una neurona en la capa de entrada, correspondiente al conjunto de datos de entrada que se propone sean los contenidos volumétricos de agua; una neurona en la capa de salida, correspondiente al conjunto de datos de salida que serían los datos de succión, y una capa oculta; se comienza a definir la arquitectura de la red. El argumento principal para utilizar una BP con una capa oculta es que éstas pueden aproximar una función continua dentro de cualquier intervalo cerrado, (Hecht y Nielson, 1989); dado que definir una red problema de optimización, se podrían usar más de una capa oculta, pero resultaría ocioso o excesivo.

Cuando se trabaja con redes neuronales es recomendable hacer un pre proceso a los datos tanto de entrada como de salida. El conjunto de datos  $\theta-\Psi$  de la curva de retención de los suelos aquí usados fueron normalizados antes del proceso de entrenamiento de la red. Los valores de contenido volumétrico de agua fueron normalizados de la siguiente manera:

- El conjunto de datos se lleva a un conjunto de datos con media cero. Se calcula la media del conjunto de datos y se le resta a cada dato; dejando así un nuevo conjunto con media cero.

$$\theta_{media0} = \theta - \bar{\theta} \quad 4-1$$

- Se escalan los datos en un intervalo entre 0 y 1 ya que se va a usar la función logística como función de transferencia, usando la siguiente fórmula:

$$\theta_N = (\theta_{media0} - \theta_{min}) / (\theta_{max} - \theta_{min}) \quad 4-2$$

Los valores de succión también fueron normalizados y escalados con el siguiente procedimiento:

- Dado que el intervalo de valores para la succión es muy extenso, lo primero que se hace es aplicar la función logaritmo natural (ln), con el fin de reducir éste intervalo.
- Cuando los datos de succión ya se encuentran en un intervalo más pequeño, se calcula la media del conjunto de datos y se le resta a cada dato, dejando así un nuevo conjunto con media cero.

$$\Psi_{media0} = \Psi - \bar{\Psi} \quad 4-3$$

- Finalmente se escalan a valores entre 0 y 1 tal como se procedió con los datos de contenido volumétrico de agua.

$$\Psi_N = (\Psi_{media0} - \Psi_{min}) / (\Psi_{max} - \Psi_{min}) \quad 4-4$$

El conjunto de datos  $\theta$ - $\Psi$  obtenidos después de este proceso de normalización se muestran en las Figuras 4.7, 4.8, 4.9. En el anexo A.9 se encuentran las tablas de valores usados para el entrenamiento de las redes, así como un cálculo tipo de uno de éstos valores. Para cada una de las redes que se desea entrenar se tienen conjuntos de aproximadamente 60 parejas de datos. Todos estos fueron usados para entrenar la red.

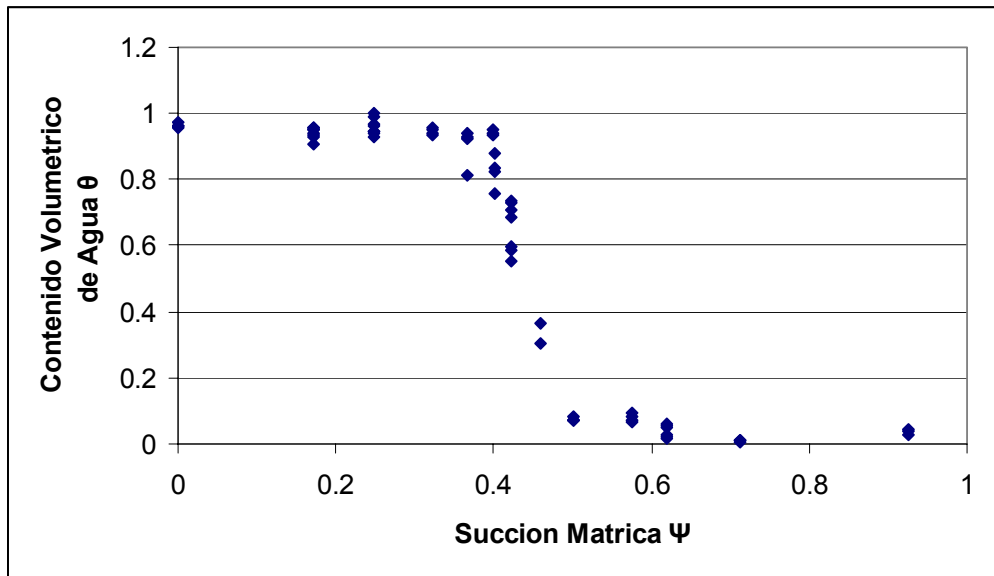


Figura 4.7. Datos experimentales AFU escalados usados para entrenar la red

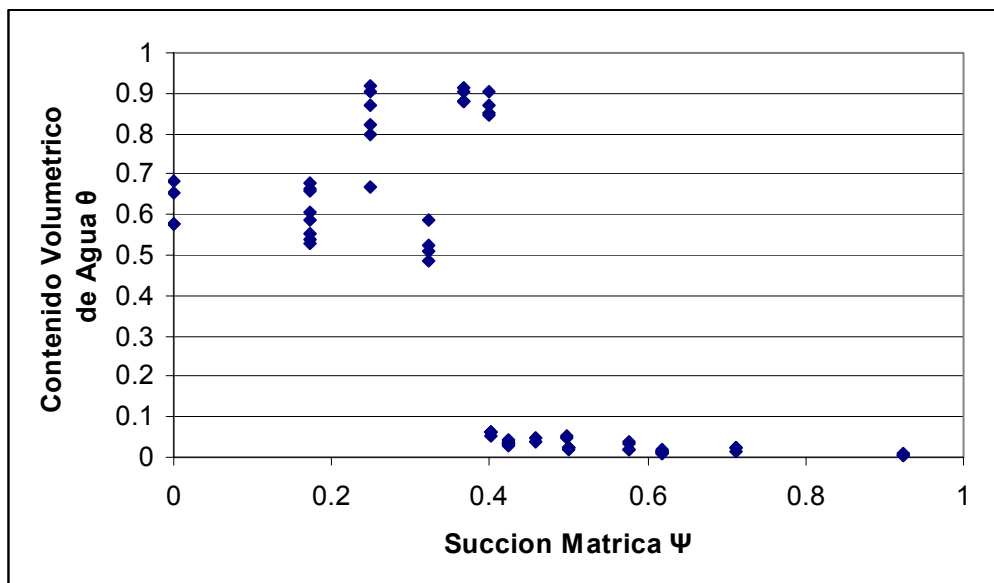


Figura 4.8. Datos experimentales AMU escalados usados para entrenar la red




Figura 4.9. Datos experimentales ADTP escalados usados para entrenar la red

Como se mencionó anteriormente, el algoritmo de entrenamiento que se va a usar es el backpropagation, también se mencionó que este algoritmo actualiza los pesos usando el gradiente de la función error. Se define como función error el mínimo error cuadrático sobre la totalidad de los ejemplos de entrenamiento.

$$E = \frac{1}{N} \sum_{k=1}^N (\Psi^{calc} - \Psi^{medid})^2 \quad 4-5$$

donde;

$N$ = numero de patrones de entrenamiento

$\Psi^{calc}$ = Valor de salida en la red, en este caso será succión mátrica.

$\Psi^{med}$ = Valor patrón de salida presentado a la red, en este caso serian los datos de succión medidos en el laboratorio.

La función de transferencia en la capa oculta es la función logística, esto atendiendo al hecho de que los datos de entrada fueron escalados en el intervalo de 0 a 1, el cual es el intervalo de valores en el que trabaja la función logística.

$$f(y) = \frac{1}{1 + e^{-y}} \text{ donde } y \text{ es la entrada en la neurona } y = \sum_{i=1}^n (w_i \times x_i + w_0) \quad 4-6$$

El número de neuronas de la capa oculta fue determinado, como muchos parámetros de las RNA, a ensayo y error. Existen algunas teorías sobre el mínimo de neuronas que debe tener una red en su capa oculta (Kolmogorov), pero estos son sólo valores de referencia, la cantidad de neuronas en la capa oculta se determina empíricamente.

En la actualidad existen muchos programas que manejan redes neuronales. En este caso específico, se utilizó la herramienta de Matlab (licencia de la Universidad Nacional), para entrenar y probar las redes. Una modificación en el algoritmo de BP llamada BP con Levenberg-Marquardt se utilizó para mejorar la velocidad de convergencia de la red, ya que tiene una eficiente implementación en Matlab (Demuth et al., 2008).

4.3.1 Arquitectura RNA para la curva AFU

La Figura 4.10 muestra la arquitectura definitiva de la RNA entrenada para modelar los datos de la curva de retención para la arena fina uniforme. Con una neurona en la capa de entrada, 18 neuronas en la capa oculta, una neurona en la capa de salida, una función de transferencia logística en la capa oculta, una función de transferencia lineal en la capa de salida, 8785 iteraciones y después de presentarle a la red 8785 veces los patrones de entrenamiento, el error alcanzado por esta red fue  $E=0.0045$ . La Figura 4.11 generada por Matlab, muestra la disminución del error cuadrático durante el entrenamiento de la red, la línea azul representa el entrenamiento y la línea negra es el límite de error que debe alcanzar la red. Tanto en el caso de la red entrenada para AFU como para las correspondientes a AMU y ADTP límite del mínimo error cuadrático, o goal, que se adoptó fue el menor que se podía alcanzar con los datos con los que se contaba.




Figura 4.10. Arquitectura RNA para datos AFU




Figura 4.11. Grafica del entrenamiento de la red para AFU

### 4.3.2 Arquitectura RNA para la curva AMU

La Figura 4.12 muestra la arquitectura definitiva de la RNA entrenada para modelar los datos de la curva de retención para la arena media uniforme. Con una neurona en la capa de entrada, 10 neuronas en la capa oculta, una neurona en la capa de salida, una función de transferencia logística en la capa oculta, una función de transferencia lineal en la capa de salida, 821 iteraciones y después de presentarle a la red 821 veces los patrones de entrenamiento, el error alcanzado por esta red fue  $E=0.004$ . La Figura 4.13 muestra la disminución del error cuadrático durante el entrenamiento de la red.




Figura 4.12. Arquitectura RNA para datos AMU




Figura 4.13. Grafica del entrenamiento de la red para AMU

### 4.3.3 Arquitectura RNA para la curva ADTP

La Figura 4.14 muestra la arquitectura definitiva de la RNA entrenada para modelar los datos de la curva de retención para la arena con diferentes tamaños de partícula. Con una neurona en la capa de entrada, 8 neuronas en la capa oculta, una neurona en la capa de salida, una función de transferencia logística en la capa oculta, una función de transferencia lineal en la capa de salida, 2149 iteraciones y después de presentarle a la red 2149 veces los patrones de entrenamiento, el error alcanzado por esta red fue  $E=0.004$ , la Figura 4.15 muestra la disminución del error cuadrático durante el entrenamiento de la red.




Figura 4.14. Arquitectura RNA para datos ADTP




Figura 4.15. Grafica del entrenamiento de la red para ADTP

## 5 RESULTADOS Y DISCUSIÓN

### 5.1 INTRODUCCIÓN

El objetivo principal de este trabajo es implementar un sistema de redes neuronales para determinar las curvas de retención de agua en arenas limpias. Para este fin se tomaron los resultados de ensayos de laboratorio realizados sobre 3 tipos de arenas. Se propuso ensayar una red neuronal para cada tipo de arena y se determinó el algoritmo adecuado para generar el modelo respectivo.

Al modelar sistemas con RNA, se hace referencia a un tema de optimización, es decir, se entrenan muchas arquitecturas para determinar la que mejor describe el proceso y requiere menos recursos. Para el presente trabajo se ensayaron diez arquitecturas por cada tipo de suelo, cada una del tipo Backpropagation BP. Las secciones 4.3.1, 4.3.2, 4.3.3, presentan las que logran una mejor adaptación a los objetivos de este trabajo. Los parámetros que controlaron la optimización corresponden al error medio cuadrático sobre los datos, la cantidad de neuronas en la capa oculta y la capacidad de generalización de la red.

En este capítulo se pretende analizar los resultados obtenidos modelando las CRA por medio de redes neuronales. Para esto se comparan los resultados obtenidos con la RNA con los datos tomados en laboratorio. Se comparan los resultados obtenidos con la simulación de la curva teórica Fredlund y Xing (1994).

### 5.2 RESULTADOS DE LA RED ENTRENADA PARA AFU

#### 5.2.1 Modelo De La RNA Con Los Datos Medidos En El Laboratorio

La Figura 5.1 muestra los datos medidos en laboratorio correspondientes a la curva de retención para arena fina uniforme. En la Figura 5.2 se pueden ver los datos generados por la red correspondiente a las mediciones hechas en laboratorio. Al detallar las Figuras 5.3 y 5.4 se pueden comparar los resultados obtenidos usando la red neuronal con los datos medidos en laboratorio. En la Figura 5.3 se pueden ver como los datos de la red se ajustan a la tendencia de los datos del laboratorio con muy buena precisión, ya que el error mínimo cuadrático que se consiguió con esta red, corresponde a un valor de 0.0045. Como se muestra en el Anexo A.10.1 donde se encuentran los valores correspondientes a estas figuras, se aprecia que el error máximo es de 0.2521, pero los errores como éste son muy pocos, ya que la mayoría de los errores se encuentran por debajo de éste valor. La curva de dispersión respalda esta afirmación, ya que si bien no todos los datos caen sobre la recta, la dispersión de los datos es pequeña y todos se encuentran próximos a la recta.

# DETERMINACION DE LA CURVA DE RETENCION DE AGUA DE SUELOS GRANULARES USANDO REDES NEURONALES ARTIFICIALES




Figura 5.1 CRA datos medidos en laboratorio




Figura 5.2 CRA datos estimados por RNA




Figura 5.3 CRA para AFU medidos en el laboratorio y estimados por la red




Figura 5.4 Diagrama de dispersión de datos para la CRA en AFU. Ilustra la precisión en la estimación de la RNA

### 5.2.2 Modelo De La RNA Con Los Datos De La Curva Teórica Propuesta Por Fredlund y Xing

La Figura 5.5 muestra los datos obtenidos a partir de la curva teórica de Fredlund y Xing (1994), la cual es un modelo que se genera a partir de la caracterización directa de las propiedades de retención (Barrera y Muñoz, 2003). Se simularon los datos de contenido volumétrico de humedad de la curva teórica en la red entrenada para los datos de laboratorio y se obtuvieron los resultados mostrados en las Figuras 5.6 y 5.7. Al comparar los resultados obtenidos con las RNA con los datos de la curva teórica, se puede ver que la RNA aprendió la tendencia y la relación existente entre los datos de entrada y salida, por esta razón se aproxima de manera razonablemente buena a la curva teórica. La Figura 5.8 muestra la dispersión de los datos obtenidos con la curva teórica contra los datos estimados de esta curva usando RNA; en este caso se tienen unos puntos que no se ajustan a los valores esperados pero en general se puede decir que la red aproxima adecuadamente a la curva teórica. Las tablas de datos correspondientes a estas gráficas se encuentran en el anexo A.10.1.




Figura 5.5 CRA generada con el modelo teórico




Figura 5.6 CRA datos estimados por la RNA para el modelo teórico




Figura 5.7 CRA para AFU según modelo teórico de Fredlund Y Xing y estimación del modelo por la red




Figura 5.8 Dispersión de datos para la CRA teórica en AFU. Ilustra la precisión en la estimación de la RNA

La Figura 5.9 es una superposición de los resultados obtenidos por todos los métodos, tanto los medidos en el laboratorio como los de la curva teórica y los estimados por la RNA

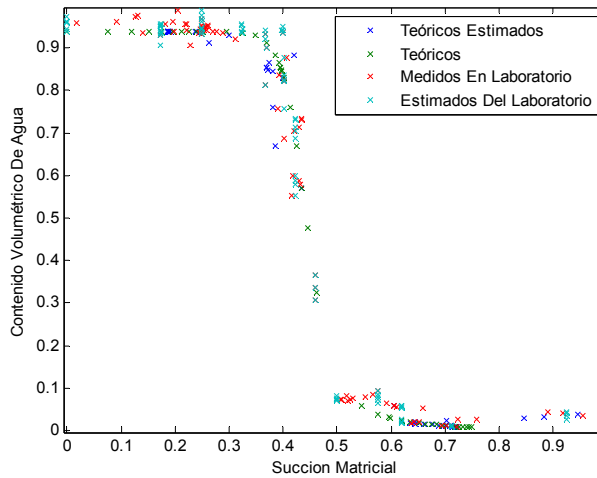


Figura 5.9 CRA para AFU todos los métodos de determinación

### 5.3 RESULTADOS DE LA RED ENTRENADA PARA AMU

#### 5.3.1 Modelo De La RNA Con Los Datos Medidos En El Laboratorio

En la Figura 5.10 se ilustran los datos medidos en laboratorio para las curvas de retención de agua en arenas medias uniformes. Con una evaluación a priori de los datos, se puede determinar que tienen errores en su medición, así que se puede esperar que la red que se entrene para modelar éstos, no se ajuste de manera adecuada. En la Figuras 5.11 y 5.12 se encuentran los resultados de los datos estimados por la red. En la Figura 5.11 se

puede ver claramente que después del proceso de entrenamiento la red determina, basada en los datos de laboratorio y que existen dos tendencias en la zona de capilaridad de la curva que están muy bien demarcados; que los resultados obtenidos son mucho mejores de lo que se esperaba. Si bien la curva generó una tendencia que no existe, fue una respuesta a los datos con los que fue entrenada. La Figura 5.13 muestra la dispersión de los datos medidos contra los datos esperados. El error máximo es de 0.1688 y los valores correspondientes a estas graficas se encuentran en el anexo A.10.2.




Figura 5.10 CRA datos medidos en laboratorio




Figura 5.11 CRA datos estimados por la RNA




Figura 5.12 CRA para AMU medidos en el laboratorio y estimados por la red




Figura 5.13 Diagrama de dispersión de datos para la CRA en AMU. Ilustra la precisión en la estimación de la RNA

### 5.3.2 Modelo De La RNA Con Los Datos De La Curva Teórica Propuesta Por Fredlund y Xing

La simulación de la red con los datos teóricos (Figuras 5.14, 5.15, 5.16), produce resultados satisfactorios. En la Figura 5.15 se puede observar como la red aprendió dos tendencias en la zona de capilaridad y así simuló los datos teóricos. En términos de ajuste a la curva teórica, no corresponde con los resultados deseados, pero muestra que la red generalizó las relaciones aprendidas con los datos de laboratorio y definió dos ramificaciones en la zona capilar. Si bien no corresponde a la realidad de la CRA, la red está respondiendo a los parámetros con los que fue entrenada y lo está haciendo de forma adecuada. En la Figura 5.16 se puede ver cómo también está ajustándose bien a los datos de la curva teórica en la ramificación superior, fenómeno que sí corresponde al comportamiento de la curva de retención. La Figura 5.17 muestra el diagrama de dispersión para los datos teóricos. La Figura 5.18 es una superposición de los datos de la curva de retención, evaluados por los métodos usados en esta investigación. Pese al ruido en los datos, la red limpia la señal y determina dos ramificaciones en la parte superior de la curva (zona capilar). La tabla de los datos teóricos de la curva y los estimados teóricos se encuentran en el anexo A.10.2.




Figura 5.14 CRA generada con el modelo teórico




Figura 5.15 CRA datos estimados por la RNA modelo teórico




Figura 5.16 CRA para AMU según modelo teórico de Fredlund Y Xing y estimación del modelo por la red




Figura 5.17 Diagrama de dispersión de datos para la CRA en AMU. Ilustra la precisión en la estimación de la RNA




Figura 5.18 CRA para AMU todos los métodos de determinación

## 5.4 RESULTADOS DE LA RED ENTRENADA PARA ADTP

### 5.4.1 Modelo De La RNA Con Los Datos Medidos En El Laboratorio

Los resultados de la simulación de los datos de la red entrenada, para los datos de laboratorio de la ADTP, se encuentran en la Figura 5.20, los datos obtenidos en el laboratorio se encuentran en la Figura 5.19. En la Figura 5.21 se comparan la CRA de los datos medidos en el laboratorio con los datos estimados por la red neuronal, el diagrama de dispersión de los datos se presenta en la Figura 5.22 e indica que la red aproxima adecuadamente los datos medidos, ya que se tiene una tendencia en los datos de la forma  $Y=X$ , y si bien no todos se ubican sobre la recta, la dispersión es pequeña. Aquí se puede ver que en la parte alta de la zona de desaturación y en la zona de capilaridad los datos tienen mucho ruido.

El valor más grande de error es de 0.24454. En el anexo A.10.3 se pueden encontrar los datos correspondientes a estas gráficas con sus respectivos errores.




Figura 5.19 CRA datos medidos en laboratorio




Figura 5.20 CRA datos estimados por la RNA




Figura 5.21 CRA para ADTP medidos en el laboratorio y estimados por la red




Figura 5.22 Diagrama de dispersión de datos para la CRA en ADTP. Ilustra la precisión en la estimación de la RNA

#### 5.4.2 Modelo De La RNA Con Los Datos De La Curva Teórica Propuesta Por Fredlund y Xing

La Figura 5.24 muestra la curva retención de agua en arenas con diferentes tamaños de partícula, determinada usando el modelo teórico de Fredlund y Xing (1994). En la Figura 5.23 se muestra la gráfica de los valores simulados por la red para la curva teórica. Si se observa la Figura 5.25 se pueden comparar los resultados del modelo de RNA con la curva teórica, pero infortunadamente el ajuste no es bueno, lo que indica que la red está generalizando de una manera muy pobre. Esto se debe a que los datos en la parte alta de la curva de succión, zona de desaturación y de capilaridad, tienen mucho ruido y la red no aprendió adecuadamente el patrón de comportamiento de los datos.




Figura 5.23 CRA generada con el modelo teórico




Figura 5.24 CRA datos estimados por la RNA para el modelo teórico




Figura 5.25 CRA para ADTP según modelo teórico de Fredlund Y Xing y estimación del modelo por la red

## 6 CONCLUSIONES Y RECOMENDACIONES

Las RNA demuestran ser un método sólido y eficaz para describir la relación de la succión con el contenido de humedad, ya que se demostró que dan muy buenos resultados con porcentajes de error de ajuste muy bajos, tanto para los datos del laboratorio como para los datos de los modelos teóricos. Las RMN Son capaces de extraer de los ejemplos la relación que existe entre los datos de entrada y los de salida, sin tener que asumir valores empíricos.

En los casos en que las redes cuentan con suficiente cantidad de datos, aprenden las relaciones que existen entre estos, de manera que al mostrarles datos que no conocían, generaron en casi todos los casos respuestas razonablemente buenas. Se pudo observar que en los casos de AFU y AMU, la red generalizó de una forma satisfactoria la relación existente entre los datos, lo cual se demostró al simular los datos teóricos.

Si bien es cierto que las redes neuronales tienen la capacidad de filtrar datos con ruido, es importante anotar que para poder detectar estos ruidos, se debe tener una cantidad suficiente de datos "limpios". En el caso de la red entrenada para la AFU, la red contó con una cantidad suficiente de datos con buena calidad para generar una relación satisfactoria, de modo que generó curvas, tanto de laboratorio como teóricas, más aproximadas. En el caso de la curva para ADTP, la gran dispersión de datos no permite que la red realice un proceso de generalización satisfactorio.

El comportamiento de la red entrenada para AFU, es satisfactorio, ya que se ajusta muy bien tanto a los datos de laboratorio como a la curva teórica, lo que indica que la red aprendió y generalizó muy bien. La principal razón de esto es la calidad de los datos, si se comparan las curvas de datos obtenidos en laboratorio de cada una de las 3 arenas, se observa que la calidad en los datos de AFU es mucho mayor que la de los otros suelos. Así que se aconseja que en las mediciones que se realicen en el laboratorio con miras a generar modelos de redes neuronales, se preste atención especial al proceso de toma de datos.

El modelo generado para la curva de AMU también generó una buena relación entre los datos. El principal factor que jugó en contra de esta red, se encuentra en la calidad de los datos de laboratorio, ya que los datos ubicados en la zona capilar, cuando las succiones son bajas, muestran dos tendencias al mismo tiempo, por lo tanto, la red aprendió éste comportamiento y mostró esta misma tendencia al simular la curva teórica.

Las redes neuronales requieren una gran cantidad y calidad de datos para mejorar su precisión, y dado que en esta investigación se contó con pocos datos para generar los cálculos, se observó que en algunos casos el comportamiento de la red no es el esperado. En estos casos no se contó con más datos, pero se recomienda aumentar la base de datos para plantear redes neuronales que se ajusten y generalicen de mejor forma.

Se propone a futuro generar una red más general que incluya características del tipo de suelo como porcentaje de poros, granulometría y contenido volumétrico de humedad, con una base de datos ampliada.

Adicionalmente se propone modelar las CRA incluyendo la histéresis en el modelo, usando la herramienta de redes neuronales para este propósito. Ya que la relación de histéresis que existe en los suelos, cuya modelación teórica y física es muy compleja; es del tipo de problemas donde las redes pueden mostrar todas sus bondades.

Los métodos basados en redes neuronales para modelar la CRA resultan ser buenas alternativas, ya que ajustan los datos reales que son los medidos en el laboratorio satisfactoriamente. Estos modelos aprenden y generalizan las relaciones entre los datos, y después de entrenada la red solo requiere de contenidos de humedad y un cálculo numérico en computador.

Tanto las curvas obtenidas por Niño y Tovar, como por Báez y Rangel, requieren de transformaciones para poder ser comparadas con las curvas de retención de agua obtenidas en el presente trabajo. Para poder hacer dichas transformaciones se requiere de datos, y debido a que las gráficas no ofrecen información suficiente y los datos numéricos no fueron conseguidos, no fue posible llevar a cabo las comparaciones propuestas.

## 7 REFERENCIAS BIBLIOGRAFICAS

- Arangueren, S. M; Muzachiodi, S. L. (2003) Implicancias del Data Mining. Capítulo VII – Redes Neuronales y Algoritmos Genéticos. Tesis de grado en licenciatura en Sistemas de Información. Universidad Tecnológica Nacional. Universidad Autónoma Entre Ríos. Argentina.
- Barrera, N. E.; Muñoz, J. A. (2003) Análisis de la influencia de la distribución de tamaño de partículas en la conductividad hidráulica de arenas limpias. Trabajo de grado de Ingeniero Civil. Universidad Nacional de Colombia. Bogotá D.C., Colombia.
- Bear, J. (1972) Dynamics of fluids in porous media. Dover Publications, Inc. New York.
- Burland, J. B. and Ridley, A. M. (1996) The Importance of Suction in Soil Mechanics, Imperial College of Science Technology and Medicine. London.
- Delgado, A. (1998) Inteligencia Artificial Y Minirobots. Eco Ediciones. Bogota, Colombia.
- Donado, L. D. (2004) Modelo De Conductividad Hidráulica En Suelos. Tesis De Maestría En Ingeniería – Recursos Hídricos. Universidad Nacional De Colombia. Bogota. Colombia.
- Fausett, L. (1994) Fundamentals Of Neural Networks Arqchitectures, Algorithms And Applications. Prentice-Hall. New Jersey, U.S.A.
- Feng, L.; Hong, W. (2007) On Hydrologic Calculation Using Artificial Neural Networks. Applied Mathematics Letters. Elsevier. DOI. 10.1016/j.aml.2007.06.004 453 - 458
- Fredlund, M. (1999) The Role of Unsaturated Soil Property Functions in the Practice of Unsaturated Soil Mechanics. PhD thesis. University of Saskatchewan, Canada.
- Fredlund, D. G.; Huang; Shangyan; y Xing, A. (1994) Predicting the permeability function for unsaturated soils using the soil-water characteristic curve. Department of Civil Engineering, University of Saskatchewan, Saskatoon. Canada.
- Funahashi, K. I. (1989) On The Approximate Realization Of Continuous Mappings By Neural Networks. Neural Networks, 2, 183 – 192.
- Funahashi, K. I. (1990) Approximate Realization Of Identity Mappings By Three Layer Neural Networks. Electronics And Communications In Japan, Part3, 73, 61-68
- Gee, G. W., Ward, A. L., Zhang, Z. F., Campbell, G. S. y Mathison, J. (2002) The influence of hydraulic nonequilibrium on pressure plate data. Soil Science Society of America, Vadose Zone Journal, 1: 172-178.

- Jain, S. K.; Singh, V. P.; van Genuchten, M. Th. (2004) Analisis Of Soil Water Retention Data Using Artificial Neural Networks. Journal of hydrologic engineering. ASCE. DOI 10.1061/ASCE. 1084-0699 (2004) 9:5, 415-420.
- Pérez, N. (2008) Determinación De Las Curvas Características En Suelos No Saturados Con Celdas De Presión. Publicación Técnica No. 313. Sanfandila, Qro. Ciudad de México. México.
- Prebble, R. E.; Stirk, G. B. (1959) Effect of free iron oxide on range of available water in soils. Soil Sci. 88 : 213 – 217.
- Pachepsky, Ya. A.; Timlin, D.; Varallyay, G. (1996) Artificial Neural Networks to Estimate Soil Water Retention From Easily Measurable Data. Soil Science Society of America Journal. Vol. 60, no.3 May – June 1996. 727 – 733.
- Lambooy, A. M. (1984) Relationship Between Cation Exchange Capacity, Clay Content And Water Retention Of Highveld Soils. S. Afr. J. Plant Soil 1 : 33-38
- Rajkai, K.; Kabos, S.; van Genuchten, M. Th. (2004) Estimating the water retention curve from soil properties: comparison of linear, nonlinear and concomitant variable methods. Soil & Tillage Research. ELSEVIER. DOI. 10.1016/ j.still.2004.07.003 145 - 152
- Salas, R. (2004) Redes Neuronales Artificiales. Departamento de Computación. Universidad de Valparaíso. Chile.
- Stakman, W. P.; Bishay, B. G. (1976) Moisture Retention And Plasticity Of Highly Calcareous Soils in Egypt. Neth. J. Agric. Sci. 24: 43 – 57
- Taboada M.A.; Micucci F.G.; Gil R. (2002) INPOFOS Cono sur. Cátedra de Fertilidad de Suelos, FAUBA. INTA Castelar. [http://www.ppi-ppic.org/ppiweb/ltams.nsf/87cb8a98bf72572b8525693e0053ea70/3462b8ebc74e7a4003256c540055f4de/\\$FILE/Agua-Fmicucci.doc](http://www.ppi-ppic.org/ppiweb/ltams.nsf/87cb8a98bf72572b8525693e0053ea70/3462b8ebc74e7a4003256c540055f4de/$FILE/Agua-Fmicucci.doc)
- Townend, J.; Reeve, M. J.; Carter, A. (2001) Water release characteristic. Chapter 3 in Soil and environmental analysis. Edited by K. A. Smith y C. E. Mullins. Marcel Dekker, Inc. New York, USA.
- Tindall, James y Kunkel, James. 1999. Unsaturated Zone Hydrology for Scientists and Engineers. Prentice-Hall. New Jersey, U.S.A

## **ANEXOS**

## A. ANEXOS

### A.1. ALGORITMO DE ENTRENAMIENTO DE UNA RED BACKPROPAGATION.

#### A.1.1. NOMENCLATURA.

La nomenclatura usada en el algoritmo de entrenamiento para la red backpropagation mostrada en la Figura1. es la siguiente.

$x$	Vector de patrones de entrada de entrenamiento $x = (x_1, \dots, x_i, \dots, x_n)$
$t$	Vector de patrones de salida de entrenamiento $t = (t_1, \dots, t_k, \dots, t_m)$
$\delta_k$	Porcentaje de corrección del error de pesos ajustado para $w_{jk}$ que esta asociado a un error en la unidad de salida $Y_k$ ; también, la información sobre el error en la unidad $Y_k$ que es propagada hacia atrás a las unidades ocultas que están conectadas con la unidad $Y_k$
$\delta_j$	Porcentaje de corrección del error de los pesos ajustado para $v_{ij}$ que esta asociado a la propagación inversa del error de la capa de salida a las unidades ocultas $Z_j$
$\alpha$	Tasa de aprendizaje
$X_i$	Unidad de entrada $i$ : Para una unidad de entrada, la señal de entrada y la señal a la salida son la misma, llamada $x_i$
$v_{0j}$	Umbral en la unidad de la capa oculta $j$
$Z_j$	Unidad oculta $j$ : La entrada de la red a la unidad $Z_j$ esta denotada por $z\_in_j$ : $z\_in_j = v_{0j} + \sum_i x_i \cdot v_{ij}$ La señal de salida (activación) de $Z_j$ es llamada $z_j$ : $z_j = f(z\_in_j)$
$w_{0k}$	Umbral en la unidad de la capa de salida $k$
$Y_k$	Unidad de salida $k$ : La entrada de la red a la unidad $Y_k$ se denota por $y\_in_k$ : $y\_in_k = w_{0k} + \sum_i z_j \cdot w_{jk}$ La señal de salida de $Y_k$ es llamada $y_k$ : $y_k = f(y\_in_k)$




Figura 26 Red Neuronal de tipo Backpropagation con una capa oculta, Fausett (1994).

#### A.1.2. ALGORITMO DE ENTRENAMIENTO.

Cualquiera de las funciones de transferencia definidas en la sección 3.3.3 puede ser usada en el algoritmo dado a continuación.

Los valores iniciales de los pesos de la red son determinados aleatoriamente, el siguiente algoritmo se repetirá hasta que se alcance la condición para detenerse. Esta condición la determina el diseñador de la red y corresponde a un error admisible en los datos.

##### Feedforward

- Cada unidad de entrada ( $X_i, i=1,2,\dots,n$ ) recibe una señal de entrada  $x_i$  y la transmite a todas las unidades en la siguiente capa (las unidades de la capa oculta).
- Cada unidad oculta ( $Z_j, j=1,2,\dots,p$ ) suma sus entradas ponderadas,

$$z\_in_j = v_{0j} + \sum_{i=1}^n x_i \cdot v_{ij} \quad \text{Ec.1}$$

- Y aplica la función de activación para calcular su señal de salida,

$$z_j = f(z\_in_j) \quad \text{Ec.2}$$

- Finalmente envía esta señal,  $z_j$ , a todas las unidades de la siguiente capa (unidades de salida).
- Cada unidad de salida ( $Y_k, k=1,2,\dots,m$ ) suma sus entradas ponderadas,

$$y\_in_k = w_{0k} + \sum_{j=1}^p z_j \cdot w_{jk} \quad \text{Ec.3}$$

- Y aplica la función de activación para calcular su señal de salida,

$$y_k = f(y_{in_k}) \quad \text{Ec.4}$$

### Backpropagation

- Cada unidad de salida ( $Y_k, k = 1, 2, \dots, m$ ) recibe un patrón de salida preestablecido, correspondientes a los patrones de entrada, calcula el factor de corrección del error,

$$\delta_k = (t_k - y_k) \cdot f'(y_{in_k}) \quad \text{Ec.5}$$

- Calcula el termino de corrección de pesos ( usado para actualizar  $w_{jk}$  después),

$$\Delta w_{jk} = \alpha \delta_k z_j \quad \text{Ec.6}$$

- Calcula el termino de corrección del umbral ( usado para actualizar  $w_{0k}$  después),

$$\Delta w_{0k} = \alpha \delta_k \quad \text{Ec.7}$$

- Finalmente envía  $\delta_k$  a unidades en la capa de atrás. Cada unidad de la capa oculta ( $Z_j, j = 1, 2, \dots, p$ ) suma sus entradas  $\delta$  (provenientes de la capa siguiente),

$$\delta_{in_j} = \sum_{k=1}^m \delta_k w_{jk} \quad \text{Ec.8}$$

- Multiplicando por la derivada de su función de activación se calcula el factor de corrección error

$$\delta_j = \delta_{in_j} \cdot f'(z_{in_j}) \quad \text{Ec.9}$$

- Se calcula el termino de corrección del error (usado para actualizar los pesos mas  $v_{ij}$  adelante)

$$\Delta v_{ij} = \alpha \delta_j x_i \quad \text{Ec.10}$$

- Calcula el termino de corrección del error del umbral (usado para actualizar  $v_{0j}$  después)

$$\Delta v_{0j} = \alpha \delta_j \quad \text{Ec.11}$$

### Actualización de pesos y umbrales

- Cada unidad de salida ( $Y_k, k = 1, 2, \dots, m$ ) actualiza sus pesos y umbrales ( $j = 0, 1, \dots, p$ )

$$w_{jk}(\text{actualizado}) = w_{jk}(\text{anterior}) + \Delta w_{jk} \quad \text{Ec.12}$$

- Cada unidad oculta ( $Z_j, j = 1, 2, \dots, p$ ) actualiza sus pesos y umbrales ( $i = 0, 1, \dots, n$ )

$$v_{ij}(\text{actualizado}) = v_{ij}(\text{anterior}) + \Delta v_{ij} \quad \text{Ec.13}$$

Un "Epoch" se refiere a un ciclo entero de paso del conjunto de datos de entrenamiento. Generalmente se requieren varios ciclos para entrenar una red neuronal backpropagation.

A continuación se muestran un ejemplo numérico de la utilización del algoritmo BP, con el objetivo de esclarecer un poco más como funciona este algoritmo.

Usando una neurona y el algoritmo BP, con función de activación tanh se sintetiza una autoregresión de segundo orden  $p^k = g(p^{k-1}, p^{k-2})$ , para los precios de una acción. Los parámetros de entrenamiento se deben sacar de la Tabla 1.

Tabla 4 Precios De Una Acción En La Bolsa

Trimestre	Valor De La Acción
1	0.5
2	0.4
3	0.7
4	0.8

Se toma el vector de pesos inicial y la tasa de aprendizaje como,  
 $[w^1] = [0.1 \ 0.1 \ 0.1]$                        $\alpha = 0.1$

La autoregresión de orden dos indica que la red calcula el precio del trimestre actual  $p^k$  tomando como entradas los precios de trimestres anteriores  $p^{k-1}$  y  $p^{k-2}$ . Tomando como base la Tabla 1 se construye la Tabla 2 que tiene los patrones que se utilizarán para entrenar la neurona.

Tabla 5 Patrones de autoregresión de orden 2

$x_1$	$x_2$	$y_d$
0.5	0.4	0.7
0.4	0.7	0.8

La fórmula para actualizar los pesos es,  
 $w_{jk}(\text{actualizado}) = w_{jk}(\text{anterior}) + \Delta w_{jk}$

El esquema de la neurona usada, se muestra en la Figura 2




Figura 27 Neurona Con Dos Entradas Y Función De Activación Tanh

La suma  $s$  para la iteración  $k$  es,

$$s^k = (1)(w_0^k) + (x_1^k).(w_1^k) + (x_2^k).(w_2^k)$$

Iteración 1,  $k=1$

Se reemplaza el patrón de entrada  $x_1^1 = 0.5, x_2^1 = 0.4$ , la suma ponderada en la neurona es

$$s^1 = (1)(0.1) + (0.5).(0.1) + (0.4).(0.1) = 0.19$$

La salida de la neurona es

$$y^1 = \tanh(s^1) = 0.1877$$

el error se obtiene restando la salida actual de la salida deseada,

$$e^1 = y_d^1 - y^1 = 0.7 - 0.1877 = 0.5123$$

se actualiza el vector de pesos

$$\begin{bmatrix} w_0^2 \\ w_1^2 \\ w_2^2 \end{bmatrix} = \begin{bmatrix} 0.1 \\ 0.1 \\ 0.1 \end{bmatrix} + (2).(0.1).(0.5123) \cdot \begin{bmatrix} 1 - (0.1877)^2 \\ 0.5 \\ 0.4 \end{bmatrix}$$

se realizan las operaciones y se obtiene

$$\begin{bmatrix} w_0^2 \\ w_1^2 \\ w_2^2 \end{bmatrix} = \begin{bmatrix} 0.1988 \\ 0.1494 \\ 0.1395 \end{bmatrix}$$

*Iteración 2, k=2*

Se reemplaza el patrón de entrada  $x_1^2 = 0.4, x_2^2 = 0.7$ , la suma ponderada en la neurona es

$$s^2 = (1)(0.1988) + (0.4).(0.1494) + (0.7).(0.1395) = 0.3562$$

La salida de la neurona es

$$y^2 = \tanh(s^2) = 0.3419$$

el error se obtiene restando la salida actual de la salida deseada,

$$e^2 = y_d^2 - y^2 = 0.8 - 0.3419 = 0.4581$$

se actualiza el vector de pesos

$$\begin{bmatrix} w_0^3 \\ w_1^3 \\ w_2^3 \end{bmatrix} = \begin{bmatrix} 0.1988 \\ 0.1494 \\ 0.1395 \end{bmatrix} + (2).(0.1).(0.4581) \cdot \begin{bmatrix} 1 - (0.3419)^2 \\ 0.4 \\ 0.7 \end{bmatrix}$$

se realizan las operaciones y se obtiene

$$\begin{bmatrix} w_0^3 \\ w_1^3 \\ w_2^3 \end{bmatrix} = \begin{bmatrix} 0.2797 \\ 0.1818 \\ 0.1961 \end{bmatrix}$$

*Iteración 3, k=3*

Se inicia el recorrido de la tabla de nuevo, reemplazando el primer patrón de entrada  $x_1^3 = 0.5$ ,  $x_2^3 = 0.4$ , la suma ponderada en la neurona es

$$s^3 = (1)(0.2797) + (0.5).(0.1818) + (0.4).(0.1961) = 0.4490$$

La salida de la neurona es

$$y^3 = \tanh(s^1) = 0.4211$$

el error se obtiene restando la salida actual de la salida deseada,

$$e^3 = y_d^1 - y^1 = 0.8 - 0.3419 = 0.2789$$

se actualiza el vector de pesos

$$\begin{bmatrix} w_0^4 \\ w_1^4 \\ w_2^4 \end{bmatrix} = \begin{bmatrix} 0.2797 \\ 0.1818 \\ 0.1961 \end{bmatrix} + (2).(0.1).(0.2789).[1 - (0.4211)^2] \begin{bmatrix} 1.0 \\ 0.5 \\ 0.4 \end{bmatrix}$$

se realizan las operaciones y se obtiene

$$\begin{bmatrix} w_0^4 \\ w_1^4 \\ w_2^4 \end{bmatrix} = \begin{bmatrix} 0.3256 \\ 0.2047 \\ 0.2145 \end{bmatrix}$$

El procedimiento se repite hasta que se cumpla que el error medio cuadrático  $e_{rms}$  sobre todos los patrones es menor a un valor  $\epsilon$  determinado por el diseñador de la red (Delgado, 1994).

## A.2. CONSIDERACIONES EVALUADAS PARA DETERMINAR ARENAS LIMPIAS COMO OBJETO DE ESTUDIO.

Debido a que el proceso de retención depende de múltiples factores entre los cuales se encuentran la absorción de minerales arcillosos, absorción osmótica y la tensión superficial, y a que el laboratorio de la UNAL no cuenta con las condiciones idóneas para analizar suelos constituidos por minerales arcillosos, se redujo el rango de posibilidades de estudio a suelos granulares, en los cuales la tensión superficial, generadora de la capilaridad, es el único factor de los nombrados anteriormente decisivo en el drenaje y la retención de agua.

A partir de las características ofrecidas por los equipos de medición de presión con los que cuenta el laboratorio de la UNAL para el cálculo de las curvas de retención, se determinó seleccionar arena como suelo granular, ya que debido a su pequeño tamaño de partículas, permiten un manejo más sencillo dentro de los equipos. No obstante, debido a que la presencia de partículas muy pequeñas (tamaños inferiores a 75µm) en la muestra pueden generar alteraciones en la estructura del medio poroso, se decidió separar los finos de las arenas empleadas.

Con base en las consideraciones anteriormente señaladas, se estableció como objeto de estudio arenas limpias, con tamaños de partículas que varían desde 0.84mm, tamiz retiene #30 y 0.074mm, tamiz retiene #200.

### A.3. REQUERIMIENTOS PARA CLASIFICAR UN SUELO COMO ARENA BIEN GRADADA.

Para considerar un suelo como bien gradado debe cumplir con las siguientes ecuaciones:

$$C_U = \frac{D_{60}}{D_{10}} > 6 \quad \text{y} \quad 1 \leq C_G = \frac{(D_{30})^2}{D_{10} \times D_{60}} \leq 3 \quad \text{Ec.14}$$

**C<sub>U</sub>**: Coeficiente de uniformidad.

**C<sub>G</sub>**: Coeficiente de gradación.

**D<sub>10</sub>**: Diámetro de la partícula para la cual el 10% del suelo posee partículas de diámetros inferiores.

**D<sub>30</sub>**: Diámetro de la partícula para la cual el 30% del suelo posee partículas de diámetros inferiores.

**D<sub>60</sub>**: Diámetro de la partícula para la cual el 60% del suelo posee partículas de diámetros inferiores.

Tabla 6 Porcentajes para la preparación de la arena de diferentes tamaños de partícula. Barrera y Muñoz (2003)

Tamiz	Tamaño de partícula(mm)	% retenido	% retenido acumulado	% que pasa
20	0,84	0	0,00	100,00
30	0,6	40,00	40,00	60,00
40	0,425	30,00	70,00	30,00
50	0,3	10,00	80,00	20,00
60	0,25	3,00	83,00	17,00
70	0,21	3,00	86,00	14,00
80	0,18	1,00	87,00	13,00
100	0,15	3,00	90,00	10,00
200	0,074	10,00	100,00	0,00

Ahora, se comprueban los coeficientes de la ecuación 14, en las ecuaciones 15 y 16, con el propósito de asignar a la arena de diferentes tamaños de partícula, la denominación de arena bien gradada.

$$C_u = \frac{D_{60}}{D_{10}} = \frac{0.6}{0.15} = 4 \quad \text{Ec.15}$$

$$C_g = \frac{D_{30}^2}{D_{10} * D_{60}} = \frac{0.425^2}{0.6 * 0.1} = 2.01 \quad \text{Ec.16}$$

A partir de la discusión preliminar, se presenta la distribución granulométrica de los tres suelos en estudio, en la tabla 4-1 y en la figura 4.1 de la sección 4 de este informe.

#### A.4. MÉTODO DE PREPARACIÓN DE MUESTRAS.

Para la preparación de las muestra a analizar en el laboratorio de la UNAL, se consideraron los siguientes métodos:

- Con embudo:** Es empleado para esparcir la muestra en el interior del molde, llenando el centro y posteriormente el perímetro del molde.
- Llenado a mano:** Como su nombre lo indica, este método se lleva a cabo esparciendo el suelo dentro del molde manualmente, procurando obtener un llenado uniforme.
- Con tamiz:** Se riega el suelo a través de un tamiz #80 (mayor al tamaño de la partícula) dentro del molde, conservando un llenado uniforme.
- Mediante compactación:** Este método consiste en el llenado del molde en tres capas de suelo, donde cada una de estas es compactada con 15 golpes.
- Saturación parcial:** Consiste en sumergir el molde en agua, para posteriormente llenarlo gradualmente con la mano, evitando la aparición de grumos.

Para cada uno de los métodos, se realizó una evaluación del ajuste de sus respectivos datos a una distribución normal de probabilidad. Esta distribución se originó para el estudio de errores experimentales, y se puede aplicar cuando estos tienden a acercarse a un valor central, lo cual se puede analizar a partir del coeficiente de asimetría (Kottegoda y Rosso, 1997). A continuación se presentan los valores de la media, desviación, y los coeficientes de asimetría y variación:

Tabla 7 Datos estadísticos para los datos de cada método de preparación de las muestras. Barrera y Muñoz (2003)

MÉTODO DE PREPARACIÓN	Valor promedio de la densidad (g/cm <sup>3</sup> )	Desviación Estándar (g/cm <sup>3</sup> )	Coficiente de asimetría	Coficiente de variación
Llenado con embudo	1.366	0.043	-1.235	3.15%
Llenado con la mano	1.348	0.0070	-0.108	0.52%
Llenado con tamiz	1.514	0.023	-0.484	1.51%
Llenado mediante compactación	1.469	0.010	-1.752	0.71%
Llenado con saturación Parcial	1.584	0.071	-0.926	4.48%

Cabe resaltar que el signo negativo presente en los valores del coeficiente de asimetría señala que la media es mayor que los valores de la mediana y moda.

Con base en los datos obtenidos en la Tabla 4, se determina aplicar la distribución normal a los métodos que presentan mayor grado de simetría, los cuales son el método de llenado a mano y llenado con tamiz. Para aplicar la distribución normal se usó:

$$P = \frac{1}{\sqrt{2\pi} * \sigma} e^{-\frac{(x-\bar{x})^2}{2\sigma^2}} \quad \text{Ec.17}$$

- P: Probabilidad de ocurrencia en valor X de densidad.
- X: Densidad al cual se calcula la probabilidad de ocurrencia.
- $\bar{x}$ : Media de los valores de densidad.
- $\sigma$ : Desviación estándar de los valores de densidad.

Al aplicar el ajuste de los datos de los métodos seleccionados, a la función de distribución, se puede obtener la Figura3:

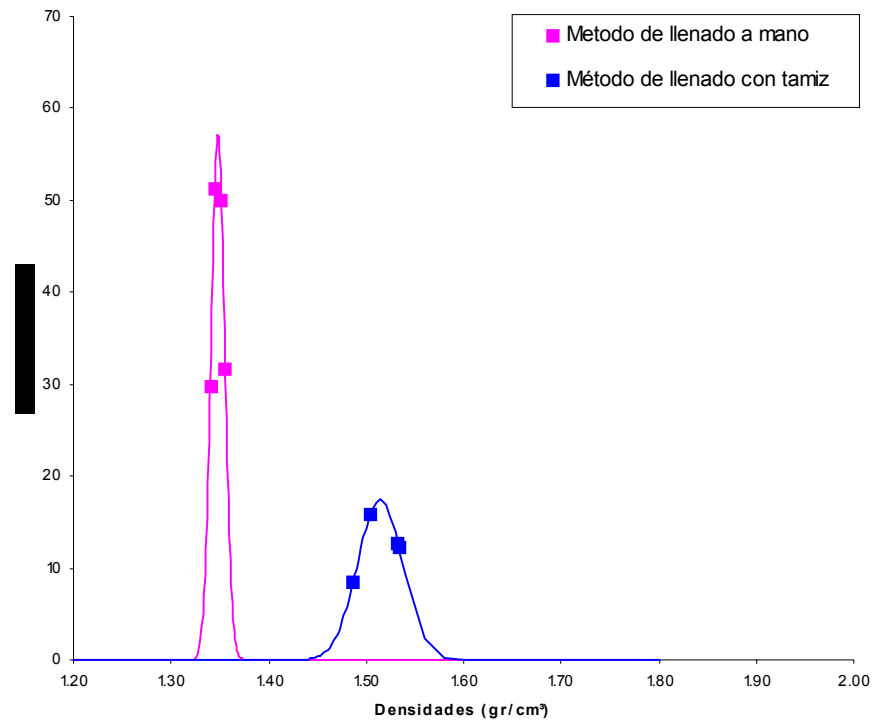


Figura 28 Ajuste a la función de distribución normal de probabilidad. Barrera y Muñoz (2003)

Como se puede observar en la Figura 3, el método de llenado a mano presenta el conjunto de datos con menor dispersión, por lo tanto fue el método seleccionado para preparar las muestras en el proyecto de la UNAL. (Barrera y Muñoz, 2003).

#### A.5. EVALUACIÓN DE POROSIDAD Y RELACIÓN DE VACÍOS EN EL SUELO DE ESTUDIO.

Para la obtención de la relación de vacíos, se tomaron cuatro muestras con arena en moldes de volumen conocido (volumen total de la muestra), y se procedió a secar dichas

muestras para así obtener el peso de los sólidos (peso seco) de cada una de ellas. Una vez obtenidos estos datos, se procedió a determinar la relación de vacíos y la porosidad mediante las ecuaciones:

$$e = \frac{V_v}{V_s} = \frac{V - V_s}{V_s} = \frac{V - \frac{W_s}{G_s}}{\frac{W_s}{G_s}} \quad \text{Ec.18}$$

$$n = \frac{V_v}{V} = \frac{V - V_s}{V} = \frac{V - \frac{W_s}{G_s}}{V} \quad \text{Ec.19}$$

**n:** Porosidad de la muestra, generalmente expresada en porcentaje.  
**e:** Relación de vacíos de la muestra.

Estas ecuaciones son obtenidas del análisis de las relaciones de fase en un elemento de suelo, como se puede observar en la Figura 4




Figura 29 Relaciones de fase. Barrera y Muñoz (2003)

Los resultados de las ecuaciones para las cuatro muestras tomadas se encuentran a continuación (Tabla 5):

Tabla 8 Relación de vacíos y porosidad. Barrera y Muñoz (2003)

Arena	Relación de vacíos	Porosidad (%)
Uniforme grano medio	<b>0.66</b>	<b>40 %</b>
Uniforme grano fino	<b>0.85</b>	<b>46 %</b>
De diferentes tamaños de partícula	<b>0.60</b>	<b>37 %</b>

Con base en la tabla 5, se concluye que la relación de vacíos en la arena uniforme de grano fino es mayor que en la arena uniforme de grano medio, lo que demuestra que la relación de vacíos no crece con el aumento del tamaño de las partículas en todos los casos.

## A.6. DETERMINACIÓN DE LA HUMEDAD DE EQUILIBRIO EMPLEANDO EL MÉTODO INDIRECTO.

La humedad saturada se refiere a la cantidad máxima de agua que se puede almacenar en un suelo dentro su matriz en los espacios vacíos. Este valor corresponde, en las curvas de retención de humedad, cuando el suelo saturado presenta a un valor de succión igual a cero. Para la determinación de la humedad de equilibrio, se llevaron a cabo dos métodos, uno directo y otro indirecto. (Barrera y Muñoz, 2003).

### A.6.1. MÉTODO DIRECTO.

Para llevar a cabo este método, fueron preparadas cuatro muestras de cada arena, según los alineamientos consignados en el anexo A.4. Estas muestras fueron sometidas a saturación por capilaridad la cual se realizó colocando las muestras sobre un plato poroso cargado por una columna de agua externa (Ver figura 5). Al terminar el proceso de saturación, se determinó el contenido de humedad por el método tradicional. Los datos se encuentran consignados en la Tabla 6.




Figura 30. Saturación de las muestras mediante la aplicación de carga constante. Barrera y Muñoz (2003).

Tabla 9 Datos para el cálculo de la humedad saturada con el método directo. Barrera y Muñoz (2003).

MÉTODO DIRECTO					
Arena	Peso Húmedo	Peso Seco	$w_s$	$w_s$ promedio	$\theta_s$
Uniforme grano fino	27.75	20.83	33.22%	33.31%	47,26%
	25.61	19.16	33.66%		
	26.69	20.03	33.25%		
	27.9	20.9	33.11%		
Uniforme grano Medio	27.6	23.4	17.77%	16.22%	25,64%
	27.4	23.8	15.03%		
	24.9	21.6	14.99%		
	27.7	23.6	17.10%		
De diferentes tamaños de partícula	31.79	26.41	20.37%	19.67%	32,40%
	32.49	27.24	19.27%		
	28.31	23.78	19.05%		
	32.02	26.69	19.97%		

$w_s$ : contenido gravimétrico de agua saturada.

$\theta_s$ : contenido volumétrico de agua saturada.

A.6.2. MÉTODO INDIRECTO.

El contenido de humedad se calculó utilizando las relaciones de fase, asumiendo grado de saturación igual a 100 %, un volumen de vacíos (agua) conocido y  $G_s$  igual a 2.63. Estas condiciones se muestran en la Figura 6. En la Tabla 7 se presentan los resultados encontrados por este método.




Figura 31 Relaciones de fase en condición saturada

Tabla 10. Datos para el cálculo de la humedad saturada con el método indirecto. Barrera y Muñoz (2003)

Arena	V	e	$V_A=V_w$	$V_s$	$W_s$	$W_w$	$w_s$	$\theta_s$
Uniforme grano fino	2.17	0.85	1.00	1.17	3.08	1.00	32.46%	46.05%
Uniforme grano medio	2.50	0.66	1.00	1.50	3.96	1.00	25.27%	41.20%
Diferentes tamaños de partícula	2.68	0.60	1.00	1.68	4.41	1.00	22.67%	37.36%

Observando las Tablas 6 y 7 se puede notar que los valores para la arena uniforme de grano medio no corresponden. Esto se debe a que al momento de medir el contenido de humedad de la arena uniforme de grano medio para realizar a cabo el método, no estaba totalmente saturada, posiblemente por mala apreciación visual al momento de evaluar si las muestras estaban saturadas. Por esta razón para efectos de cálculos y realización de graficas, se empleará el valor obtenido por el método indirecto, para las tres arenas.

#### A.7. PREPARACIÓN DE MUESTRAS PARA DETERMINAR LAS PROPIEDADES DE RETENCIÓN EN LAS ARENAS ESTUDIADAS.

El procedimiento para la preparación de las muestras a ensayar en el método de plato extractor de presión u ollas de presión, y el método de la mesa de succión es el mismo, y consta de los siguientes pasos:

1. Preparar las muestras mediante el método de llenado a mano (ver A.4.) dentro de moldes circulares de PVC de 4.35 cm de diámetro y 1 cm de altura. Estas muestras se preparan directamente sobre piedras porosas de alto valor de entrada de aire.



Figura 32 Preparación de las muestras sobre las piedras porosas. Barrera y Muñoz (2003)

2. Se aplica una carga constante de agua a las piedras porosas para lograr saturación de la muestras por capilaridad (Ver figura 8). La saturación dura entre 1 y 24 horas, dependiendo de la capacidad de entrada de aire de la piedra porosa que se utilice.

Los pasos señalados anteriormente se emplean en los dos métodos de medición utilizados, sin embargo las muestras se montan de manera diferente en cada uno de ellos.

### A.7.1 MONTAJE DE MUESTRAS EN LAS OLLAS DE PRESIÓN.

Las muestras previamente saturadas se dejan secar dentro de las ollas el tiempo necesario aplicando una succión determinada, esto con el fin de obtener la humedad de equilibrio correspondiente con esta succión.



Figura 33 Muestras saturadas listas para ser colocadas en las ollas. Barrera y Muñoz (2003)

Si las muestras a determinado valor de succión no drenan más agua dentro las ollas de presión, se ha alcanzado la humedad de equilibrio, así que se procede a su extracción de las ollas y a la medición de la humedad de equilibrio, dejándolas secar en el horno a 100°C durante 24 horas. Este procedimiento se debe repetir por cada punto que se requiera para completar la curva de cada suelo.




Figura 34 Muestras drenando. Nótese el tubo extractor de agua. Cuando las muestras terminan de drenar el tubo está seco. Barrera y Muñoz (2003)

### A.7.2 MONTAJE DE MUESTRAS EN LA MESA DE SUCCIÓN.

Las muestras se someten a una presión de agua negativa (UW), obtenida de conectar una manguera de 2 mm de diámetro a la piedra porosa, donde están colocadas las muestras, permitiendo que el agua succionada salga a la altura  $\Delta h$ , con respecto al nivel de las muestras. (ver Figura 4.3).

Para evitar pérdidas de humedad debido a evaporación, las muestras son protegidas con papel vinipel (Ver Figura 10). Por este método, se considera que las muestras han alcanzado la humedad de equilibrio, cuando dejan de drenar.




Figura 35 Muestras saturadas protegidas con papel vinipel. Barrera y Muñoz (2003)

Para obtener una mayor certeza en los resultados, se realizaron entre 3 y 4 ensayos para determinar cada punto de la gráfica.

A.8. REUSLTADOS DE LOS ENSAYOS DE LABORATORIO PARA LA DETERMINACION DE LAS CURVAS DE RETENCION

A.8.1. DATOS CONSOLIDADOS PARA LA CURVA DE RETENCIÓN DE LA ARENA UNIFORME DE GRANO FINO CON LOS DOS METODOS.

**CARACTERIZACIÓN DEL SUELO**

Descripción: Arena uniforme de grano fino  
 Relación de  
 Peso específico Gs: 2,63 vacíos 0,85

Muestra #	Presión de aire. $U_a$ (kPa)	Presión de agua. $U_w$ (kPa)	Succión Matricial $S$ (kPa)	Contenido Gravimetrico de Agua $w$	OBSERVACIONES
1	20	0	20	2,37%	Medido con las ollas de presión
2	20	0	20	2,64%	Medido con las ollas de presión
3	20	0	20	3,43%	Medido con las ollas de presión
4	20	0	20	3,08%	Medido con las ollas de presión
5	30	0	30	1,95%	Medido con las ollas de presión
6	30	0	30	2,16%	Medido con las ollas de presión
7	30	0	30	2,20%	Medido con las ollas de presión
8	70	0	70	0,44%	Medido con las ollas de presión
9	70	0	70	0,55%	Medido con las ollas de presión
10	70	0	70	0,58%	Medido con las ollas de presión
11	500	0	500	1,59%	Medido con las ollas de presión
12	500	0	500	1,03%	Medido con las ollas de presión
13	500	0	500	1,63%	Medido con las ollas de presión
14	0	-6,9	6,9	12,77%	Medido con el aparato de columna de agua
15	0	-6,9	6,9	10,70%	Medido con el aparato de columna de agua
16	0	-9,8	9,8	13,78%	Medido con el aparato de columna de agua
17	0	-9,8	9,8	14,24%	Medido con el aparato de columna de agua
18	0	-4,9	4,9	19,20%	Medido con el aparato de columna de agua
19	0	-4,9	4,9	20,33%	Medido con el aparato de columna de agua
20	0	-4,9	4,9	20,75%	Medido con el aparato de columna de agua
21	10	0	10	3,02%	Medido con las ollas de presión
22	10	0	10	2,63%	Medido con las ollas de presión
23	10	0	10	2,72%	Medido con las ollas de presión
24	10	0	10	2,56%	Medido con las ollas de presión
25	0	-2,9	3	28,08%	Medido con el aparato de columna de agua
26	0	-2,9	3	31,83%	Medido con el aparato de columna de agua

## CARACTERIZACIÓN DEL SUELO

Descripción: Arena uniforme de grano fino  
 Peso específico Gs: 2,63 Relación de vacíos 0,85

Muestra #	Presión de aire. $U_a$ (kPa)	Presión de agua. $U_w$ (kPa)	Succión Matricial $S$ (kPa)	Contenido Gravimetrico de Agua $w$	OBSERVACIONES
27	0	-2,9	3	32,18%	Medido con el aparato de columna de agua
28	0	-2,9	3	32,48%	Medido con el aparato de columna de agua
29	30	0	30	0,87%	Medido con las ollas de presión
30	30	0	30	1,08%	Medido con las ollas de presión
31	30	0	30	0,76%	Medido con las ollas de presión
32	0	-1,0	1	33,45%	Medido con el aparato de columna de agua
33	0	-1,0	1	32,74%	Medido con el aparato de columna de agua
34	0	-1,0	1	34,11%	Medido con el aparato de columna de agua
35	0	-1,0	1	34,53%	Medido con el aparato de columna de agua
36	0	-4,9	5	23,80%	Medido con el aparato de columna de agua
37	0	-4,9	5	24,43%	Medido con el aparato de columna de agua
38	0	-4,9	5	25,32%	Medido con el aparato de columna de agua
39	0	-4,9	5	25,36%	Medido con el aparato de columna de agua
40	0	-0,5	0,5	31,33%	Medido con el aparato de columna de agua
41	0	-0,5	0,5	32,80%	Medido con el aparato de columna de agua
42	0	-0,5	0,5	32,95%	Medido con el aparato de columna de agua
43	0	-0,5	0,5	32,34%	Medido con el aparato de columna de agua
44	4	0	4,0	26,19%	Medido con las ollas de presión
45	4	0	4,0	28,91%	Medido con las ollas de presión
46	4	0	4,0	28,44%	Medido con las ollas de presión
47	4	0	4,0	30,34%	Medido con las ollas de presión
48	0	-3,9	3,9	32,29%	Medido con el aparato de columna de agua
49	0	-3,9	3,9	32,79%	Medido con el aparato de columna de agua
50	0	-3,9	3,9	32,53%	Medido con el aparato de columna de agua
51	0	-2,0	2,0	32,37%	Medido con el aparato de columna de agua
52	0	-2,0	2,0	32,39%	Medido con el aparato de columna de agua
53	0	-2,0	2,0	32,89%	Medido con el aparato de columna de agua

**CARACTERIZACIÓN DEL SUELO**

Descripción: Arena uniforme de grano fino  
 Relación de  
 Peso específico Gs: 2,63 vacíos 0,85

Muestra #	Presión de aire. $U_a$ (kPa)	Presión de agua. $U_w$ (kPa)	Succión Matricial $S$ (kPa)	Contenido Gravimetrico de Agua $w$	OBSERVACIONES
54	0	-2,0	2,0	33,00%	Medido con el aparato de columna de agua
55	0	-1,0	1,0	32,38%	Medido con el aparato de columna de agua
56	0	-1,0	1,0	32,18%	Medido con el aparato de columna de agua
57	0	-1,0	1,0	32,64%	Medido con el aparato de columna de agua
58	0	-1,0	1,0	33,27%	Medido con el aparato de columna de agua
58	0	0	0	33,22%	Humedad saturada
60	0	0	0	33,66%	Humedad saturada
61	0	0	0	33,25%	Humedad saturada
62	0	0	0	33,11%	Humedad saturada
63	0	-0,5	0,5	32,10%	Medido con el aparato de columna de agua
64	0	-0,5	0,5	32,99%	Medido con el aparato de columna de agua
65	0	-0,5	0,5	32,85%	Medido con el aparato de columna de agua
66	0	-0,5	0,5	32,51%	Medido con el aparato de columna de agua

**A.8.2. DATOS CONSOLIDADOS PARA LA CURVA DE RETENCIÓN DE LA ARENA UNIFORME DE GRANO MEDIO CON LOS DOS METODOS.**

**CARACTERIZACIÓN DEL SUELO**

Descripción: Arena uniforme de grano medio  
 Relación de  
 Peso específico Gs: 2,63 vacíos 0,66

Muestra #	Presión de aire. $U_a$ (kPa)	Presión de agua. $U_w$ (kPa)	Succión Matricial $S$ (kPa)	Contenido Gravimetrico de Agua $w$	OBSERVACIONES
1	20	0	20	0,83%	Medido con las ollas de presión

## CARACTERIZACIÓN DEL SUELO

Descripción: Arena uniforme de grano medio

Peso específico Gs: 2,63 Relación de vacíos 0,66

Muestra #	Presión de aire. $U_a$ (kPa)	Presión de agua. $U_w$ (kPa)	Succión Matricial $S$ (kPa)	Contenido Gravimetrico de Agua $w$	OBSERVACIONES
2	20	0	20	0,95%	Medido con las ollas de presión
3	20	0	20	0,48%	Medido con las ollas de presión
4	20	0	20	0,50%	Medido con las ollas de presión
5	30	0	30	0,41%	Medido con las ollas de presión
6	30	0	30	0,26%	Medido con las ollas de presión
7	30	0	30	0,21%	Medido con las ollas de presión
8	500	0	500	0,17%	Medido con las ollas de presión
9	500	0	500	0,22%	Medido con las ollas de presión
10	500	0	500	0,17%	Medido con las ollas de presión
11	70	0	70	0,43%	Medido con las ollas de presión
12	70	0	70	0,62%	Medido con las ollas de presión
13	70	0	70	0,57%	Medido con las ollas de presión
14	0	-6,9	6,9	0,98%	Medido con el aparato de columna de agua
15	0	-6,9	6,9	1,20%	Medido con el aparato de columna de agua
16	0	-9,8	9,8	1,43%	Medido con el aparato de columna de agua
17	0	-9,8	9,8	1,31%	Medido con el aparato de columna de agua
18	0	-4,9	4,9	0,87%	Medido con el aparato de columna de agua
19	0	-4,9	4,9	0,87%	Medido con el aparato de columna de agua
21	0	-4,9	4,9	0,84%	Medido con el aparato de columna de agua
22	10	0	10,0	0,64%	Medido con las ollas de presión
23	10	0	10,0	0,53%	Medido con las ollas de presión
24	10	0	10,0	0,59%	Medido con las ollas de presión
25	10	0	10,0	0,65%	Medido con las ollas de presión
26	0	-2,9	2,9	22,91%	Medido con el aparato de columna de agua
27	0	-2,9	2,9	22,95%	Medido con el aparato de columna de agua
28	0	-2,93952	2,93952	23,88%	Medido con el aparato de columna de agua
29	0	-2,93952	2,93952	23,55%	Medido con el aparato de columna de agua
30	30	0	30	0,39%	Medido con las ollas de presión
31	30	0	30	0,47%	Medido con las ollas de presión
32	30	0	30	0,41%	Medido con las ollas de presión
33	30	0	30	0,41%	Medido con las ollas de presión

**CARACTERIZACIÓN DEL SUELO**

Descripción: Arena uniforme de grano medio  
 Peso específico Gs: 2,63 Relación de vacíos 0,66

Muestra #	Presión de aire. <b>U<sub>a</sub></b> (kPa)	Presión de agua. <b>U<sub>w</sub></b> (kPa)	Succión Matricial <b>S</b> (kPa)	Contenido Gravimetrico de Agua <b>w</b>	OBSERVACIONES
34	0	-1,0	1,0	17,42%	Medido con el aparato de columna de agua
35	0	-1,0	1,0	20,82%	Medido con el aparato de columna de agua
36	0	-1,0	1,0	21,46%	Medido con el aparato de columna de agua
37	0	-4,9	4,9	1,02%	Medido con el aparato de columna de agua
38	0	-4,9	4,9	1,07%	Medido con el aparato de columna de agua
39	0	-4,9	4,9	0,75%	Medido con el aparato de columna de agua
40	0	-0,5	0,5	17,14%	Medido con el aparato de columna de agua
41	0	-0,5	0,5	17,31%	Medido con el aparato de columna de agua
42	0	-0,5	0,5	13,76%	Medido con el aparato de columna de agua
43	0	-0,5	0,5	15,84%	Medido con el aparato de columna de agua
44	4	0	4,0	1,42%	Medido con las ollas de presión
45	4	0	4,0	1,69%	Medido con las ollas de presión
46	4	0	4,0	1,59%	Medido con las ollas de presión
47	4	0	4,0	1,65%	Medido con las ollas de presión
48	0	-3,9	3,9	22,03%	Medido con el aparato de columna de agua
49	0	-3,9	3,9	22,73%	Medido con el aparato de columna de agua
50	0	-3,9	3,9	23,57%	Medido con el aparato de columna de agua
51	0	-3,9	3,9	22,21%	Medido con el aparato de columna de agua
52	0	-2,0	2,0	12,60%	Medido con el aparato de columna de agua
53	0	-2,0	2,0	13,61%	Medido con el aparato de columna de agua
54	0	-2,0	2,0	15,24%	Medido con el aparato de columna de agua
55	0	-2,0	2,0	13,27%	Medido con el aparato de columna de agua
56	0	-1,0	1,0	22,69%	Medido con el aparato de columna de agua
57	0	-1,0	1,0	23,91%	Medido con el aparato de columna de agua
58	0	-1,0	1,0	23,54%	Medido con el aparato de columna de agua
59	0	-1,0	1,0	23,95%	Medido con el aparato de columna de agua

## A.8.3. DATOS CONSOLIDADOS PARA LA CURVA DE RETENCIÓN DE LA ARENA DE DIFERENTES TAMAÑOS DE PARTÍCULAS CON LOS DOS METODOS.

## CARACTERIZACIÓN DEL SUELO

Descripción: Arena de diferentes tamaños de partículas

Peso específico Gs: 2,63 Relación de vacíos 0,60

Muestra #	Presión de aire. $U_a$ (kPa)	Presión de agua. $U_w$ (kPa)	Succión Matricial $S$ (kPa)	Contenido Gravimetrico de Agua $w$	OBSERVACIONES
1	20	0	20	1,20%	Medido con las ollas de presión
2	20	0	20	1,58%	Medido con las ollas de presión
3	20	0	20	1,36%	Medido con las ollas de presión
4	20	0	20	1,57%	Medido con las ollas de presión
5	70	0	70	1,55%	Medido con las ollas de presión
6	70	0	70	1,66%	Medido con las ollas de presión
7	70	0	70	1,87%	Medido con las ollas de presión
8	500	0	500	0,47%	Medido con las ollas de presión
9	500	0	500	0,53%	Medido con las ollas de presión
10	500	0	500	0,49%	Medido con las ollas de presión
11	0	-6,9	6,9	4,92%	Medido con el aparato de columna de agua
12	0	-6,9	6,9	4,86%	Medido con el aparato de columna de agua
13	0	-9,8	9,8	4,12%	Medido con el aparato de columna de agua
14	0	-9,8	9,8	3,30%	Medido con el aparato de columna de agua
15	0	-9,8	9,8	4,44%	Medido con el aparato de columna de agua
20	10	0	10,0	1,24%	Medido con las ollas de presión
21	10	0	10,0	1,17%	Medido con las ollas de presión
22	10	0	10,0	1,41%	Medido con las ollas de presión
23	10	0	10,0	1,82%	Medido con las ollas de presión
24	0	-2,9	2,9	21,81%	Medido con el aparato de columna de agua
25	0	-2,9	2,9	15,56%	Medido con el aparato de columna de agua
26	0	-2,9	2,9	21,31%	Medido con el aparato de columna de agua
27	0	-2,9	2,9	21,35%	Medido con el aparato de columna de agua
28	30	0	30	0,59%	Medido con las ollas de presión
29	30	0	30	0,67%	Medido con las ollas de presión
30	30	0	30	0,65%	Medido con las ollas de presión
31	30	0	30	0,75%	Medido con las ollas de presión
32	0	-1,0	1,0	18,82%	Medido con el aparato de columna de agua

**CARACTERIZACIÓN DEL SUELO**Descripción: Arena de diferentes tamaños de partículasPeso específico Gs: 2,63 Relación de vacíos 0,60

Muestra #	Presión de aire. $U_a$ (kPa)	Presión de agua. $U_w$ (kPa)	Succión Matricial (kPa) $S$	Contenido Gravimétrico de Agua $w$	OBSERVACIONES
33	0	-1,0	1,0	20,96%	Medido con el aparato de columna de agua
34	0	-1,0	1,0	20,21%	Medido con el aparato de columna de agua
35	0	-1,0	1,0	20,48%	Medido con el aparato de columna de agua
36	0	-4,9	4,9	7,06%	Medido con el aparato de columna de agua
37	0	-4,9	4,9	8,00%	Medido con el aparato de columna de agua
38	0	-4,9	4,9	7,25%	Medido con el aparato de columna de agua
39	0	-0,5	0,5	23,33%	Medido con el aparato de columna de agua
40	0	-0,5	0,5	20,73%	Medido con el aparato de columna de agua
41	0	-0,5	0,5	21,50%	Medido con el aparato de columna de agua
42	4	0,0	4,0	8,11%	Medido con las ollas de presión
43	4	0,0	4,0	7,23%	Medido con las ollas de presión
44	4	0,0	4,0	6,70%	Medido con las ollas de presión
45	4	0,0	4,0	6,86%	Medido con las ollas de presión
46	0	-3,9	3,9	21,72%	Medido con el aparato de columna de agua
47	0	-3,9	3,9	21,00%	Medido con el aparato de columna de agua
48	0	-3,9	3,9	21,46%	Medido con el aparato de columna de agua
49	0	-3,9	3,9	21,53%	Medido con el aparato de columna de agua
50	0	-2,0	2,0	21,62%	Medido con el aparato de columna de agua
51	0	-2,0	2,0	20,75%	Medido con el aparato de columna de agua
52	0	-2,0	2,0	20,31%	Medido con el aparato de columna de agua
53	0	-2,0	2,0	20,41%	Medido con el aparato de columna de agua
54	0	-1,0	1,0	20,33%	Medido con el aparato de columna de agua
55	0	-1,0	1,0	20,76%	Medido con el aparato de columna de agua
56	0	-1,0	1,0	21,08%	Medido con el aparato de columna de agua
57	0	-1,0	1,0	21,01%	Medido con el aparato de columna de agua
58	0	0,0	0,0	20,37%	Humedad saturada
59	0	0,0	0,0	19,27%	Humedad saturada
60	0	0,0	0,0	19,05%	Humedad saturada
61	0	0,0	0,0	19,97%	Humedad saturada
62	0	-0,5	0,5	20,82%	Medido con el aparato de columna de agua

**CARACTERIZACIÓN DEL SUELO**

Descripción: Arena de diferentes tamaños de partículas  
 Peso específico Gs: 2,63 Relación de vacíos 0,60

Muestra #	Presión de aire. $U_a$ (kPa)	Presión de agua. $U_w$ (kPa)	Succión Matricial $S$ (kPa)	Contenido Gravimétrico de Agua $w$	OBSERVACIONES
63	0	-0,5	0,5	20,85%	Medido con el aparato de columna de agua
64	0	-0,5	0,5	21,36%	Medido con el aparato de columna de agua
65	0	-0,5	0,5	21,07%	Medido con el aparato de columna de agua

**A.9. NORMALIZACIÓN PARA LOS DATOS EMPLEADOS EN EL ENTRENAMIENTO DE LA RED.**

Un cálculo tipo para la determinación de los datos normalizados se presenta a continuación, aunque el cálculo es para la AFU, se procede de la misma manera para AMU y ADTP.

- Se aplica la función logaritmo natural (LN) a la serie de valores de succión. Así para el primer valor de succión de AFU.

$$\Psi = 20$$

$$LN(\Psi) = 2.995732274$$

- Se calcula el valor medio de la succión y del contenido volumétrico de agua de la serie de datos para AFU.

$$\bar{\theta} = 0.25516$$

$$LN(\bar{\Psi}) = 1.87687$$

- Se toma la primera pareja de valores  $\theta - LN(\Psi)$  de la tabla del anexo A.8.1 (0.0336, 2.995732274)
- Se resta la media a cada uno de los valores de la serie de datos, con el fin de tener datos de succión y contenido volumétrico de agua con media cero.

$$\theta_{media0} = 0.0336 - 0.25516 = -0.2215378$$

$$\Psi_{media0} = 2.995732274 - 1.87687 = 1.118861082$$

- Para escalar los datos se determinan los valores máximos y mínimos de la serie de datos de succión y contenido volumétrico con media cero.

$$\theta_{max} = 0.23478 \quad \theta_{min} = -0.25277$$

$$\Psi_{max} = 5.03088 \quad \Psi_{min} = -4.17946$$

- Finalmente se escalan los datos usando la ecuación 4-2 para  $\theta$ , o 4-4 para  $\Psi$ .

$$\theta_N = \frac{(-0.2215378 - (-0.25277))}{0.23478 - (-0.25277)} = 0.06406405$$

$$\Psi_N = \frac{(1.118861082 - (-4.17946))}{5.03088 - (-4.17946)} = 0.5752575$$

Se procese de la misma forma para toda la serie de datos, así como también para todos los tipos de suelos.

#### A.9.1. DATOS PARA LA ARENA FINA UNIFORME.

Succión Matricial S (kPa)	LN Succión Matricial S (kPa)	Contenido Volumétrico de Agua	MEDIA CERO LN Succión Matricial S (kPa)	MEDIA CERO Contenido Volumétrico de Agua $\theta$	LN Succión Matricial S (kPa) ENTRE 0 Y 1,	Contenido Volumétrico de Agua $q$ ENTRE 0 Y 1
20	2,99573227	0,03361998	1,118861082	-	0,5752575	0,06406405
20	2,99573227	0,03750035	1,118861082	-	0,5752575	0,07202294
20	2,99573227	0,04868305	1,118861082	-	0,5752575	0,09495938
20	2,99573227	0,04365425	1,118861082	-	0,5752575	0,08464499
30	3,40119738	0,02771022	1,524326191	-	0,61928031	0,05194275
30	3,40119738	0,03062528	1,524326191	-	0,61928031	0,05792174
30	3,40119738	0,03114212	1,524326191	-	0,61928031	0,0589818
70	4,24849524	0,00626009	2,371624051	-	0,71127451	0,00794714
70	4,24849524	0,00784466	2,371624051	-	0,71127451	0,0111972
70	4,24849524	0,00819002	2,371624051	-	0,71127451	0,01190555
500	6,2146081	0,02252005	4,337736907	-	0,9247425	0,04129738

DETERMINACION DE LA CURVA DE RETENCION DE AGUA DE SUELOS GRANULARES USANDO REDES NEURONALES ARTIFICIALES

Succión Matricial S (kPa)	LN Succión Matricial S (kPa)	Contenido Volumétrico de Agua	MEDIA CERO LN Succión Matricial S (kPa)	MEDIA CERO Contenido Volumétrico de Agua $\theta$	LN Succión Matricial S (kPa) ENTRE 0 Y 1,	Contenido Volumétrico de Agua q ENTRE 0 Y 1
0,48983023	-	0,4588974	-2,5905676	0,20373966	0,1725114	0,93633558
4	1,38629436	0,37154996	-	0,11639222	0,400515	0,75718032
4	1,38629436	0,41020135	-	0,15504361	0,400515	0,83645683
4	1,38629436	0,40344682	-	0,14828909	0,400515	0,82260286
4	1,38629436	0,43042549	-	0,17526775	0,400515	0,87793785
3,91864186	1,36574513	0,4581567	-	0,20299896	0,39828389	0,93481636
3,91864186	1,36574513	0,46522235	-	0,21006461	0,39828389	0,94930846
3,91864186	1,36574513	0,46148485	-	0,20632711	0,39828389	0,94164261
1,95932093	0,67259795	0,45928334	-	0,2041256	0,32302639	0,93712717
1,95932093	0,67259795	0,45946971	-	0,20431198	0,32302639	0,93750944
1,95932093	0,67259795	0,4666604	-	0,21150266	0,32302639	0,95225799
1,95932093	0,67259795	0,46818539	-	0,21302766	0,32302639	0,95538586
0,97966046	0,02054923	0,45942168	-	0,20426394	0,2477689	0,93741091
0,97966046	0,02054923	0,45657374	-	0,20141601	0,2477689	0,93156961
0,97966046	0,02054923	0,46310002	-	0,20794228	0,2477689	0,94495543
0,97966046	0,02054923	0,47199422	-	0,21683648	0,2477689	0,96319801
0,1	2,30258509	0,47761078	-	0,22245304	0	0,97471794
0,1	2,30258509	0,47174053	-	0,21658279	0	0,96267768
0,1	2,30258509	0,46975771	-	0,21459997	0	0,95861079
0,48973545	0,71388994	0,45545936	-	0,20030163	0,17249039	0,92928395
0,48973545	0,71388994	0,46811635	-	0,21295861	0,17249039	0,95524425
0,48973545	0,71388994	0,46602231	-	0,21086458	0,17249039	0,95094925

A.9.2. DATOS PARA LA ARENA MEDIA UNIFORME.

Succión Matricial S (kPa)	LN Succión Matricial S (kPa)	Contenido Volumétrico de Agua	MEDIA CERO LN Succión Matricial S (kPa)	MEDIA CERO Contenido Volumétrico de Agua $\theta$	LN Succión Matricial S (kPa) ENTRE 0 Y 1,	Contenido Volumétrico de Agua $q$ ENTRE 0 Y 1
20	2,99573227	0,013112621	1,0596357	0,12771342	0,5752575	0,03181679
20	2,99573227	0,014976975	1,0596357	0,12584906	0,5752575	0,03634142
20	2,99573227	0,007560148	1,0596357	0,13326589	0,5752575	0,01834141
20	2,99573227	0,007940055	1,0596357	0,13288598	0,5752575	0,01926341
30	3,40119738	0,006452195	1,46510081	0,13437384	0,61928031	0,0156525
30	3,40119738	0,004091681	1,46510081	0,13673436	0,61928031	0,00992373
30	3,40119738	0,003351869	1,46510081	0,13747417	0,61928031	0,00812827
500	6,2146081	0,00262035	4,27851152	0,13820569	0,9247425	0,00635293
500	6,2146081	0,003475739	4,27851152	-0,1373503	0,9247425	0,00842889
500	6,2146081	0,002614929	4,27851152	0,13821111	0,9247425	0,00633978
70	4,24849524	0,006813587	2,31239867	0,13401245	0,71127451	0,01652957
70	4,24849524	0,0097435	2,31239867	0,13108254	0,71127451	0,02364022
70	4,24849524	0,008956472	2,31239867	0,13186957	0,71127451	0,02173017
6,85886837	1,92554247	0,015490891	0,01055411	0,12533515	0,45906312	0,03758865
6,85886837	1,92554247	0,019036998	0,01055411	0,12178904	0,45906312	0,04619476
9,79838339	2,28221741	0,022572441	0,34612084	-0,1182536	0,49778861	0,05477498
9,79838339	2,28221741	0,020699618	0,34612084	0,12012642	0,49778861	0,0502298
4,8991917	1,58907023	0,013680267	0,34702634	0,12714577	0,42253111	0,03319442
4,8991917	1,58907023	0,013799745	0,34702634	0,12702629	0,42253111	0,03348439
4,8991917	1,58907023	0,013277906	0,34702634	0,12754813	0,42253111	0,03221793
10	2,30258509	0,010048145	0,36648852	0,13077789	0,5	0,02437957
10	2,30258509	0,008378635	0,36648852	-0,1324474	0,5	0,02032781
10	2,30258509	0,009324452	0,36648852	0,13150159	0,5	0,02262323

DETERMINACION DE LA CURVA DE RETENCION DE AGUA DE SUELOS GRANULARES USANDO REDES NEURONALES ARTIFICIALES

Succión Matricial S (kPa)	LN Succión Matricial S (kPa)	Contenido Volumétrico de Agua	MEDIA CERO LN Succión Matricial S (kPa)	MEDIA CERO Contenido Volumétrico de Agua $\theta$	LN Succión Matricial S (kPa) ENTRE 0 Y 1,	Contenido Volumétrico de Agua $q$ ENTRE 0 Y 1
10	2,30258509	0,010276884	0,36648852	0,13054915	0,5	0,0249347
2,93951502	1,07824461	0,362029081	0,85785197	0,22120304	0,36706892	0,87860772
2,93951502	1,07824461	0,362690913	0,85785197	0,22186488	0,36706892	0,88021393
2,93951502	1,07824461	0,37725322	0,85785197	0,23642718	0,36706892	0,91555542
2,93951502	1,07824461	0,372140239	0,85785197	0,2313142	0,36706892	0,90314665
30	3,40119738	0,006223474	1,46510081	0,13460256	0,61928031	0,01509741
30	3,40119738	0,007430859	1,46510081	0,13339518	0,61928031	0,01802763
30	3,40119738	0,006556311	1,46510081	0,13426973	0,61928031	0,01590518
30	3,40119738	0,006488997	1,46510081	0,13433704	0,61928031	0,01574181
0,97956713	0,02064451	0,275306002	1,95674109	0,13447996	0,24775855	0,66813809
0,97956713	0,02064451	0,328992164	1,95674109	0,18816613	0,24775855	0,7984299
0,97956713	0,02064451	0,339118979	1,95674109	0,19829294	0,24775855	0,82300683
4,89783563	1,5887934	0,016080367	0,34730317	0,12474567	0,42250105	0,03901926
4,89783563	1,5887934	0,016871393	0,34730317	0,12395464	0,42250105	0,04093902
4,89783563	1,5887934	0,011820979	0,34730317	0,12900506	0,42250105	0,02868209
0,4896859	0,71399111	0,27081281	2,65008769	0,12998677	0,1724794	0,65723349
0,48958257	0,71420216	0,273527203	2,65029873	0,13270117	0,17245649	0,6638211
0,48947368	0,71442459	0,217364244	2,65052116	0,07653821	0,17243234	0,52751832
0,48947368	0,71442459	0,250216498	2,65052116	0,10939046	0,17243234	0,60724798
4	1,38629436	0,025114659	0,54980221	0,11571138	0,400515	0,06094473
4	1,38629436	0,026009397	0,54980221	0,11481664	0,400515	0,06311618
3,91578944	1,36501695	0,348079693	0,57107962	0,20725366	0,39820483	0,84475373

Succión Matricial S (kPa)	LN Succión Matricial S (kPa)	Contenido Volumétrico de Agua	MEDIA CERO LN Succión Matricial S (kPa)	MEDIA CERO Contenido Volumétrico de Agua <sup>θ</sup>	LN Succión Matricial S (kPa) ENTRE 0 Y 1,	Contenido Volumétrico de Agua q ENTRE 0 Y 1
3,91578944	1,36501695	0,359107011	-	0,21828097	0,39820483	0,8715161
3,91578944	1,36501695	0,372382057	-	0,23155602	0,39820483	0,90373352
3,91578944	1,36501695	0,350963007	-	0,21013697	0,39820483	0,85175129
1,95932093	0,67259795	0,199162057	-	0,05833602	0,32302639	0,48334314
1,95932093	0,67259795	0,215043441	-	0,0742174	0,32302639	0,52188592
1,95932093	0,67259795	0,240833956	-	0,10000792	0,32302639	0,58447733
1,95932093	0,67259795	0,209681017	-	0,06885498	0,32302639	0,50887177
0,97966046	0,02054923	0,358583217	-	0,21775718	0,2477689	0,8702449
0,97966046	0,02054923	0,377784262	-	0,23695822	0,2477689	0,91684422
0,97966046	0,02054923	0,371972308	-	0,23114627	0,2477689	0,90273909
0,1	2,30258509	0,280781492	-	0,13995545	0	0,68142665
0,1	2,30258509	0,237474964	-	0,09664893	0	0,57632534
0,1	2,30258509	0,236900951	-	0,09607491	0	0,57493226
0,1	2,30258509	0,270257673	-	0,12943163	0	0,65588622
0,48973545	0,71388994	0,222340724	-	0,08151469	0,17249039	0,53959581
0,48973545	0,71388994	0,227481017	-	0,08665498	0,17249039	0,55207087
0,48973545	0,71388994	0,278745442	-	0,1379194	0,17249039	0,67648533
0,48973545	0,71388994	0,241596487	-	0,10077045	0,17249039	0,58632793

A.9.3. DATOS PARA ARENA DE DIFERENTES TAMAÑOS DE PARTÍCULA.

Succión Matricial <b>S</b> (kPa)	LN Succión Matricial <b>S</b> (kPa)	Contenido Volumétrico de Agua	MEDIA CERO LN Succión Matricial <b>S</b> (kPa)	MEDIA CERO Contenido Volumétrico de Agua $\theta$	LN Succión Matricial <b>S</b> (kPa) ENTRE 0 Y 1,	Contenido Volumétrico de Agua $q$ ENTRE 0 Y 1
20	2,99573227	0,01977046	1,07871064	0,14117639	0,5752575	0,04423925
20	2,99573227	0,02604804	1,07871064	0,13489881	0,5752575	0,06069892
20	2,99573227	0,02236478	1,07871064	0,13858208	0,5752575	0,05104148
20	2,99573227	0,02594549	1,07871064	0,13500136	0,5752575	0,06043003
500	6,2146081	0,00779145	4,29758647	-0,1531554	0,9247425	0,01283055
500	6,2146081	0,00865986	4,29758647	0,15228699	0,9247425	0,01510749
500	6,2146081	0,00808337	4,29758647	0,15286348	0,9247425	0,01359595
6,85886837	1,92554247	0,08102649	0,00852084	0,07992037	0,45906312	0,20485122
6,85886837	1,92554247	0,08004236	0,00852084	0,08090449	0,45906312	0,20227086
9,79838339	2,28221741	0,06793266	0,36519578	0,09301419	0,49778861	0,17051949
9,79838339	2,28221741	0,05428671	0,36519578	0,10666014	0,49778861	0,13474011
9,79838339	2,28221741	0,07311562	0,36519578	0,08783124	0,49778861	0,18410909
10	2,30258509	0,02038659	0,38556346	0,14056026	0,5	0,04585472
10	2,30258509	0,01922621	0,38556346	0,14172064	0,5	0,04281224
10	2,30258509	0,02328128	0,38556346	0,13766557	0,5	0,05344453
10	2,30258509	0,0300297	0,38556346	0,13091715	0,5	0,07113875
2,93951502	1,07824461	0,25638491	0,83877702	0,09543806	0,36706892	0,66463723
2,93951502	1,07824461	0,35172171	0,83877702	0,19077486	0,36706892	0,91460826
30	3,40119738	0,01074605	1,48417575	0,15020081	0,61928031	0,02057742
30	3,40119738	0,01235963	1,48417575	0,14858722	0,61928031	0,0248082

DETERMINACION DE LA CURVA DE RETENCION DE AGUA DE SUELOS GRANULARES USANDO REDES NEURONALES ARTIFICIALES

Succión Matricial <b>S</b> (kPa)	LN Succión Matricial <b>S</b> (kPa)	Contenido Volumétrico de Agua	MEDIA CERO LN Succión Matricial <b>S</b> (kPa)	MEDIA CERO Contenido Volumétrico de Agua $\theta$	LN Succión Matricial <b>S</b> (kPa) ENTRE 0 Y 1,	Contenido Volumétrico de Agua $q$ ENTRE 0 Y 1
0,97956713	-	0,31011759	-	0,14917074	0,24775855	0,80552315
0,97956713	0,02064451	0,31011759	1,93766614	0,14917074	0,24775855	0,80552315
0,97956713	-	0,34531579	-	0,18436893	0,24775855	0,89781206
0,97956713	0,02064451	0,34531579	1,93766614	0,18436893	0,24775855	0,89781206
0,97956713	-	0,33299325	-	0,17204639	0,24775855	0,86550262
0,97956713	0,02064451	0,33299325	1,93766614	0,17204639	0,24775855	0,86550262
0,97956713	-	0,33742341	-	0,17647655	0,24775855	0,87711841
0,97956713	0,02064451	0,33742341	1,93766614	0,17647655	0,24775855	0,87711841
4,89783563	1,5887934	0,11634648	0,32822823	0,04460037	0,42250105	0,29745949
4,89783563	-	0,13180308	-	0,02914377	0,42250105	0,33798636
4,89783563	1,5887934	0,13180308	0,32822823	0,02914377	0,42250105	0,33798636
4,89783563	-	0,11939577	-	0,04155108	0,42250105	0,30545465
4,89783563	1,5887934	0,11939577	0,32822823	0,04155108	0,42250105	0,30545465
0,48978356	-	0,38428939	-	0,22334253	0,17250105	1
0,48978356	0,71379169	0,38428939	2,63081332	0,22334253	0,17250105	1
0,48978356	-	0,34157086	-	0,18062401	0,17250105	0,88799295
0,48978356	0,71379169	0,34157086	2,63081332	0,18062401	0,17250105	0,88799295
0,48978356	-	0,3542489	-	0,19330205	0,17250105	0,9212345
0,48978356	0,71379169	0,3542489	2,63081332	0,19330205	0,17250105	0,9212345
4	1,38629436	0,13362144	0,53072727	0,02732542	0,400515	0,34275405
4	-	0,11905136	-	0,04189549	0,400515	0,30455162
4	1,38629436	0,11905136	0,53072727	0,04189549	0,400515	0,30455162
4	-	0,11044273	-	0,05050412	0,400515	0,28197998
4	1,38629436	0,11044273	0,53072727	0,05050412	0,400515	0,28197998
4	-	0,11299799	-	0,04794887	0,400515	0,2886798
4	1,38629436	0,11299799	0,53072727	0,04794887	0,400515	0,2886798
3,9174872	1,36545043	0,35352042	-0,5515712	0,19257356	0,3982519	0,91932442
3,9174872	-	0,35466097	-	0,19371412	0,3982519	0,92231493
3,9174872	1,36545043	0,35466097	-0,5515712	0,19371412	0,3982519	0,92231493
1,95932093	-	0,3562755	-	0,19532864	0,32302639	0,92654819
1,95932093	0,67259795	0,3562755	1,24442368	0,19532864	0,32302639	0,92654819
1,95894179	-	0,34190021	-	0,18095336	0,32300538	0,88885649
1,95894179	0,67240443	0,34190021	1,24461721	0,18095336	0,32300538	0,88885649
1,95853974	-	0,33453836	-	0,17359151	0,3229831	0,86955388
1,95853974	0,67219916	0,33453836	1,24482247	0,17359151	0,3229831	0,86955388
1,95811524	-	0,33630947	-	0,17536262	0,32295956	0,8741977
1,95811524	0,6719824	0,33630947	1,24503923	0,17536262	0,32295956	0,8741977
0,97966046	-	0,33496467	-	0,17401782	0,2477689	0,87067166
0,97966046	0,02054923	0,33496467	1,93757086	0,17401782	0,2477689	0,87067166
0,97966046	-	0,34205907	-	0,18111222	0,2477689	0,88927302
0,97966046	0,02054923	0,34205907	1,93757086	0,18111222	0,2477689	0,88927302
0,97966046	-	0,34726696	-	0,18632011	0,2477689	0,902928
0,97966046	0,02054923	0,34726696	1,93757086	0,18632011	0,2477689	0,902928

DETERMINACION DE LA CURVA DE RETENCION DE AGUA DE SUELOS GRANULARES USANDO REDES NEURONALES ARTIFICIALES

Succión Matricial <b>S</b> (kPa)	LN Succión Matricial <b>S</b> (kPa)	Contenido Volumétrico de Agua	MEDIA CERO LN Succión Matricial <b>S</b> (kPa)	MEDIA CERO Contenido Volumétrico de Agua $\theta$	LN Succión Matricial <b>S</b> (kPa) ENTRE 0 Y 1,	Contenido Volumétrico de Agua $q$ ENTRE 0 Y 1
0,97966046	- 0,02054923	0,34608058	- 1,93757086	0,18513373	0,2477689	0,89981734
0,1	- 2,30258509	0,33562126	- 4,21960672	0,1746744	0	0,87239321
0,1	- 2,30258509	0,31753221	- 4,21960672	0,15658536	0	0,82496412
0,1	- 2,30258509	0,31384986	- 4,21960672	0,152903	0	0,81530907
0,1	- 2,30258509	0,32901388	- 4,21960672	0,16806703	0	0,85506881
0,48983023	- 0,71369641	0,34304734	- 2,63071804	0,18210049	0,1725114	0,89186424
0,48983023	- 0,71369641	0,3434413	- 2,63071804	0,18249445	0,1725114	0,8928972
0,48983023	- 0,71369641	0,35198225	- 2,63071804	0,1910354	0,1725114	0,91529139
0,48983023	- 0,71369641	0,347206	- 2,63071804	0,18625914	0,1725114	0,90276815

A.10. RESULTADOS NUMERICOS DEL MODELAMIENTO DE LAS CURVAS DE RETENCION USANDO REDES NEURONALES

A.10.1 ARENAS FINAS UNIFORMES

<b>DATOS DEL LAB.</b>			
<b>Contenido Volumétrico de Agua</b>	<b>medidos</b>	<b>estimados</b>	<b>error</b>
	<b>Succión Matricial S (kPa)</b>	<b>Succión Matricial S (kPa)</b>	
0,071763	0,5	0,5068	-0,0068013
0,97472	0	0,1255	-0,1255
0,93713	0,32303	0,28736	0,035667
0,92928	0,17249	0,17335	-0,00085839
0,94164	0,39828	0,25437	0,14392
0,058982	0,61928	0,60537	0,013913
0,93157	0,24777	0,24822	-0,000447
0,96184	0	-0,047675	0,047675
0,020331	0,61928	0,64177	-0,022486
0,057922	0,61928	0,60595	0,01333
0,94496	0,24777	0,24894	-0,001174
0,95524	0,17249	0,22204	-0,049545
0,95539	0,32303	0,21779	0,10523
0,082928	0,5	0,51836	-0,018362
0,59884	0,42253	0,41798	0,0045491
0,36659	0,45906	0,45906	-9,63E-07
0,94035	0,36707	0,22177	0,1453
0,072023	0,57526	0,50703	0,068224
0,042634	0,92474	0,89067	0,034075
0,0079471	0,71127	0,72036	-0,0090887
0,011197	0,71127	0,70264	0,0086333
0,96838	0,24776	0,24934	-0,0015832
0,93165	0,36707	0,36635	0,00071848
0,68777	0,4225	0,40056	0,021946
0,73199	0,4225	0,43477	-0,012269
0,58657	0,42253	0,42846	-0,0059336
0,70609	0,4225	0,42065	0,00185
0,94931	0,39828	0,25508	0,14321
0,074198	0,5	0,52339	-0,02339

<b>DATOS DEL LAB.</b>			
<b>Contenido Volumétrico de Agua</b>	<b>medidos</b>	<b>estimados</b>	<b>error</b>
	<b>Succión Matricial S (kPa)</b>	<b>Succión Matricial S (kPa)</b>	
0,071763	0,5	0,5068	-0,0068013
0,97472	0	0,1255	-0,1255
0,93713	0,32303	0,28736	0,035667
0,92928	0,17249	0,17335	-0,00085839
0,94164	0,39828	0,25437	0,14392
0,058982	0,61928	0,60537	0,013913
0,93157	0,24777	0,24822	-0,000447
0,96184	0	-0,047675	0,047675
0,020331	0,61928	0,64177	-0,022486
0,057922	0,61928	0,60595	0,01333
0,94496	0,24777	0,24894	-0,001174
0,95524	0,17249	0,22204	-0,049545
0,95539	0,32303	0,21779	0,10523
0,082928	0,5	0,51836	-0,018362
0,59884	0,42253	0,41798	0,0045491
0,36659	0,45906	0,45906	-9,63E-07
0,94035	0,36707	0,22177	0,1453
0,072023	0,57526	0,50703	0,068224
0,042634	0,92474	0,89067	0,034075
0,0079471	0,71127	0,72036	-0,0090887
0,011197	0,71127	0,70264	0,0086333
0,96838	0,24776	0,24934	-0,0015832
0,93165	0,36707	0,36635	0,00071848
0,68777	0,4225	0,40056	0,021946
0,73199	0,4225	0,43477	-0,012269
0,58657	0,42253	0,42846	-0,0059336
0,70609	0,4225	0,42065	0,00185
0,94931	0,39828	0,25508	0,14321
0,074198	0,5	0,52339	-0,02339
0,93741	0,24777	0,27634	-0,028567
0,9632	0,24777	0,19486	0,052907
0,025188	0,92474	0,72409	0,20065
0,017283	0,61928	0,63667	-0,017393
0,084645	0,57526	0,56612	0,0091377

<b>DATOS DEL LAB.</b>			
<b>Contenido Volumétrico de Agua</b>	<b>medidos</b>	<b>estimados</b>	<b>error</b>
	<b>Succión Matricial S (kPa)</b>	<b>Succión Matricial S (kPa)</b>	
1	0,24776	0,28547	-0,037716
0,92143	0,36707	0,31164	0,055431
0,87794	0,40051	0,40518	-0,0046638
0,81219	0,36707	0,36794	-0,00087136
0,95095	0,17249	0,25996	-0,087471
0,041297	0,92474	0,91764	0,0070995
0,051943	0,61928	0,65822	-0,038944
0,93634	0,17251	0,13894	0,033572
0,8226	0,40051	0,40137	-0,00085245
0,96268	0	0,092142	-0,092142
0,94792	0,24776	0,25018	-0,0024226
0,026482	0,61928	0,75707	-0,13779
0,98772	0,24776	0,20443	0,043332
0,93482	0,39828	0,39972	-0,0014384
0,011906	0,71127	0,69402	0,017254
0,94192	0,39777	0,25704	0,14073
0,976	0,25	0,13001	0,11999
0,93668	0,17474	0,2448	-0,070056
0,94419	0	0,25215	-0,25215
0,074627	0,5	0,52872	-0,028716
0,01035	0,71127	0,71148	-0,00020929
0,90141	0,36928	0,36901	0,00027471
0,021365	0,61928	0,65214	-0,032863
0,94428	0,25	0,25169	-0,0016914
0,33646	0,45971	0,45971	-1,69E-07
0,036373	0,92474	0,95543	-0,03069
0,57971	0,42255	0,43215	-0,0095983
0,71475	0,42255	0,42896	-0,0064115
0,82354	0,40051	0,4024	-0,0018897
0,078923	0,57526	0,55194	0,023321
0,93972	0	0,19716	-0,19716
0,94557	0,32526	0,24746	0,077802
0,056282	0,61928	0,61033	0,0089548
0,95632	0,17474	0,18099	-0,0062432
0,30633	0,45906	0,45906	-1,08E-06

<b>DATOS DEL LAB.</b>			
<b>Contenido Volumétrico de Agua</b>	<b>medidos</b>	<b>estimados</b>	<b>error</b>
	<b>Succión Matricial S (kPa)</b>	<b>Succión Matricial S (kPa)</b>	
0,95861	0	0,016468	-0,016468
0,90668	0,17251	0,22754	-0,055028
0,94972	0,17251	0,25655	-0,084041
0,55372	0,42253	0,41595	0,006581
0,94128	0,17249	0,24869	-0,076197
0,75718	0,40051	0,38895	0,011563
0,95399	0,17251	0,24785	-0,075341
0,83646	0,40051	0,39276	0,0077525
0,064064	0,57526	0,59239	-0,017132
0,094959	0,57526	0,57527	-1,28E-05
0,069618	0,5	0,51971	-0,019707
0,73314	0,4225	0,43434	-0,011839
0,95226	0,32303	0,26009	0,062934
0,93751	0,32303	0,26871	0,054321

<b>CURVA TEORICA</b>			
<b>Contenido Volumétrico de Agua</b>	<b>medidos</b>	<b>estimados</b>	<b>error</b>
	<b>Succión Matricial S (kPa)</b>	<b>Succión Matricial S (kPa)</b>	
0,92845	0,34949	0,29992	0,04957
0,020565	0,63602	0,64373	-0,00771
0,57093	0,43509	0,43311	0,00198
0,47613	0,44454	-0,51639	0,96093
0,05976	0,54402	0,60538	-0,06136
0,83176	0,40051	0,40005	0,00046
0,93784	0,29402	0,23759	0,05643
0,66909	0,42474	0,3852	0,03954
0,02421	0,61928	0,70142	-0,08214

<b>CURVA TEORICA</b>			
<b>Contenido Volumétrico de Agua</b>	<b>medidos</b>	<b>estimados</b>	<b>error</b>
	<b>Succión Matricial S (kPa)</b>	<b>Succión Matricial S (kPa)</b>	
0,007789	0,75	0,71975	0,03025
0,9385	0,23856	0,18866	0,0499
0,010668	0,71127	0,7084	0,00287
0,017972	0,65051	0,6346	0,01591
0,009477	0,72577	0,71806	0,00771
0,0114	0,70323	0,70026	0,00297
0,93857	0,17474	0,18612	-0,01138
0,84362	0,39777	0,37988	0,01789
0,029755	0,59949	0,84535	-0,24586
0,93859	0,075257	0,18549	-0,110233
0,86465	0,39205	0,37339	0,01866
0,0081477	0,74443	0,72088	0,02355
0,93859	0	0,18531	-0,18531
0,016024	0,6633	0,64475	0,01855
0,93855	0,21127	0,18689	0,02438
0,8822	0,38602	0,42062	-0,0346
0,031235	0,59505	0,88199	-0,28694
0,039301	0,57526	0,9458	-0,37054
0,0145	0,67474	0,66046	0,01428
0,013271	0,68509	0,67607	0,00902
0,85246	0,39552	0,36916	0,02636
0,0085438	0,73856	0,72112	0,01744
0,32393	0,46127	-0,93785	1,39912
0,75933	0,4133	0,38116	0,03214
0,85458	0,39495	0,36815	0,0268
0,91263	0,36928	0,26312	0,10616
0,0089841	0,73235	0,72026	0,01209
0,93847	0,24891	0,19019	0,05872
0,93846	0,25108	0,19063	0,06045
0,9354	0,32526	-0,17334	0,4986
0,93858	0,11928	0,18568	-0,0664
0,93853	0,22577	0,18757	0,0382
0,93856	0,19454	0,18644	0,0081
0,010034	0,71877	0,71421	0,00456
0,93857	0,15051	0,18588	-0,03537
0,84922	0,39637	0,37199	0,02438
0,93846	0,25	0,1904	0,0596
0,012255	0,69454	0,68951	0,00503

## A.10.2 ARENAS MEDIAS UNIFORMES

<b>DATOS DEL LAB.</b>			
<b>Contenido Volumétrico de Agua</b>	<b>medidos</b>	<b>estimados</b>	<b>error</b>
	<b>Succión Matricial S (kPa)</b>	<b>Succión Matricial S (kPa)</b>	
0,036341	0,57526	0,45122	0,12404
0,054469	0,40051	0,43958	-0,039066
0,01653	0,71127	0,62802	0,083256
0,015097	0,61928	0,61673	0,0025454
0,90315	0,36707	0,32478	0,042292
0,57493	0	-0,032679	0,032679
0,90274	0,24777	0,3254	-0,077627
0,020328	0,5	0,61	-0,11
0,0084289	0,92474	0,75592	0,16882
0,67649	0,17249	0,10154	0,070954
0,85175	0,3982	0,38329	0,014916
0,91556	0,36707	0,30344	0,063631
0,015652	0,61928	0,6219	-0,0026241
0,52752	0,17243	0,20234	-0,029911
0,87024	0,24777	0,3628	-0,11503
0,018028	0,61928	0,6296	-0,010316
0,05023	0,49779	0,43993	0,057854
0,0063529	0,92474	0,93731	-0,012569
0,57633	0	0,038731	-0,038731
0,65589	0	0,12797	-0,12797
0,58448	0,32303	0,22719	0,095839
0,018341	0,57526	0,62837	-0,053115
0,02173	0,71127	0,5896	0,12168
0,015742	0,61928	0,62266	-0,0033823
0,60725	0,17243	0,15097	0,021459
0,033194	0,42253	0,46188	-0,039349
0,022623	0,5	0,57526	-0,075257
0,0063398	0,92474	0,93858	-0,013835
0,040939	0,4225	0,44383	-0,021332
0,033484	0,42253	0,46061	-0,038082
0,55207	0,17249	0,18032	-0,0078328
0,5396	0,17249	0,16604	0,0064522
0,0099237	0,61928	0,6635	-0,044223
0,50887	0,32303	0,32238	0,00064223
0,48334	0,32303	0,32119	0,0018365
0,02364	0,71127	0,55875	0,15252

<b>DATOS DEL LAB.</b>			
<b>Contenido Volumétrico de Agua</b>	<b>medidos</b>	<b>estimados</b>	<b>error</b>
	<b>Succión Matricial S (kPa)</b>	<b>Succión Matricial S (kPa)</b>	
0,019263	0,57526	0,6219	-0,046647
0,037589	0,45906	0,4485	0,010565
0,82301	0,24776	0,24788	-0,00012639
0,90373	0,3982	0,32388	0,074328
0,58633	0,17249	0,2223	-0,049806
0,84475	0,3982	0,39509	0,0031164
0,68143	0	0,08196	-0,08196
0,031817	0,57526	0,4689	0,10635
0,024935	0,5	0,53865	-0,038648
0,66382	0,17246	0,12326	0,049192
0,65723	0,17248	0,1274	0,045082
0,91684	0,24777	0,30092	-0,053155
0,02438	0,5	0,54708	-0,04708
0,0081283	0,61928	0,77908	-0,1598
0,87861	0,36707	0,3548	0,012273
0,054775	0,49779	0,43957	0,058223
0,060945	0,40051	0,43941	-0,038896
0,87152	0,3982	0,36161	0,036599
0,064805	0,40051	0,43938	-0,038867
0,79843	0,24776	2,48E-01	-2,47E-05
0,88021	0,36707	0,35319	0,013881
0,063116	0,40051	0,43939	-0,038877
0,66814	0,24776	0,11868	0,12907
0,028682	0,4225	0,49259	-0,070086
0,52189	0,32303	0,34393	-0,020904
0,046195	0,45906	0,44077	0,018289
0,032218	0,42253	0,46668	-0,044147
0,039019	0,4225	0,44611	-0,02361
0,015905	0,61928	0,62398	-0,0046996
0,58862	0,17474	0,21193	-0,037189
0,90209	0,25	0,32637	-0,076368
0,026441	0,57526	0,5177	0,057555
0,060834	0,40051	0,43941	-0,038898
1	0	5,64E-05	-5,64E-05
0,020633	0,71127	0,60591	0,10536
0,032966	0,42255	0,46293	-0,040381

<b>DATOS DEL LAB.</b>			
<b>Contenido Volumétrico de Agua</b>	<b>medidos</b>	<b>estimados</b>	<b>error</b>
	<b>Succión Matricial S (kPa)</b>	<b>Succión Matricial S (kPa)</b>	
0,61396	0,17474	0,14269	0,032052
0,052502	0,49781	0,4397	0,058102
0,52464	0,32526	0,27914	0,04612
0,76319	0,25	2,50E-01	5,21E-05
0,041892	0,45971	0,443	0,016713
0,89438	0,3656	0,33707	0,028525
0,016193	0,61928	0,62605	-0,006773
0,0070405	0,92474	0,87257	0,05217
0,011235	0,61928	0,61721	0,0020718
0,62214	0	0,13701	-0,13701
0,036213	0,42255	0,45154	-0,02899
0,023066	0,5	0,56804	-0,068041
0,86794	0,39777	0,36498	0,032787

<b>CURVA TEORICA</b>			
<b>Contenido Volumétrico de Agua</b>	<b>medidos</b>	<b>estimados</b>	<b>error</b>
	<b>Succión Matricial S (kPa)</b>	<b>Succión Matricial S (kPa)</b>	
1,15E-06	9,76E-01	1,48E+00	-5,03E-01
0,00048572	0,59949	1,4485	-8,49E-01
0,85206	0,37629	0,38284	-6,55E-03
0,00083519	0,57526	1,4254	-8,50E-01
0,00011062	0,68509	1,4721	-7,87E-01
0,36399	0,42474	0,43935	-1,46E-02
0,85248	0,3762	0,38223	-6,03E-03
6,69E-06	9,01E-01	1,48E+00	-5,78E-01
0,97072	0,17474	0,1348	3,99E-02
0,15666	0,44454	0,43936	5,18E-03
0,97067	0,21127	0,13503	7,62E-02
0,86834	0,37284	0,3646	8,24E-03
0,03017	0,47577	0,47985	-4,08E-03

<b>CURVA TEORICA</b>			
<b>Contenido Volumétrico de Agua</b>	<b>medidos</b>	<b>estimados</b>	<b>error</b>
	<b>Succión Matricial S (kPa)</b>	<b>Succión Matricial S (kPa)</b>	
0,015937	0,48856	0,62422	-1,36E-01
0,95891	0,32526	0,18183	1,43E-01
0,66427	0,40051	0,12287	2,78E-01
0,06527	0,46127	0,43938	2,19E-02
1,04E-05	8,69E-01	1,48E+00	-6,09E-01
5,14E-07	9,89E-01	1,48E+00	-4,90E-01
4,60E-05	7,50E-01	1,48E+00	-7,26E-01
0,10036	0,45323	0,43936	1,39E-02
0,01212	0,49443	0,60338	-1,09E-01
5,77E-05	7,32E-01	1,48E+00	-7,43E-01
3,01E-06	9,45E-01	1,48E+00	-5,34E-01
1,95E-06	9,61E-01	1,48E+00	-5,17E-01
0,51204	0,4133	0,35975	5,36E-02
0,91794	0,35784	0,29874	5,91E-02
7,64E-05	7,11E-01	1,47E+00	-7,63E-01
0,00024203	0,63602	1,464	-8,28E-01
4,93E-05	7,44E-01	1,48E+00	-7,31E-01
0,97051	0,23856	0,13569	1,03E-01
0,00018919	0,65051	1,4672	-8,17E-01
5,32E-05	7,39E-01	1,48E+00	-7,37E-01
0,00032803	0,61928	1,4586	-8,39E-01
0,9707	0,19454	0,13488	5,97E-02
0,883	0,36928	0,35031	1,90E-02
0,97073	0,15051	0,13475	1,58E-02
0,93459	0,34949	0,25984	8,97E-02
0,00946	0,5	0,68781	-1,88E-01
0,97075	0	0,13466	-1,35E-01
0,026278	0,47845	0,51981	-4,14E-02
4,48E-06	9,25E-01	1,48E+00	-5,54E-01
1,82E-05	8,25E-01	1,48E+00	-6,52E-01
9,65E-05	6,95E-01	1,47E+00	-7,78E-01
6,90E-05	7,19E-01	1,47E+00	-7,56E-01
0,021577	0,48235	0,59199	-1,10E-01
0,24297	0,43509	0,43936	-4,27E-03
8,54E-05	7,03E-01	1,47E+00	-7,70E-01
0,043644	0,46877	0,44184	2,69E-02
0,00012905	0,67474	1,4709	-7,96E-01

<b>CURVA TEORICA</b>			
<b>Contenido Volumétrico de Agua</b>	<b>medidos</b>	<b>estimados</b>	<b>error</b>
	<b>Succión Matricial S (kPa)</b>	<b>Succión Matricial S (kPa)</b>	
0,79322	0,38602	1,785	-1,40E+00
0	1	1,4788	-4,79E-01
0,0019278	0,54402	1,3457	-8,02E-01
0,97074	0,11928	0,13471	-1,54E-02
0,96796	0,29402	0,14628	1,48E-01
6,29E-05	7,26E-01	1,48E+00	-7,49E-01
0,97036	0,25	0,13631	1,14E-01
0,97061	0,22577	0,13529	9,05E-02
0,00015397	0,6633	1,4694	-8,06E-01
0,97075	0,075257	0,13469	-5,94E-02

A.10.3 ARENA DIFERENTES TAMAÑOS DE PARTÍCULA

<b>DATOS DEL LAB.</b>			
<b>Contenido Volumétrico de Agua</b>	<b>Medidos Succión Matricial S (kPa)</b>	<b>Estimados Succión Matricial S (kPa)</b>	<b>error</b>
0,045855	0,5	0,55338	-0,053379
0,88799	0,1725	0,23679	-0,064285
0,30545	0,4225	0,41443	0,0080693
0,20485	0,45906	0,44869	0,010369
0,8655	0,24776	0,23001	0,017745
0,020577	0,61928	0,58622	0,03306
0,90293	0,24777	0,23515	0,012622
0,88886	0,32301	0,23567	0,087337
0,8742	0,32296	0,24605	0,076907
0,92123	0,1725	0,32767	-0,15516
0,060699	0,57526	0,58262	-0,0073629

<b>DATOS DEL LAB.</b>			
<b>Contenido Volumétrico de Agua</b>	<b>Medidos Succión Matricial S (kPa)</b>	<b>Estimados Succión Matricial S (kPa)</b>	<b>error</b>
0,66464	0,36707	0,36724	-0,00017374
0,017897	0,61928	0,65079	-0,031514
0,81531	0	0,013852	-0,013852
0,88927	0,24777	0,23514	0,01263
0,89781	0,24776	0,22933	0,018431
0,051041	0,57526	0,5474	0,027857
0,90277	0,17251	0,23481	-0,062302
0,20227	0,45906	0,45125	0,00781
0,86955	0,32298	0,2403	0,08268
0,30455	0,40051	0,41396	-0,013441
0,042812	0,5	0,55697	-0,056973
0,012831	0,92474	0,93934	-0,014602
0,34275	0,40051	0,40353	-0,0030135
0,87712	0,24776	0,24675	0,0010052
0,021359	0,61928	0,58322	0,036062
0,29746	0,4225	0,4107	0,011803
0,015107	0,92474	0,88843	0,036315
0,053445	0,5	0,54529	-0,045289
0,91461	0,36707	0,288	0,079068
0,044239	0,57526	0,55529	0,019969
0,87239	0	0,24454	-0,24454
0,18411	0,49779	0,47051	0,027279
0,8929	0,17251	0,23115	-0,058636
0,071139	0,5	0,61009	-0,11009
0,91932	0,39825	0,31774	0,08051
1	0,1725	0,17381	-0,0013106
0,89982	0,24777	0,23048	0,017286
0,85507	0	0,17955	-0,17955
0,13474	0,49779	0,52992	-0,032128
0,89186	0,17251	0,23213	-0,059623
0,024808	0,61928	0,57788	0,041405
0,92655	0,32303	0,33497	-0,011948
0,87067	0,24777	0,24225	0,0055169
0,06043	0,57526	0,57921	-0,003948
0,013596	0,92474	0,9324	-0,0076557
0,28868	0,40051	0,40803	-0,0075118
0,82496	0	-0,031552	0,031552

<b>DATOS DEL LAB.</b>			
<b>Contenido Volumétrico de Agua</b>	<b>Medidos Succión Matricial S (kPa)</b>	<b>Estimados Succión Matricial S (kPa)</b>	<b>error</b>
0,92231	0,39825	0,33205	0,066198
0,33799	0,4225	0,41752	0,0049822
0,17052	0,49779	0,48607	0,011716
0,80552	0,24776	0,24636	0,0014013
0,28198	0,40051	0,40707	-0,0065513
0,91529	0,17251	0,2924	-0,11989
0,8468	0,17474	0,11827	0,056474
0,16312	0,49781	0,49486	0,0029497
0,91806	0,39777	0,31016	0,087602
0,31363	0,42255	0,41914	0,0034125
0,054102	0,57526	0,545	0,030254
0,065642	0,71127	0,61386	0,097415
0,20356	0,45971	0,44997	0,0097446
0,85675	0,3656	0,18996	0,17564
0,013845	0,92474	0,92876	-0,0040169
0,93641	0,17474	0,17196	0,0027798
0,30449	0,40051	0,41392	-0,01341
0,053313	0,5	0,54537	-0,045369
0,02116	0,61928	0,58382	0,035463
0,84193	0	0,077154	-0,077154
0,97187	0	0,0092196	-0,0092196
0,88979	0,32526	0,2345	0,090761
0,86149	0,25	0,21466	0,035345

<b>CURVA TEORICA</b>			
<b>Contenido Volumétrico de Agua</b>	<b>Medidos Succión Matricial S (kPa)</b>	<b>Estimados Succión Matricial S (kPa)</b>	<b>error</b>
0,91005	0,19454	0,26118	-0,06664
0,90984	0,25	0,26009	-0,01009

<b>CURVA TEORICA</b>			
<b>Contenido Volumétrico de Agua</b>	<b>Medidos Succión Matricial S (kPa)</b>	<b>Estimados Succión Matricial S (kPa)</b>	<b>error</b>
0,029129	0,59949	0,57291	0,02658
0,027093	0,60784	0,57524	0,0326
0,90034	0,32526	0,23101	0,09425
0,00052109	0,97577	0,9572	0,01857
0,0091747	0,75	0,94774	-0,19774
0,91003	0,21127	0,26107	-0,0498
0,095652	0,49443	0,57951	-0,08508
0,024979	0,61746	0,57768	0,03978
0,036369	0,57526	0,56453	0,01073
0,0012583	0,94454	0,9564	-0,01186
0,14914	0,46877	0,51191	-0,04314
0,019157	0,65051	0,60195	0,04856
0,11647	0,48235	0,55308	-0,07073
0,024602	0,61928	0,57812	0,04116
0,91008	0,075257	0,26135	-0,186093
0,010437	0,73235	0,94613	-0,21378
0,87749	0,34949	0,2467	0,10279
0,00024107	0,98856	0,9575	0,03106
0,0095565	0,74443	0,94728	-0,20285
0,015929	0,67474	0,83009	-0,15535
0,012904	0,70323	0,93887	-0,23564
0,82651	0,36928	-0,028116	0,397396
0,014747	0,68509	0,90493	-0,21984
0,012168	0,71127	0,94243	-0,23116
0,20516	0,45323	0,44839	0,00484
0	1	0,95776	0,04224
0,13082	0,47577	0,53487	-0,0591
0,91006	0,17474	0,26125	-0,08651
0,013754	0,69454	0,93019	-0,23565
0,79584	0,37629	0,74594	-0,36965
0,0099751	0,73856	0,94676	-0,2082
0,0024564	0,90051	0,95511	-0,0546
0,011522	0,71877	0,94423	-0,22546
0,1731	0,46127	0,48306	-0,02179

<b>CURVA TEORICA</b>			
<b>Contenido Volumétrico de Agua</b>	<b>Medidos Succión Matricial S (kPa)</b>	<b>Estimados Succión Matricial S (kPa)</b>	<b>error</b>
0,81195	0,37284	0,067487	0,305353
0,0034529	0,86928	0,95404	-0,08476
0,030294	0,59505	0,57157	0,02348
0,90999	0,22577	0,26089	-0,03512
0,91009	0	0,26138	-0,26138
0,017365	0,6633	0,69027	-0,02697
0,90993	0,23856	0,26058	-0,02202
0,0051371	0,82526	0,95221	-0,12695
0,00085326	0,96127	0,95684	0,00443
0,91008	0,11928	0,26133	-0,14205
0,90806	0,29402	0,25169	0,04233
0,050142	0,54402	0,54838	-0,00436
0,30946	0,43509	0,41667	0,01842
0,0017711	0,92474	0,95585	-0,03111
0,087908	0,5	0,58928	-0,08928
0,043351	0,55761	0,55634	0,00127
0,021471	0,63602	0,58292	0,0531
0,010949	0,72577	0,94534	-0,21957
0,034587	0,58055	0,5666	0,01395
0,105	0,48856	0,56766	-0,0791
0,91007	0,15051	0,26129	-0,11078
0,24896	0,44454	0,41476	0,02978