



UNIVERSIDAD NACIONAL AUTÓNOMA
DE MÉXICO

FACULTAD DE ESTUDIOS SUPERIORES ARAGON

**VARIADOR NEURONAL ESPACIAL DE
GEO-PROPIEDADES**

T E S I S

QUE PARA OBTENER EL TÍTULO DE:

INGENIERO CIVIL

P R E S E N T A :

CESAR ALEJANDRO GARCIA FELIX



**DIRECTOR DE TESIS:
DRA. SILVIA RAQUEL GARCIA BENITEZ**

MÉXICO, D. F., FEBRERO DEL 2014



UNAM – Dirección General de Bibliotecas

Tesis Digitales
Restricciones de uso

DERECHOS RESERVADOS ©
PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL

Todo el material contenido en esta tesis está protegido por la Ley Federal del Derecho de Autor (LFDA) de los Estados Unidos Mexicanos (Méjico).

El uso de imágenes, fragmentos de videos, y demás material que sea objeto de protección de los derechos de autor, será exclusivamente para fines educativos e informativos y deberá citar la fuente donde la obtuvo mencionando el autor o autores. Cualquier uso distinto como el lucro, reproducción, edición o modificación, será perseguido y sancionado por el respectivo titular de los Derechos de Autor.

JURADO ASIGNADO:

Presidente: Ing. José Mario Avalos Hernandez
Secretario: Dra. Silvia Raquel Garcia Benitez
Vocal: Ing. Gabriel Álvarez Bautista
1^{er}. Suplente: Ing. Maridel Zárate Morales
2^{do}. Suplente: Ing. Jorge Arturo Pantoja Domínguez

Lugar o lugares donde se realizó la tesis: Instituto de Ingeniería UNAM

TUTOR DE TESIS:

DRA. SILVIA RAQUEL GARCÍA BENÍTEZ

FIRMA

AGRADECIMIENTOS

Primeramente le doy gracias al Instituto de Ingeniería UNAM por a verme brindado durante este periodo importante de mi vida el espacio y tiempo para la realización de esta tesis.

A mi directora de tesis, la Dra. Silvia Raquel Garcia Benitez por su esfuerzo y dedicación, quien con sus conocimientos, su experiencia, su paciencia y su motivación ha logrado en mí que pueda concluir este trabajo.

A los sinodales de tesis: Ing. Jose Mario Avalos Hernandez, Ing. Gabriel Alvarez Bautista, Ing. Maridel Zarate Morales y al Ing. Jorge Arturo Pantoja Dominguez., por compartirme sus consejos y observaciones en la revisión de éste trabajo de tesis.

Y finalmente a mis Padres, Hermanos y Amigos por su apoyo en todo momento.

RESUMEN

Esta Tesis plantea una metodología neuronal para estimar la variación espacial de geo-propiedades en un volumen complejo de roca. En la investigación se enuncian y discuten los aspectos de los algoritmos neuronales que pueden ser utilizados para encontrar multi-relaciones, adaptativas y flexibles, {X, Y, Z \rightarrow geo-propiedad} y concluir sobre comportamientos a través de ambientes 3D gráfico/numéricos. Mediante un ejemplo que trata el modelado de las laderas del sitio de construcción de una presa, se muestra y justifica el modelo neuronal descrito.

Contenido

INTRODUCCIÓN.....	1
Objetivo.....	2
Alcances	2
CAPÍTULO I CARACTERIZACIÓN BÁSICA DE MACIZOS ROCOSOS.....	3
1.1 Clasificación geomecánica de macizos rocosos para fines de ingeniería.....	3
1.1.1 Índice de calidad de roca (RQD).....	4
1.1.2 Fracturación del macizo rocoso.....	5
1.1.3 Porcentaje de Recuperación (%REC).....	6
CAPÍTULO II DEPENDENCIA ESPACIAL	7
2.1 Algunos métodos convencionales de interpolación numérica.....	8
2.1.1 Método de interpolación lineal.....	8
2.1.2 Método de vecinos cercanos.....	8
2.1.3 Método de superficie de tendencia.....	9
2.2 Geoestadística.	10
2.2.1 Campos aleatorios.	11
2.2.2 Análisis estructural.	12
2.2.3 Estimaciones paramétricas.	13
CAPÍTULO III REDES NEURONALES: ASPECTOS BÁSICOS	16
3.1 Descripción de una neurona artificial (RNs).....	16
3.2 Perceptrón multicapa.....	20
3.2.1 Regla de entrenamiento- aprendizaje	22
CAPÍTULO IV APROXIMADOR NEURONAL DE GEO-PROPIEDADES	24
4.1 Descripción del campo de estudio.....	24
4.1.1 Campaña de exploración	27
4.1.2 Volumen para la modelación neuronal.....	28
4.2 Geo-variables para el modelado 3D	30
4.2.1 Variables geométricas.	30
4.2.2 Variables geotécnicas.....	30

4.3	Presentación del aproximador neuronal : generalidades	35
4.4	Estimaciones neuronales en fase de entrenamiento/prueba.....	37
4.5	VEN RQD margen derecho/izquierdo	41
4.6	VEN FRAC margen derecho/izquierdo	41
4.7	VEN %REC margen derecho/izquierdo.....	41
	CONCLUSIONES.....	48
	REFERENCIAS	49
	ANEXO I BASE DE DATOS	53

INTRODUCCIÓN

La modelación de la distribución espacial de las condiciones de los suelos se puede realizar a través de esencialmente dos enfoques: i) se resuelve un sistema de ecuaciones que se ajustan a los valores medidos y ii) a partir de algunos datos puntuales se predice la distribución espacial y/o temporal de los atributos en estudio. En la segunda visión intervienen las estimaciones espaciales (definición del valor en ubicaciones no muestreadas) y las simulaciones estocásticas espaciales (se reproduce el comportamiento estadístico del fenómeno). Abusando del lenguaje, en lo sucesivo “estimador espacial” e “interpolador” son usados como sinónimos. Estrictamente un interpolador pretende que la superficie estimada pase exactamente por todos los valores de los sitios medidos y evalúa el valor de una propiedad en localizaciones no muestreadas en el área dentro de las observaciones. El razonamiento intuitivo de la idea de interpolación se establece en el ámbito de las geociencias mediante la ley de Tobler (1970): *“todas las observaciones están relacionadas entre sí, pero las más próximas en el espacio están mayormente relacionadas que las distantes”*.

En este punto resulta conveniente hacer la distinción entre el procedimiento de estimación y la forma de representación de geo-propiedades en el espacio. Usualmente se piensa en la representación (mapas) como si fuera el método de estimación (interpolador); la implementación de los métodos de representación gráfica (mapas) requieren como premisa que los valores estén ubicados en una malla regular, lo cual sólo se puede realizar mediante un procedimiento de interpolación. Existe una gran diversidad de métodos para la representación gráfica de los resultados de la estimación usando mapas (por ejemplo, de contornos, de imagen, de relieves, etc.) pero la confianza en las interpretaciones se basa exclusivamente en el algoritmo de estimación espacial. Cualquiera que sea el método de interpolación, la necesidad de una extensa base de datos crece conforme la complejidad de la condición por modelar se incrementa.

En esta investigación se propone una red neuronal RNs para la estimación espacial de geo-propiedades. A diferencia de otras herramientas de interpolación, los algoritmos neuronales son suficientemente robustos para desarrollar tareas de aproximación en ambientes no suficientemente explícitos (en datos y en conocimiento). La generación de una exhaustiva malla de valores en el entorno 3D (laderas del sitio de desplante de la cortina de una presa) permite una representación adecuada de las características del volumen. Esta propuesta se inspira en el postulado de Tobler (1970) y en las exitosas experiencias de García et al., (2005, 2006, 2011).

El ejemplo presentado muestra la versatilidad y las ventajas operacionales y gráficas de los algoritmos neuronales, aún bajo situaciones tan complejas como un entorno geológico. Las RNs, apropiadamente dirigidas, resuelven problemas de aproximación que serían extremadamente difíciles de analizar con métodos matemáticos/estadísticos tradicionales.

Objetivo

Definir la variación espacial de geo-propiedades en un volumen de suelo/roca complejo. Establecer los criterios que los ingenieros geotécnicos deben manejar para explotar las herramientas del cómputo aproximado, particularmente las redes neuronales. Fundamentar la manera en que la ingeniería práctica se ve beneficiada con propuestas de este tipo: incremento en el conocimiento y en la certeza de los números que se usan en diseño y análisis.

Alcances

Los alcances de esta investigación incluyen:

- i) Una RNs que sea capaz de descubrir relaciones lineales y no lineales entre datos numéricos para analizar y predecir comportamientos complejos. Tarea: Variación espacial de geo-propiedad
- ii) El ambiente gráfico de la variación espacial de la geo-propiedad

CAPÍTULO I CARACTERIZACIÓN BÁSICA DE MACIZOS ROCOSOS

1.1 Clasificación geomecánica de macizos rocosos para fines de ingeniería

En la clasificación de un macizo rocoso se utilizan parámetros geotécnicos útiles en todas las etapas del diseño y consolidación de proyecto de las obras de ingeniería. Los macizos rocosos, como medios discontinuos, presentan un comportamiento geomecánico complejo que, de una forma simplificada, puede ser estudiado y categorizado en función de su aptitud para distintas aplicaciones. Con este objetivo surgieron las clasificaciones geomecánicas, que aportan, mediante la observación directa de las características de los macizos rocosos y la realización de sencillos ensayos, índices de calidad relacionados con los parámetros geomecánicos del macizo y sus características frente a los soportes de túneles y taludes, la excavabilidad de las rocas, entre otros.

Las características de los macizos rocosos que se consideran en las distintas clasificaciones son las siguientes:

- i) Resistencia del material rocoso
- ii) Índice de Calidad de Roca RQD (por sus siglas en inglés *Rock Quality Designation*)
- iii) Espacio entre discontinuidades
- iv) Orientación de discontinuidades
- v) Condiciones de discontinuidades
- vi) Estructura geológica y fallas
- vii) Filtraciones y presencia de agua
- viii) Estado esfuerzos de tensión

Las clasificaciones geomecánicas más utilizadas en la actualidad son la RMR (por sus siglas en inglés *rock mass rating*) de Bienowsky (1973) el cual es un sistema de clasificación de macizo rocosos que permite a su vez relacionar índices de calidad con parámetros geotécnicos del macizo rocoso; y la Q de Barton (1974), la cual constituye un sistema de clasificación de macizos rocosos que permite estimar parámetros geotécnicos del macizo. Otras clasificaciones también usadas y no menos importantes son la clasificación de acuerdo al índice de calidad de roca RQD de Deere y la clasificación de Terzaghi (Terzaghi 1946).

1.1.1 Índice de calidad de roca (RQD)

En 1964 Deere (Deere y Miller, 1966) propuso un índice cuantitativo de la calidad de la roca basado en la recuperación de núcleos con perforación de diamante llamado *Rock Quality Designation* (RQD) (en español acuñado como *Índice de Calidad de Roca*). Se ha usado a nivel global y se ha comprobado que es muy útil en la clasificación de macizos de todo tipo bajo la mirada de gran cantidad de obras civiles. El índice RQD representa la relación entre la suma de las longitudes de los fragmentos de la muestra mayores de 10cm y la longitud total del tramo recuperado (ecuación 1.1):

$$RQD = \frac{\sum -\text{Longitud - de - fragmentos} > 10 - \text{cm}}{\text{Longitud total}} \quad (1.1)$$

Para la estimación del RQD se consideran sólo los fragmentos de la muestra fresca excluyéndose los que presentan un grado de alteración importante. La medida del RQD se debe realizar en cada maniobra de sondeo o en cada cambio litológico, siendo recomendable que la longitud de maniobra no exceda de 1.5m (Figura 1.1). El diámetro mínimo de las muestras debe ser de 48 mm. En la tabla 1.1 se describe la calidad de la roca en función de este índice.

Tabla 1.1 Índice de calidad de roca

RQD (%)	Calidad
< 10	Muy mala
25-50	Mala
50-75	Media
75-90	Buena
90-100	Muy buena

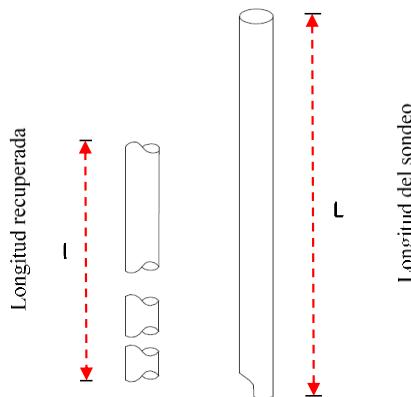


Figura 1.1 Ejemplo de un núcleo recuperado (modificado de Herbert ,2012)

1.1.2 Fracturación del macizo rocoso

La fracturación del macizo rocoso está definida por el número, espaciado y condiciones de las discontinuidades, cualquiera que sea su origen y clase. El grado de fracturación se expresa habitualmente por el valor del Índice RQD (*rock quality designation*), A pesar de su utilidad, este Índice no considera aspectos como la orientación, separación, rellenos y demás condiciones de las discontinuidades por lo que no es suficiente para describir completamente las características de la fracturación de los macizos; aspectos adicionales deben quedar cubiertos por descripciones de campo y de los testigos de los sondeos (Gonzales de Vallejo et al ,2002).

Cuando no se dispone de núcleos de perforación, se podrá estimar el RQD por la cantidad de fisuras contenidas en la unidad de volumen (Figura 1.2), en la que la cantidad de juntas por metro cúbico, en cada sistema de juntas se suman, una simple relación podrá usarse para convertir esta cantidad en RQD para una roca sin arcilla, usando este parámetro. La fracturación de un macizo rocoso se define por el número, espaciado y condiciones de las discontinuidades que presenta, cualquiera que sea su origen y clase (ecuación 1.2 y 1.3).

$$RQD = 115 - 3.3 Jv \quad (1.2)$$

$$RQD = 100 \text{ para } Jv < 4.5 \quad (1.3)$$

donde Jv = cantidad total de juntas o fisuras por m^3

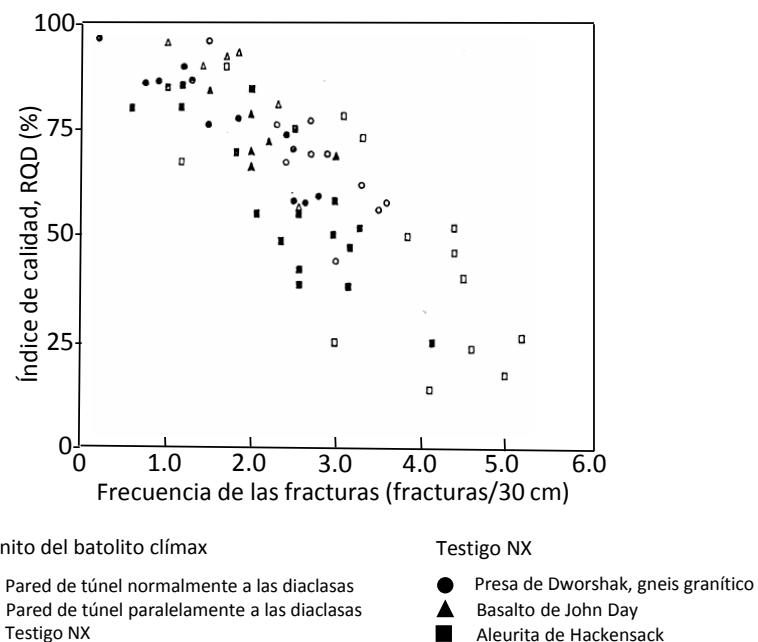


Figura 1.2 Correlación entre los índices de calidad de las rocas: frecuencia de las fracturas y RQD
(modificado de Stagg-Zienkiewics, 1970)

1.1.3 Porcentaje de Recuperación (%REC)

La recuperación de un sondeo se define como el porcentaje de testigo obtenido respecto de la longitud total del sondeo, y aunque para sondeos en suelo es un parámetro muy útil, para sondeos en roca no se puede decir lo mismo, ya que en estos materiales la recuperación suele ser casi siempre muy alta. La recuperación de muestras mediante perforaciones (Figura 1.3) debe tener las siguientes características: inalteradas, verdaderamente representativas del material con un alto porcentaje de recuperación y capaces de permitir identificar las características de la roca, y su fracturamiento, tamaño y espaciamiento de fracturas, grado de alteración y presencia de materiales de relleno.

Las propiedades de la matriz de la roca o “roca intacta”, se determinan principalmente a través de ensayos de laboratorio en probetas extraídas para las diferentes unidades geológico-geotécnicas definidas, para lo cual se deberá, una vez finalizado el levantamiento geotécnico, extraer probetas para este fin. Dentro de la etapa de caracterización se estiman la resistencia de la matriz y el grado de meteorización del tramo geotécnico (Gonzales de Vallejo et al, 2002).

La calidad del testigo recuperado depende de la perforación y de la manipulación de los testigos al ser extraídos (Figura 1.4).



Figura 1.3 Núcleo recuperado de un barreno

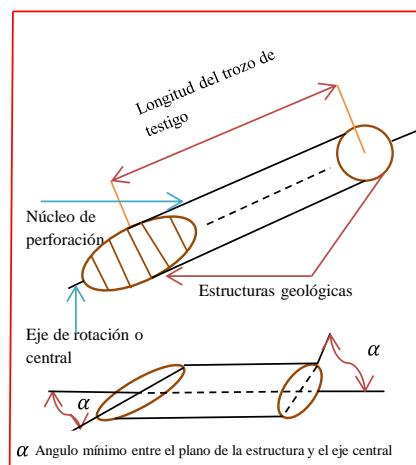


Figura 1.4 Determinación del largo de los testigos y el ángulo con respecto al eje del sondaje (modificado de Leiva G.et al,2000.)

CAPÍTULO II DEPENDENCIA ESPACIAL

La dependencia espacial es un concepto clave en la comprensión y el análisis de un fenómeno espacial. Tobler (1970) enuncia que en los ambientes que tratan con geo-materiales “*todas las observaciones están relacionadas entre sí, pero las más próximas en el espacio están mayormente relacionadas que las distantes*”.

Dependencia espacial se refiere a la relación entre los datos georreferenciados debido a la naturaleza de la variable bajo estudio y el tamaño, forma y configuración de las unidades espaciales. Cuanto menores son las unidades espaciales, mayor será la probabilidad de que las unidades cercanas sean espacialmente dependientes. Si las unidades son largas y estrechas, las posibilidades de dependencia espacial con unidades cercanas serán mayores que si las unidades son más compactas (Quintero, 2009).

La heterogeneidad espacial se produce cuando hay una falta de uniformidad espacial de los efectos de la dependencia espacial y/o de las relaciones entre las variables de estudio. Una estructura de dependencia que no es coherente en toda la zona en estudio carece de homogeneidad. En un sentido, entonces, la heterogeneidad espacial se puede considerar como un caso específico de dependencia espacial. Se representa una realización compleja de la naturaleza de la variable bajo estudio y los efectos del tamaño, forma y configuración de las unidades espaciales.

Otro significado que se le podría dar a la dependencia espacial sería que los valores de una misma variable que son medidos en localidades que son cercanas entre sí tienden a ser similares, es decir, a mayor cercanía geográfica corresponde una mayor similitud en los valores, dicho en otras palabras, la dependencia espacial se produce cuando el valor de la variable dependiente en una unidades espaciales parcialmente función del valor de la misma variable en unidades vecinas. La dependencia espacial hace diferente a la estadística espacial de la tradicional debido a que considera la distancia y la contigüidad existentes entre unidades de observación.

Este trabajo utiliza técnicas neuronales que han sido desarrolladas para determinar los grados de asociación espacial existentes entre nuestras unidades de observación, aportando elementos importantes para estudiar la posible influencia y la dependencia espacial entre estas unidades.

2.1 Algunos métodos convencionales de interpolación numérica.

La interpolación numérica es un problema complejo que permea muchas áreas del cálculo numérico. El objetivo de la interpolación consiste en obtener la expresión matemática en el espacio que verifique una serie de condicionamientos impuestos y que se acomode a un conjunto de puntos definidos (Aymerich & Navarrina, 1985).

2.1.1 Método de interpolación lineal.

Uno de los métodos de interpolación más sencillos es el llamado lineal. En este tipo de interpolación se utilizan dos puntos (x_a, y_a) y (x_b, y_b) para obtener un tercer punto interpolado (x, y) a partir de la siguiente expresión

$$y = y_a + (x - x_a) \frac{(y_b - y_a)}{(x_b - x_a)} \quad (2.1)$$

La interpolación lineal es rápida y sencilla pero poco precisa. La Figura 2.1 muestra una gráfica cuyos puntos evaluados son los interpolados linealmente (línea continua).

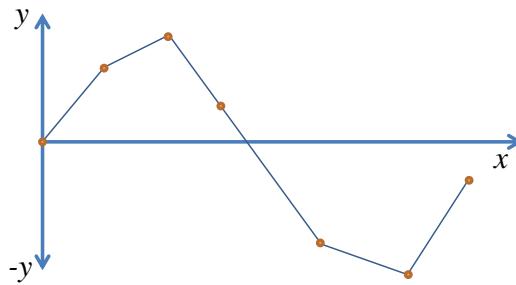


Figura 2.1 Interpolación lineal

2.1.2 Método de vecinos cercanos.

Este tipo de aproximación se caracteriza por la construcción de polígonos (llamados polígonos de Thiessen), los cuales definen áreas de influencia individual por cada punto de un conjunto de puntos. Este interpolador calcula las distancias euclidianas entre un punto de la malla y los demás puntos asignando al punto el valor que exhibe aquel con la menor distancia al punto estudiado. En la Figura 2.2 se muestra un ejemplo ilustrativo de este tipo de interpolador.

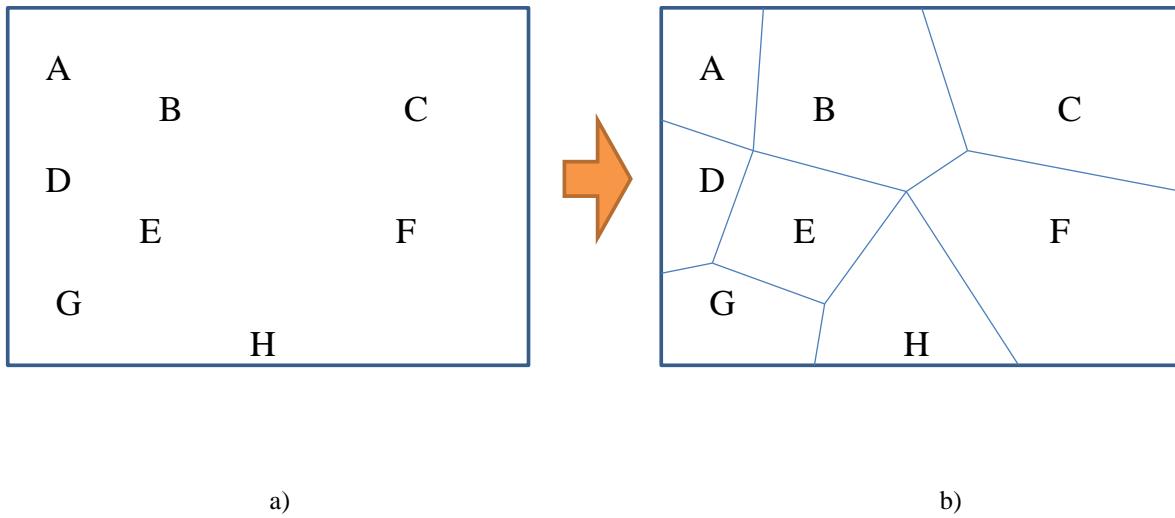


Figura 2.1 Polígonos de Thiessen, a) Conjunto de datos en el plano, b) Polígonos de interpolación de vecino más cercano.

Este método de interpolación se limita a generar polígonos para determinar áreas de influencia y no genera una superficie continua de variación espacial, por lo que la extrapolación se define únicamente por las líneas rectas que se proyectan hacia afuera del conjunto de datos y con longitud infinita.

El objetivo principal de este método es extender la información puntual asumiendo que la mejor información para ubicaciones sin observaciones es el valor del punto más cercano (Aronoff, 1989).

2.1.3 Método de superficie de tendencia.

Una forma relativamente sencilla para describir variaciones graduales en grandes distancias es por medio de una regresión polinomial. La idea es ajustar una superficie polinomial por mínimos cuadrados sobre puntos conocidos obteniendo la menor dispersión. Las funciones que se pueden usar varían desde la más sencilla o lineal (para áreas de poca variación) hasta muy complejas (dependiendo del grado de orden polinomial) para superficies con marcadas e intrincadas relaciones. La superficie que resulta es la que mejor se ajusta a la máxima cantidad de puntos (Burrough, 1985).

Esta técnica únicamente se desarrolla con mapas de puntos en el dominio del atributo numérico.

Ejemplos de superficie con una tendencia lineal, se muestran en la Figura 2.3a mientras en la Figura 2.3b se observa una polinomial.

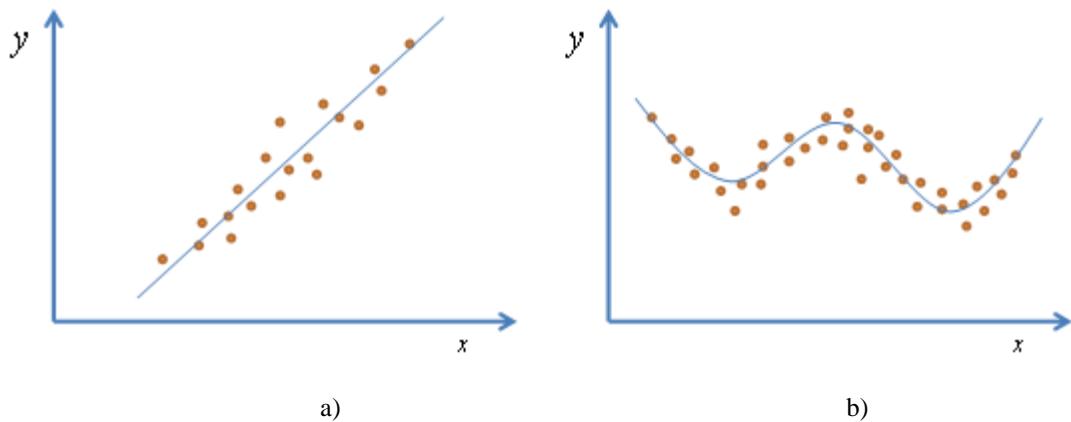


Figura 2.2 Interpolación de tendencia de superficie, a) Regresión lineal, b) Regresión polinomial

2.2 Geoestadística.

La geoestadística es demasiado compleja y su comprensión requiere de bases matemáticas muy específicas. En varios de los análisis de sistemas naturales se generan parámetros sin sentido físico y los resultados dependen en gran medida de las hipótesis de estacionalidad y normalidad de la variable estudiada. Una de las ventajas de representar la variación espacial con geoestadística es que las estimaciones se pueden hacer en cualquier punto del área de estudio (Burgess y Webster, 1980), pero para que esta técnica sea válida necesita una densa red de puntos de información sobre la propiedad en específico estudiada lo que se ve reflejado en el costo de los estudios de campo.

En un sentido amplio se define a la geoestadística como la aplicación del formalismo matemático de las funciones aleatorias al reconocimiento y estimación de fenómenos naturales (Matheron, 1965). En la geoestadística, como en cualquier método de inter-extrapolación, se busca siempre minimizar la varianza del error de estimación, es decir, la diferencia entre el valor estimado y el valor real. En la geotecnia se puede emplear la geoestadística para resolver en forma racional problemas tales como la estimación de espesores y profundidad de estratos y la variación espacial de propiedades geotécnicas en el medio (suelo) a partir de información medida en la zona, principalmente usando técnicas de estimación como el *Kriging*, que se enfoca básicamente en la obtención de estimadores lineales, sin sesgo y de mínima varianza, que toman en cuenta la estructura del medio.

El método geoestadístico y su aplicación en geotecnia han sido presentados anteriormente en forma detallada por varios autores (Auvinet, 1984, Auvinet, 1997, Juárez & Auvinet, 2000, Auvinet, 2002, Auvinet, 2009 entre otros). A continuación se describen, de manera general, algunos conceptos expuestos en este trabajo.

2.2.1 Campos aleatorios.

Sea $V(X)$ una *variable aleatoria* también conocida como *variable regionalizada* (por ejemplo, contenido de agua ó ángulo de fricción interna, o índice de calidad de roca), definida en el espacio X (“ X ”, “ Y ” y “ Z ”) del dominio estudiado R^P ($p = 1, 2, ó 3$). En cada punto del dominio, esta variable puede considerarse como aleatoria debido a que se desconoce su valor. El conjunto de estas variables aleatorias constituye un campo aleatorio. (Figura 2.4)

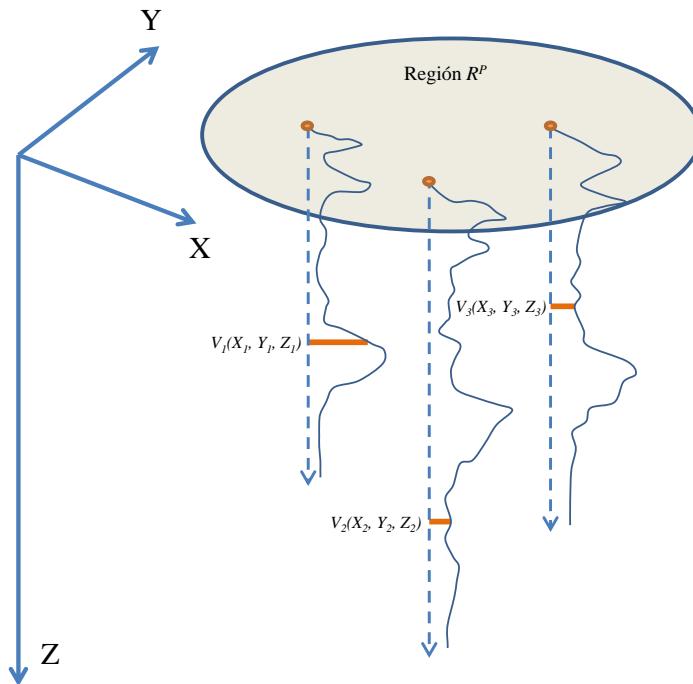


Figura 2.3 Representación de un campo aleatorio modificado de Medina (2001)

Para poder analizar el campo aleatorio se emplean principalmente los siguientes parámetros: esperanza, varianza, desviación estándar, coeficiente de variación y función de autocovarianza. La autocovarianza $C_V(X_1, X_2)$ representa el grado de dependencia lineal entre los valores de la variable aleatoria en dos puntos diferentes X_1 y X_2 . Esta dependencia se escribe bajo la forma de un coeficiente de autocorrelación (ecuación 2.2), el cual describe la correlación espacial existente entre los valores de V_1 y V_2 de la propiedad en estudio en puntos distintos X_1 y X_2 del medio.

$$\rho_V(X_1, X_2) = \frac{C_V(X_1, X_2)}{\sigma_{V_1} \sigma_{V_2}} \quad (2.2)$$

Una herramienta equivalente a la función de autocovarianza es el modelo estadístico de segundo orden del incremento $V(X) - V(X + h)$, mostrado en la (ecuación 2.3.)

$$2\gamma(h) = E\{[V(X) - V(X + h)]^2\} \quad (2.3)$$

Las funciones de correlación de las ecuaciones 2.2 y 2.3 no son propiedades intrínsecas de los dos puntos X_1 y X_2 , ya que dependen también de la población, es decir, del dominio en el que el campo se encuentra definido. Si la esperanza, la varianza y los demás parámetros son constantes en el medio, se dice que éste es estadísticamente homogéneo. Si la esperanza y la varianza del campo no son constantes, se dice entonces que presentan alguna *tendencia* o *deriva*.

2.2.2 Análisis estructural.

Las ecuaciones 2.2 y 2.3 son obtenidas estadísticamente a partir de resultados discretos (muestras aisladas) o continuos (sondeos) de las campañas de exploración. Estos últimos se evalúan haciendo uso de la siguiente aproximación (ecuación 2.4) considerando que el campo es estadísticamente homogéneo, estacionario y ergódico.

$$\mu_V \cong \mu^* = \frac{1}{L} \int_0^L V(X) dX \quad (2.4)$$

donde L es la longitud del sondeo.

En la misma forma se estima la autocovarianza a lo largo de la dirección u como:

$$C_V(\lambda u) \cong \frac{1}{L} \int_0^L V(X)V(X + hu) dX - \mu^{*2} \quad (2.5)$$

donde u es el vector unitario en la dirección en la que se evalúa la covarianza y h es un escalar.

Para el caso de un análisis tridimensional es importante determinar el grado de anisotropía de cualquier propiedad del suelo $V(X)$ dentro del medio. Para estimar la anisotropía se estima la función de autocovarianza en varias direcciones del vector u obteniéndose así los llamados *correlogramas direccionales*. A partir de estas funciones se estima la distancia de correlación, definida convencionalmente como:

$$\delta = 2a \quad (2.6)$$

donde a es el área bajo la curva representativa de la función ρ_V .

Con base en las distancias de correlación, se obtienen los modelos teóricos de las funciones de autocorrelación ajustándolos a la siguiente función exponencial (VanMarcke, 1983) donde la correlación decrece al incrementar la distancia de separación.

$$\rho = e^{-2h/\delta} \quad (2.7)$$

Si el valor de la distancia de correlación permanece constante en todas las direcciones estimadas, entonces se dice que el campo es isótropo; en cambio, si esta distancia es variable para las diferentes direcciones, se dice que es anisótropo. La anisotropía de un campo aleatorio puede representarse en forma geométrica a través de una elipse, llamada elipse de anisotropía.

2.2.3 Estimaciones paramétricas.

La técnica de Kriging, desarrollada por Matheron, (1965) con base en los trabajos de Daniel G. Krige (Krige, 1962), permite encontrar el mejor (en función de la mínima varianza) estimador lineal sin sesgo (en inglés: *Best Linear Unbiased Estimation, BLUE*), tomando en cuenta la correlación espacial supuesta.

La aplicabilidad del Kriging se determina con la aceptación de que la distribución espacial de cualquier propiedad geológica, hidrológica o geotécnica (*variable regionalizada*) es demasiado irregular para ser modelada usando una función matemática polinomial, y que además puede ser representada con mejores resultados con una superficie empíricamente determinada.

Según Goovaerts, 1997, el kriging y sus variantes (kriging simple y ordinario y co-kriging) son una variante de la regresión lineal básica. En el kriging simple se asume que existe una tendencia constante de los valores en todo el medio, para el kriging ordinario, se considera que la tendencia sólo existe en el vecindario cercano al punto medido mientras que para el co-kriging, que se basa en las consideraciones de ambos, puede incorporar información de una o más variables correlacionadas entre sí (covariables), entregando una tendencia no lineal de los valores del medio. Este último requiere de la información obtenida de modelos de covarianza entre dos variables diferentes.

Considérese una función $V(X): Rp \rightarrow R$ que representa una propiedad aleatoria del medio. Se suponen conocidos los valores de $V(X): V_1, V_2, \dots, V_n$ en n puntos X_1, X_2, \dots, X_n .

El problema consiste en estimar:

- a) El valor $V(X)$ en cualquier punto X (estimación puntual);
- b) O bien, el valor medio de V sobre un dominio de Rp (estimación global)

El estimador $V^*(X)$ de $V(X)$ en un punto X será un campo aleatorio, función de X y de la información disponible, es decir de los valores $V_i = V(X_i)$, $i = 1$ a n .

Kriging recurre a estimadores que sean combinaciones lineales de los datos:

$$V^*(X) = \sum_{i=1}^n \lambda_i V_i \quad (2.8)$$

donde los λ_i son reales.

El problema consiste en estimar los parámetros λ_i que den un estimador satisfactorio de $V(X)$. El Kriging usa al "mejor estimador sin sesgo"; es decir, a un estimador que tenga las dos propiedades siguientes:

1. Ausencia de sesgo: $E\{V(X) - V^*(X)\} = 0$
2. Mínimo valor de la varianza de estimación definida como:

$$\sigma_E^2(X) = \text{Var}[V(X) - V^*(X)] = E\{(V(X) - V^*(X))^2\} \quad (2.9)$$

Considerando la hipótesis de estacionaridad en el sentido amplio de un campo aleatorio, la función de autocovarianza puede expresarse en la forma:

$$C_V(X_1, X_2) = C_0 \rho_V(X_2 - X_1) \quad (2.10)$$

donde ρ_V es el coeficiente de autocorrelación, y C_0 es $\text{Var}[V(X)]$ en cualquier punto X .

Aceptando esta hipótesis y dividiendo la última ecuación entre C_0 , se obtiene:

$$\sum_{i=1}^n \lambda_i \rho_V(X - X_i) - \mu F(X_i) = \rho_V(X - X_i) \quad (2.11)$$

para $i = 1$ a n , con $\mu = v / C_0$

Con estas n ecuaciones adicionales se cuenta en total con $n+1$ ecuaciones que pueden escribirse en forma matricial:

$$[K][\lambda] = [\rho(X)] \quad (2.12)$$

En este caso, la varianza de estimación tiene la expresión:

$$\sigma_E^2(X) = \text{Var}[V(X)] + \mu F(X_i) - \sum_{i=1}^n \lambda_i C_V(X, X_i) \quad (2.13)$$

Se tiene que resolver este sistema lineal de orden $n+1$, donde $[\lambda]$ es el vector de las incógnitas. Si se acepta la estacionaridad, la condición de ingreso se escribe:

$$\sum_{i=1}^n \lambda_i = 1 \quad (2.14)$$

El método geoestadístico tiene la posibilidad de dar mejores resultados en medios estructurados homogéneos como los lacustres, o terraplenes de suelo compactado, no así en medios caóticos como los conglomerados, brechas y depósitos coluviales.

Algunas características importantes de la geoestadística relacionadas con este trabajo son las siguientes:

- La geoestadística es conceptualmente compleja y su correcto uso requiere de bases matemáticas sólidas.
- En muchos de los análisis de sistemas naturales se obtienen parámetros sin sentido físico y los resultados dependen en gran medida de las hipótesis de estacionalidad y normalidad de la variable estudiada.
- El método es altamente sensible al error adherido a los datos de entrada (ruido).
- Se requiere de un muestreo denso para lograr la confiabilidad en los resultados.

La correcta estimación de propiedades geotécnicas del relieve en estudio, pero el alto costo de la exploración y muestreo presenta un área de oportunidad para el desarrollo de herramientas de interpolación numérica capaces de estimar inteligentemente la variación espacial de dichas propiedades con la información de un muestreo moderado. En esta tesis se hace uso de las Redes Neuronales para estimar la variación espacial de las geo-propiedades.

CAPÍTULO III REDES NEURONALES: ASPECTOS BÁSICOS

En 1943 fue propuesto el primer modelo computacional de “actividad nerviosa” por McCulloch y Pitts (1943), que después sirvió de ejemplo para los modelos posteriores de Jhon Von Neumann, Marvin Minsky (Minsky y Papert, 1969), Frank Rosenblatt (Rosenblatt, 1962) y muchos otros. En 1969, una seria crítica por parte de Minsky a los modelos neuronales de aquel entonces cuya naturaleza era lineal, provocó una caída en las investigaciones y una época fatídica para las redes neuronales.

No fue sino hasta los años 80s en los que Rumelhart, y McClellant construyeron la primer Red Neuronal RN bajo el concepto de Procesamiento Distribuido en Paralelo PDP, cuya naturaleza era no-lineal (Rumelhart y McClelland, 1986). A partir de entonces, las RN se usan con mayor interés en tareas de predicción y clasificación en un gran número de campos de la ciencia. Las RNs son técnicas de modelado flexible que se fundamentan en la eficiencia de los procesos nerviosos biológicos (Bishop, 1996; Haykin, 1999). Las RNs son capaces de descubrir relaciones lineales y no lineales entre datos numéricos con fines de análisis y predicción de comportamientos complejos (García, 2009).

Las RNs son usadas cuando es difícil encontrar las reglas que definen la variable a modelar a través de parámetros independientes, y donde además los datos son imprecisos y escasos (en número y en distribución). Un módulo neuronal posee una topología que satisface la estructuración de datos, y un criterio de supervisión y uno de culminación aceptable.

Adaptación: las RNs no requieren de ninguna forma en específica sobre la estructura o reparto de los datos, ya que adquieren el conocimiento a través del entrenamiento y se almacena como pesos de las conexiones neurales.

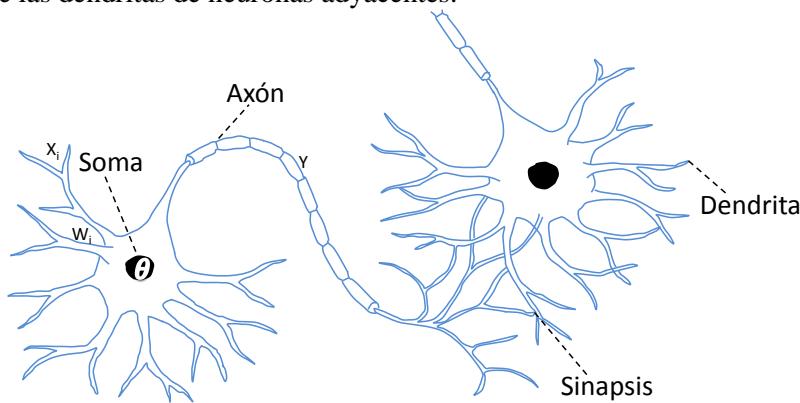
Autorganizacion: esta es una de sus más importantes ventajas ya que la aprende (y si es necesario cambia) para crear su propia representación de la información.

Flexibilidad y tolerancia a datos imperfectos: Los problemas relacionados con la falta de datos o “faltas” en los datos o problemas con los mismos ya que toda la información generada se distribuye a través de las conexiones y se explota la redundancia en el almacenamiento de la información para fortalecer el esquema ante imprecisiones y/o perturbaciones.

3.1 Descripción de una neurona artificial (RNs)

La neurona es una célula especial y es el principal constituyente del cerebro. Una neurona es una célula viva y por ende contiene todos los elementos que caracterizan a las células biológicas. Las neuronas poseen características propias que le permiten comunicarse entre ellas y esto las diferencia del resto de las células biológicas. La neurona está compuesta por las dendritas, el soma, el axón y la sinapsis, (Figura 3.1). Las dendritas son extensiones extremadamente delgadas del soma que actúan como canales que transmiten la información que proviene de otras neuronas. El soma

procesa esta información y la envía a otras neuronas a través del axón y la sinapsis que son los espacios entre las dendritas de neuronas adyacentes.



X_i = Entradas, que representan las señales que provienen de otras neuronas

W_i = Pesos, intensidad de la sinapsis que conecta dos neuronas

θ = Función umbral que la neurona debe superar para activarse

Y = Salida de la neurona

Figura 3.1. Neurona biológica

La arquitectura de la red determina cómo los elementos de procesamiento están conectados. La elección de los elementos de procesamiento combina la función de transferencia y la función en los elementos de procesamiento. En un sistema neuronal artificial se establece una estructura organizada en capas, cuya unidad básica es la neurona. Las capas constituyen a la red (Figura 3.2) y las interconexiones entre las neuronas se llaman “pesos” (coeficientes numéricos en el funcional neuronal). La modificación iterativa de los pesos permite la adaptabilidad y representa la capacidad de predicción de las RNs.

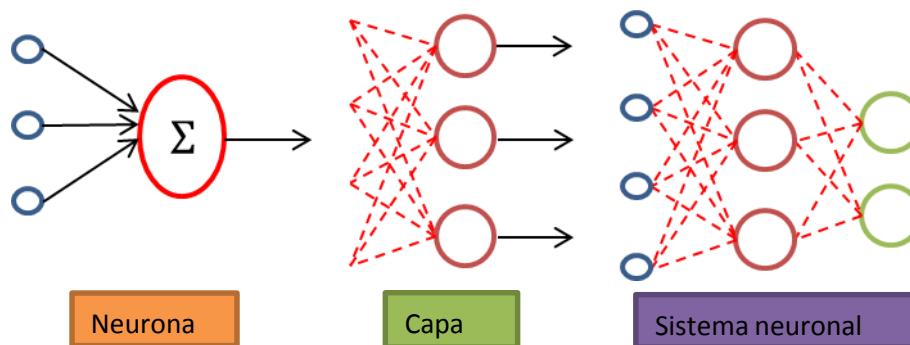


Figura 3.2 Estructura jerárquica de un sistema basado en RNs

Se define procesador elemental, neurona o perceptrón a un dispositivo simple de cálculo que, a partir de un vector de entrada procedente del exterior o de otras neuronas, proporciona una única respuesta o salida. Los elementos que constituyen la neurona de etiqueta i son los siguientes (Figura 3.3):

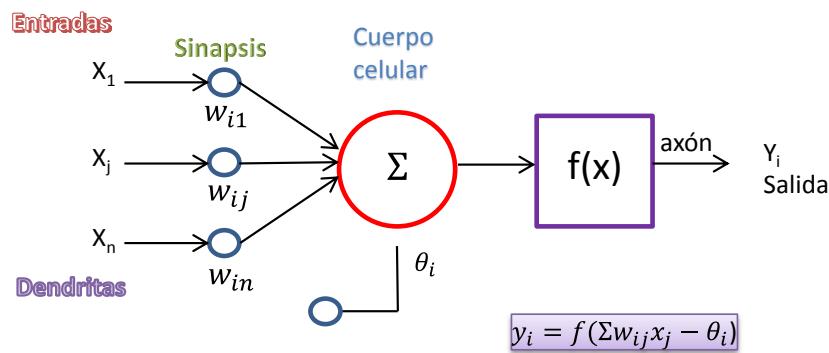


Figura 3.3 Modelo común de neurona

Considerando que la regla de propagación es la suma ponderada y que la función de salida es la identidad, la neurona estándar consiste de:

Un **conjunto de entradas** $X_j(t)$, que pueden ser binarias (digitales) o continuas (analógicas), dependiendo de la aplicación.

Unos **pesos sinápticos** W_{ij} asociados a las entradas y quienes definen en este caso la intensidad entre la neurona presináptica j y la postsináptica i . Mediante el ajuste de los pesos sinápticos la red es capaz de adaptarse a cualquier entorno y realizar una determinada tarea.

Una **regla de propagación** $n_i(t) = \sigma(w_{ij}, x_j(t))$, que permite obtener a partir de las entradas y los pesos el valor del potencial postsináptico n_i de la neurona

$$n_i(t) = \sigma(w_{ij}, x_j(t)) \quad (3.1)$$

Una **función de activación** $Y_i(t) = f_i(n_i(t))$ que representa simultáneamente la salida de la neurona y su estado de activación. Se encarga de atribuir las características no lineales al procesamiento en los nodos. La función actúa sobre el valor arrojado por la función de entrada limitando su crecimiento numérico. Existen diferentes tipos de funciones de activación, y la Tabla 3.1 muestra para cada una de estas funciones sus características principales y su representación gráfica

Una **función de salida** que proporciona la salida actual $y_k(t)$ de la neurona k en función de su estado de activación actual $a_i(t)$. Muy frecuentemente la función de salida es simplemente la identidad $F(x) = x$, de modo que el estado de activación de la neurona se considera como la propia salida, es decir:

$$y_i(t) = F_i(a_i(t)) = a_i(t) \quad (3.2)$$

De manera general, la operación de la neurona i puede expresarse de la siguiente forma

$$y_i(t) = F_i\left(f_i\left(a_i(t-1), \sigma_i(w_{ij}, x_j(t))\right)\right) \quad (3.3)$$

Al conjunto de pesos de la neurona se añade un parámetro adicional θ_i que denominaremos umbral (mínima señal registrada por un sistema), y se resta del potencial postsináptico por lo que el argumento de la función de activación se expresa

$$\sum_j w_{ij}x_j - \theta_i \quad (3.4)$$

ahora bien, si los índices i y j comienzan en 0, y definiendo $w_{i0} = \theta_i$ y $x_0 = -1$ (constante), se puede obtener el comportamiento de la neurona a través de:

$$y_i(t) = f_i \left(\sum_{j=0}^n w_{ij} x_j \right) \quad (3.5)$$

Definida la neurona estándar basta con establecer la forma de la función de activación para determinarla por completo. Una función de transferencia se escoge para satisfacer alguna característica del problema que la neurona está intentando resolver. Hay una gran variedad de funciones de transferencia, en la Tabla 3.1 se muestra para cada una de las funciones existentes su gráfico representativo.

Tabla 3.1. Funciones de activación más frecuentes

	<i>Función</i>	<i>Intervalo</i>	<i>Grafica</i>
<i>Identidad</i>	$y = x$	$[-\infty, +\infty]$	
<i>Escalón</i>	$y = sign(x)$	$[-1, +1]$	
	$y = H(x)$	$[0, +1]$	
<i>Lineal por tramos</i>	$y = \begin{cases} -1, & \text{si } x < -l \\ x, & \text{si } -l \leq x \leq l \\ +1, & \text{si } x > l \end{cases}$	$[-1, +1]$	
<i>Sigmoide</i>	$y = \frac{1}{1 + e^{-x}}$	$[0, +1]$	
	$y = tgh(x)$	$[-1, +1]$	
<i>Gaussiana</i>	$y = Ae^{-Bx^2}$	$[0, +1]$	
<i>Senoidal</i>	$y = A \operatorname{sen}(wx + \varphi)$	$[-1, +1]$	

3.2 Perceptrón multicapa

En general las neuronas se suelen agrupar en unidades estructurales denominadas capas. Dentro de una misma capa las neuronas suelen ser del mismo tipo y el conjunto de capas constituye una red neuronal. Se distinguen tres tipos de capas (Figura 3.4):

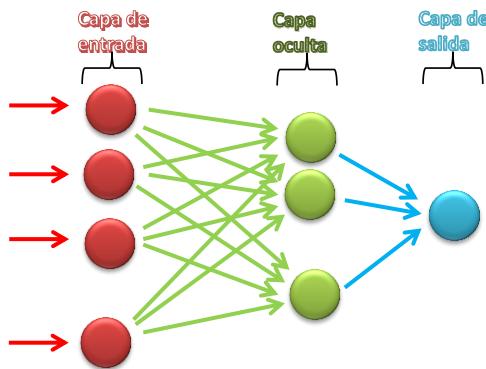


Figura 3.4 Capas representativas de una Red Neuronal

A continuación se mencionan estas capas:

- i) **Capa de entrada:** esta se encarga de recibir las señales que intervienen en el comportamiento en estudio
- ii) **Capa oculta:** es aquí donde se efectúan los procesos fundamentales de la red neuronal
- iii) **Capa de salida:** recibe la información de la capa oculta y transmite la respuesta al medio externo; esta capa contiene los parámetros objetivos.

En una RNs se crean conexiones en las que intervienen las neuronas asociadas con un peso sináptico y direccionales. Cuando la conexión se establece entre dos neuronas de una misma capa se habla de conexiones laterales o conexiones intra-capas. Por el contrario si la conexión se establece entre neuronas de distintas capas se le denomina conexión inter-capa. Si la conexión se produce en el sentido inverso al de entrada-salida la conexión se llama recurrente o retroalimentada.

Descripción de las RNs dependiendo del número de capas que la componen:

1- Red neuronal monocapa: Esta es la RN más simple ya que las neuronas de esta red funcionan como nodos de entrada y salida simultáneamente y no existen capas ocultas. Además de que se utilizan en tareas relacionadas con la autoasociación (generar información – conclusiones- acerca de patrones que se presentan a la red de manera incompleta o distorsionada).

2- Red neuronal multicapa: Aquí existe un conjunto de capas intermedias (capas ocultas) entre la capa de entrada y la de salida. Y dependiendo del tipo de conexión que se genera en las capas se pueden diferenciar. Una de las características de las capas es el hecho de que están ordenadas por la percepción de la señal desde la entrada hasta la salida.

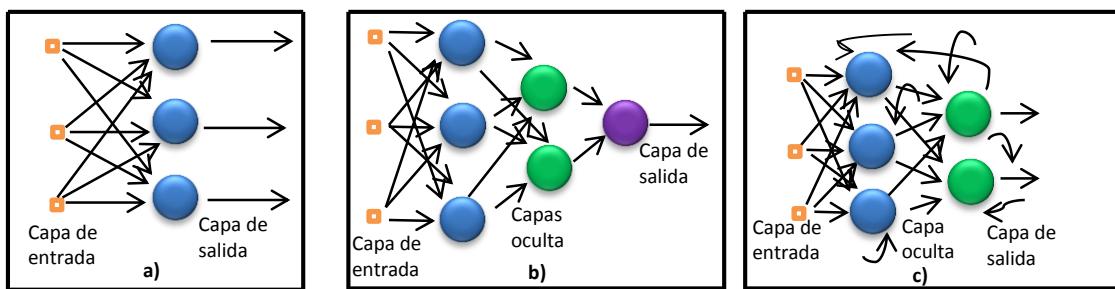


Figura 3.5. Tipos de redes neuronales. **a)** Red neuronal monocapa **b)** Red neuronal multicapa de propagación hacia adelante (feedforward) o perceptrón. **c)** Red neuronal multicapa recurrente (feedback).

Dentro de las conexiones más estudiadas y utilizadas en aplicaciones prácticas se encuentran las de multicapa de Propagación normal hacia adelante (*Multilayer Normal Feed Forward*). Cada capa recibe un vector de entrada que puede ser un vector de entrada externo o un vector de salida de una capa anterior. Las capas son ubicadas en orden; es decir, la entrada para la primera capa es la entrada externa, la entrada de la segunda capa si existe es la salida de la primera capa y así sucesivamente. Y hay algunas redes en el que las capas se encuentran unidas desde la salida hasta la entrada en forma inversa ala que viaja la señal de información, estas conexiones se les denominan de retroalimentación o feedback donde una neurona puede estar conectada a las neuronas de otra capa y a ella misma.

3.2.1 Regla de entrenamiento- aprendizaje

Esta etapa es importante ya que aquí se determina el conjunto de pesos sinápticos que permita a la red realizar una actividad en específico. La red debe de ser entrenada para que sea operativa. Otra arreglo que se tiene que hacer antes del entrenamiento es definir el carácter de ajuste a una actividad específica (cuando se dice que la RN ha aprendido).

Entre los criterios más comunes se encuentran:

- Se ha alcanzado una cota de error que se considere suficientemente pequeña
- Se ha llegado a un número máximo de iteraciones
- Se ha llegado a un punto de saturación en el que, por más que se entrene, ya no es posible reducir el error

La fase de entrenamiento consiste en hacer que la red sea capaz de extraer, a partir de ejemplos, normas generales que le permitan en el futuro responder adecuadamente a patrones nunca antes vistos. Durante esta fase es imprescindible establecer una condición de paro óptima que minimice el error y evite un sobre-ajuste, es decir, que la red es incapaz de generalizar para casos nuevos.

Básicamente existen dos tipos de aprendizaje: el supervisado y no supervisado. La diferencia fundamental entre ambos estriba en la existencia o no de un agente externo (supervisor) que controle el aprendizaje de la red.

a) Aprendizaje supervisado.

Se efectúa mediante un entrenamiento controlado bajo un agente externo (supervisor) que determina la respuesta que debería generar la red a partir de una entrada establecida. El supervisor controla la salida de la red y si la salida no coincide con la deseada entonces se procede a modificar los pesos de las conexiones, para lograr que la salida obtenida se aproxime a la deseada.

b) Aprendizaje no supervisado. (o auto-supervisado)

Este aprendizaje no requiere influencia externa (o sea un supervisor). Para que se ajusten los pesos de las conexiones entre neuronas. La red no recibe ninguna información del exterior para que se le indique si la salida procesada en respuesta a una determinada entrada es correcta o incorrecta. A estas redes se les proporcionan únicamente los estímulos y ellas ajustan sus interconexiones basándose en sus propias salidas.

c) Prueba

Una vez obtenidos estos pesos la red está lista para ser probada con patrones ajenos al entrenamiento. El objetivo de esta comprobación es observar el comportamiento de la red cuando las entradas son distintas a las que usaron en el entrenamiento. Al entrenar una red neuronal e intentar minimizar el error se corre el riesgo de sobrespecialización (comportamiento óptimo con los ejemplos de entrenamiento, con casos distintos errores considerables). La minimización del error debe hacerse de manera equilibrada y muy cuidadosa de tal forma que no origine una pérdida de generalización. Una vez que ésta resulte operativa, la arquitectura, neuronas, conexiones y pesos quedan fijos y la red está lista para funcionar. El conjunto de prueba debe ser i) significativo (debe contener ejemplos pertenecientes a todas las clases establecidas) y ii) representativo (debe guardar la relación existente entre los ejemplos del conjunto de entrenamiento).

CAPÍTULO IV APROXIMADOR NEURONAL DE GEO-PROPIEDADES

Este capítulo se enfoca en enunciar las etapas del desarrollo del modelo neuronal para analizar e interpretar base de datos de información geotécnica referenciadas (X, Y, Z) y se hace hincapié en los criterios de interpretación de resultados. Se presenta un método para decidir sobre posibles comportamientos geomecánicos y caracterización del ambiente 3D (volumen: laderas).

4.1 Descripción del campo de estudio

El proyecto Hidroeléctrico que se estudia en esta investigación está ubicado en el estado de Chiapas de la República Mexicana sobre el río Grijalva. Para su realización el personal técnico de la Comisión Federal de Electricidad (Comisión Federal de Electricidad, 1979), se realizaron estudios geológicos regionales cubriendo una extensión de 15,000 km² estos estudios junto con los sondeos de exploración (40,000 m) y socavones (4,000 m) permitieron establecer su factibilidad. La región cercana a Chicoasén se caracteriza por tener una topografía que se desarrolla sobre un terreno plegado y posteriormente afectado por fallas, las cuales han tenido movimientos verticales diferentes en las que afloran rocas sedimentarias principalmente clásticas, medianamente consolidadas. La dirección que tiene la sierra es de WNW-ESE, y las fallas siguen esta misma dirección. El rasgo fisiográfico más destacado de la región la constituye el cañón del sumidero del río Grijalva, cortado en calizas cretácicas y que tiene una profundidad de 1,200 m.

Los datos topográficos permiten diferenciar dos tipos de relieve, que son:

- (a) un relieve antiguo, representado por superficies de erosión desarrolladas durante el cenozoico tardío, levantada en forma de bloques tectónicos a distintas altitudes, que oscilan entre 1,000 y 1,700 m o más
- (b) relieve más joven representado por profundos cañones con grandes escarpes, de edad cuaternaria, desarrollados durante etapas de levantamiento rápido de la superficie de erosión, las cuales aún no se presentan disectadas por los procesos exogenéticos.

Las rocas que se encuentran en esta área varían en edad del cretácico al reciente. En esta región las rocas sedimentarias son las más abundantes, con un espesor aproximado de 5,000 m. El cretácico inferior está representado por unos 2,400 m de carbonatos de plataforma (caliza Sierra Madre) los cuales pasan transicionalmente a la parte basal del cretácico superior. La parte restante del cretácico superior cubre discordantemente el cretácico inferior y se presenta, tanto como facies carbonatada (“caliza angostura”), o como clástica (grupo Ocozocuautla), alcanzando un espesor mínimo de unos 7,00 m.

La región presenta pliegues ya que se localizaron tres anticlinales, separados por dos sinclinales, estas estructuras constituyen pliegues abiertos, que están alineados en dirección WNW-ESE. Las estructuras plegadas están truncadas sublongitudinales por fallas, y estas mismas fallas dividieron la región en bloques de altura variable, modificando los anticlinales en pilares tectónicos y los sinclinales en fosas tectónicas, produciendo además, combamientos y flexiones en los pliegues ya existentes. Además de que el cañón de Chicoasén se formó por erosión fluvial del río Grijalva sobre el flanco nororiental del anticlinal de Chicoasén, en rocas carbonatadas de la “caliza Angostura”, y para fines prácticos, se dividió al intervalo de la “caliza Angostura” que yace en el sitio, en tres unidades litológicas:

UNIDAD I: constituye la parte superior de la secuencia y está formada por calizas interestratificadas con capas de arcilla y lutita, de espesores variables de 90 a 140 m.

UNIDAD II: subyace concordantemente a la unidad I y consiste de caliza masiva, de color blanco y de textura arenosa, en bancos de más de 30 m de espesor y con un total de 120 m.

UNIDAD III: esta subyace a la unidad II, existiendo entre estas contacto erosional, aflora en la parte central del cañón, donde constituye la parte más baja de la secuencia estratigráfica que aflora, consiste de calizas gris oscura, que están interestratificadas con arcilla carbonosa, esta unidad tiene un espesor de 70 m.

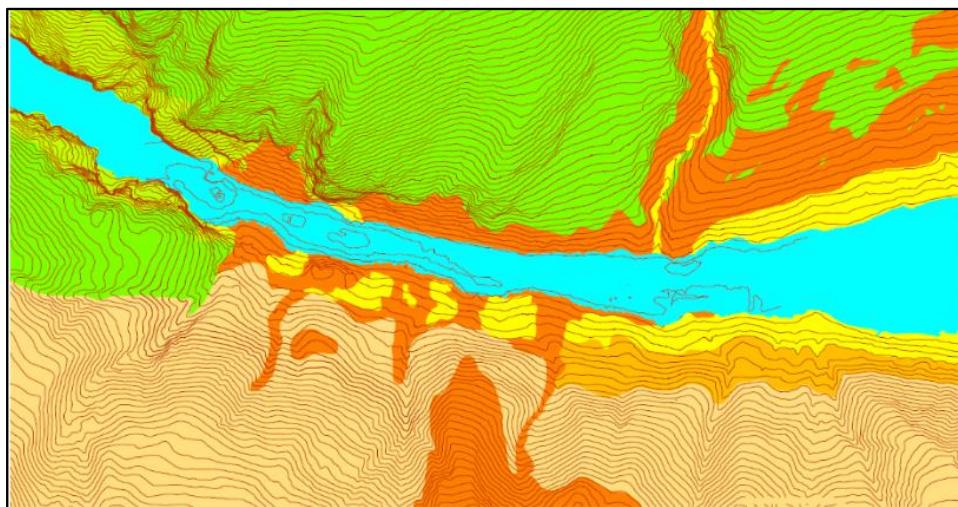
También se ha registrado tres direcciones de fallamiento, denominadas alfa, beta, gamma, con dirección N 700 E, NW-SE y N-S, respectivamente, las fallas principales tienen saltos de 3 a 50 m, y forman bloques de 100 a 200 m de ancho.

ALFA- estas fallas y fracturas tienen un rumbo general de NE-SW e inclinación hacia el sureste, variable de 70° a la vertical. Son alabeadas, tanto en el sentido horizontal como vertical, y son las más abundantes e importantes en el área, tienen desplazamientos verticales de 3 a 50 m en las diferentes unidades litológicas, originando bloques de 100 a 200 m de ancho, inclinados hacia el norte y afectan severamente a la unidad I.

BETA- las fallas y fracturas beta forman una intersección X con las fallas alfa, son menos frecuentes y presentan los mismos efectos sobre las unidades litológicas que las de la familia alfa

GAMMA- las fallas y fracturas de esta familia ocupan el segundo lugar en importancia y constituyen una debilidad paralela a gran parte del cañón, a través de estas fallas se llevó la decompresión de las laderas, al formarse el cañón de Chicoasen mediante la erosión, su efecto sobre las unidades litológicas es similar al de las fallas y fracturas alfa y también presentan frecuentemente relijes de movimiento horizontal.

En sus planos se observan estrías, tanto verticales como horizontales. Las fracturas y fallas alfa son las más abundantes, mientras que las gamma, las más grande en longitud y salto, todas las fallas principales y los bloques que delimitan, deben su origen a la influencia de la falla de Chicoasen – Malpaso de alcance regional (a manera de esquema general en Figura 4.1).



ERA	PERÍODO	EPOCA	NOMENCLATURA	LITOLOGÍA
CENOZOICO	TERCIARIO	CUATERNARIO	Qal	Depósitos aluviales Gravas, arenas y límos
			Qdt'	Qdt
MESOZOICO	CRETÁCICO	PALEOCENO	Tps	Formación Soyaló Lutitas con intercalaciones de areniscas, areniscas conglomeráticas, margas, calcarenitas y calcilitas.
			Ksa-U2	Formación Angostura (Unidad 2) Brechas calcáreas intraformacionales masivas y calizas biogénicas de grano fino con pedernal
		SUPERIOR	Ksa-U1	Formación Angostura (Unidad 1) Calizas de textura fina de color gris pardo, con macrofósiles y estratificación de 0.30 a 2.00 m

Figura 4.1. Zona de estudio y nomenclatura

A parte de los levantamientos geológicos, se efectuaron estudios geofísicos consistentes en sismología de refracción y resistividad eléctrica con punto de disposición Wenner, y en resistividad de alta densidad, estos estudios contribuyeron a definir el modelo geológico, lográndose delinear un sinclinal en la margen izquierda. Se desprendió que la margen izquierda parecía inestable, se investigó esto mediante 120 sondeos y nueve socavones, y se hicieron estudios de mecánica de rocas en el campo, de los cuales se concluyó que en la entrada del cañón efectivamente existía una zona inestable formada por la unidad I, que tenía un volumen de $9 \times 106 \text{ m}^3$ la cual al llenarse el vaso sería inestable y se deslizaría dentro del vaso.

4.1.1 Campaña de exploración

Se efectuaron barrenos en ambos márgenes de la presa, Margen Derecho 22 barrenos y en el Margen Izquierdo 20 barrenos, situados tal como se muestra en la Figura 4.2. El estudio se concentra en un área de 620m por 800m, zona de preocupación de los constructores. En la Figura 4.2 se indica la situación de los sondeos, registros procesados para el desarrollo del modelo neuronal.

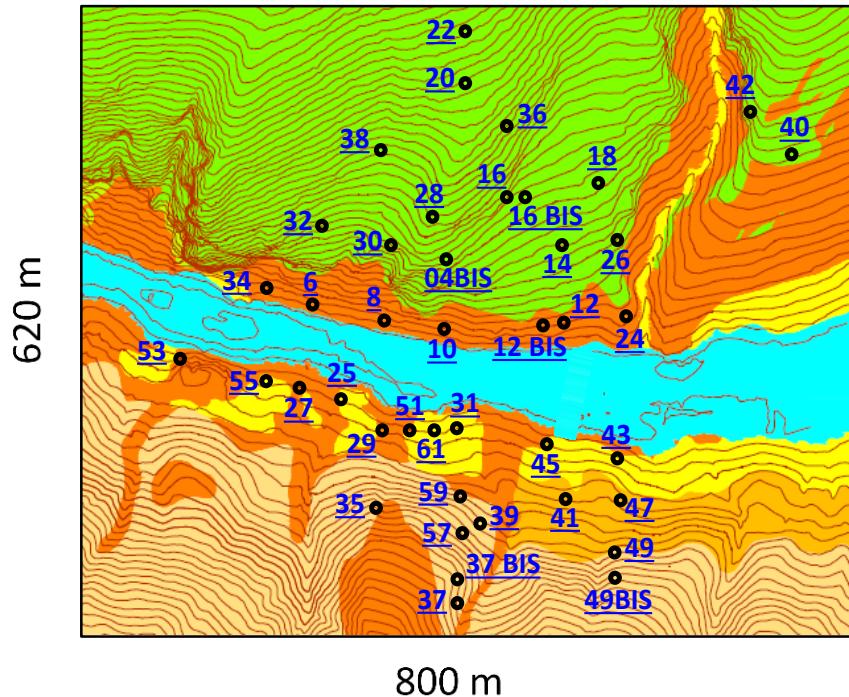


Figura 4.2 Zona de estudio con identificación de los barrenos efectuados

De la información contenida en la base de datos mostrada, las siguientes propiedades son las de mayor presencia (en número y en calidad):

Índice de calidad de la Roca *RQD* → 2799 *mediciones en los 42 barrenos*

Porcentaje de recuperación *REC %* → 936 *mediciones en los 42 barrenos*

Fracturas *FRAC* → 544 *mediciones en los 42 barrenos*

En las Tablas 4.1 y 4.2 se presenta un ejemplo de los registros de las 3 propiedades geotécnicas adheridas a las variables de posición en planta XY y profundidad Z que fueron usadas en esta investigación. Esta versión se hace masiva al tomar en cuenta todos los barrenos y todas las profundidades.

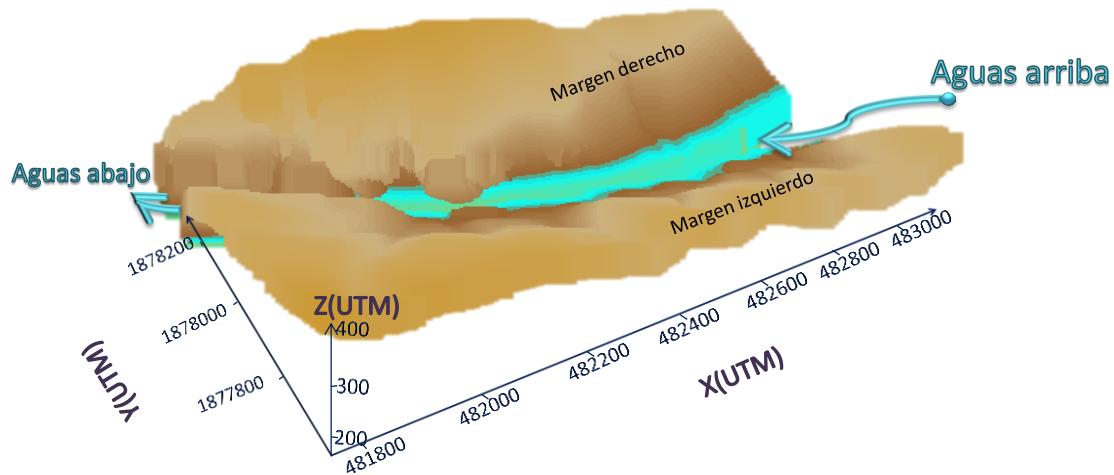


Figura 4.4 Volumen en estudio: ambiente sin transparencia

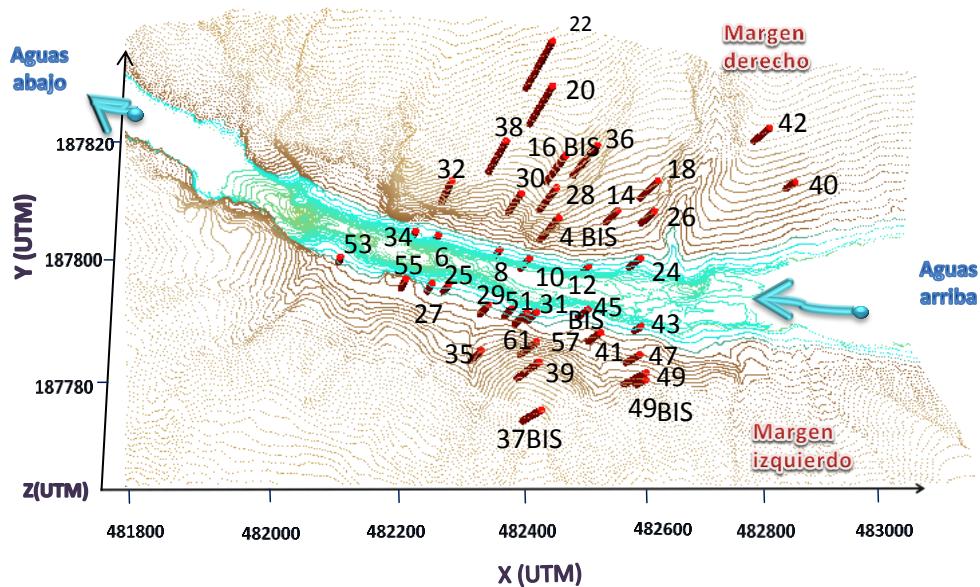


Figura 4.5 Volumen en estudio: barrenos en profundidad, transparencia

- Fracturas (FRAC); es la separación bajo presión en dos o más piezas de un cuerpo sólido o como a la superficie tectónica de un terreno (Figuras 4.10 y 4.11)
- Porcentaje de Recuperación (%REC); es el porcentaje de testigo recuperado mediante un núcleo de perforación (Figuras 4.12 y 4.13)

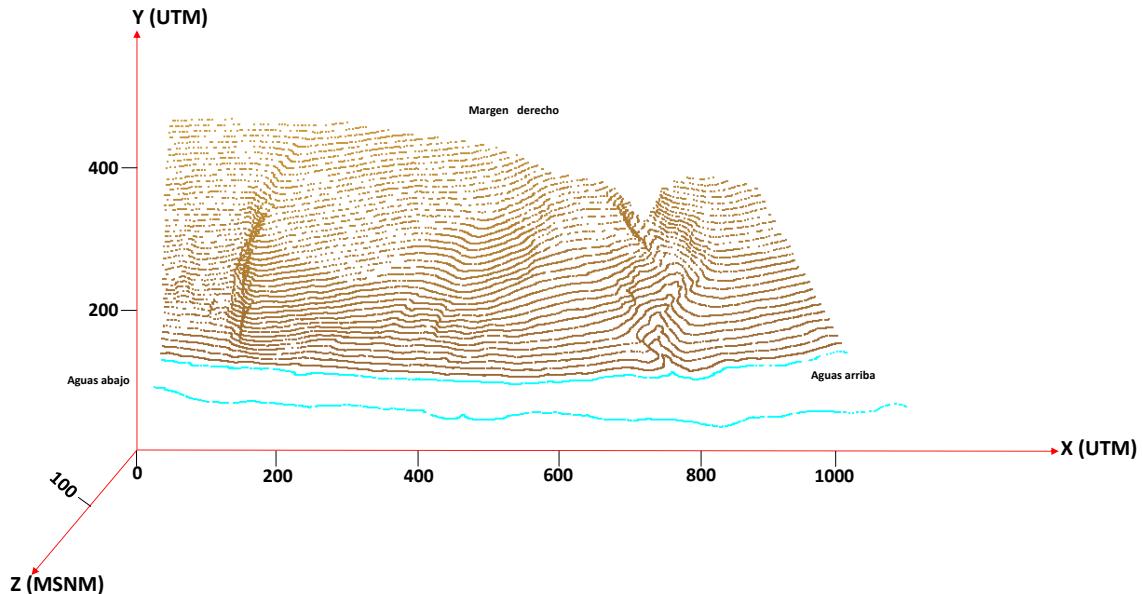


Figura 4.6 Rangos dinámicos margen derecho

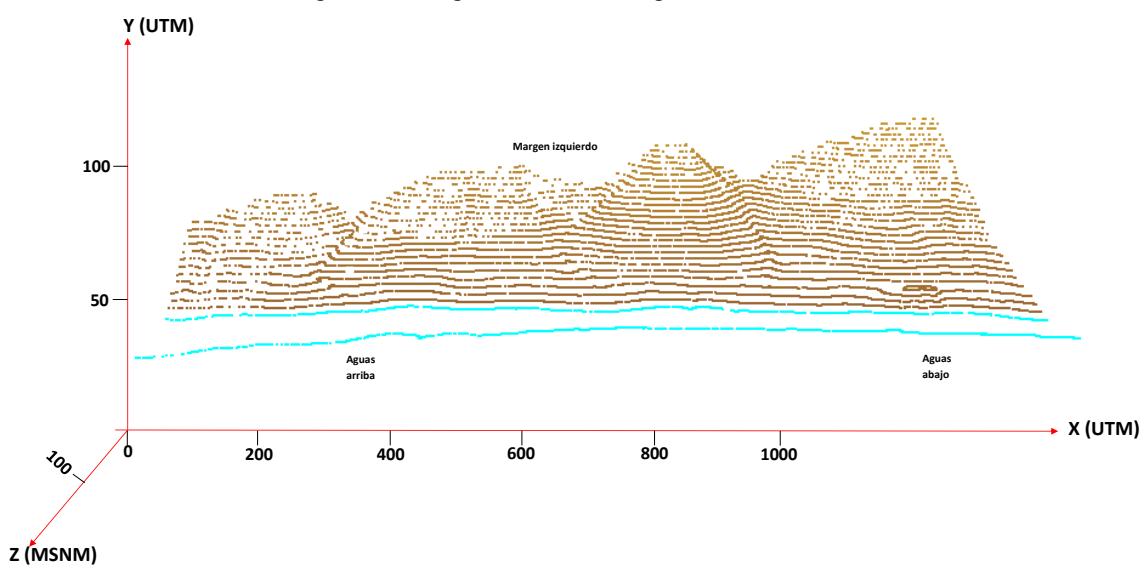


Figura 4.7 Rangos dinámicos margen izquierdo

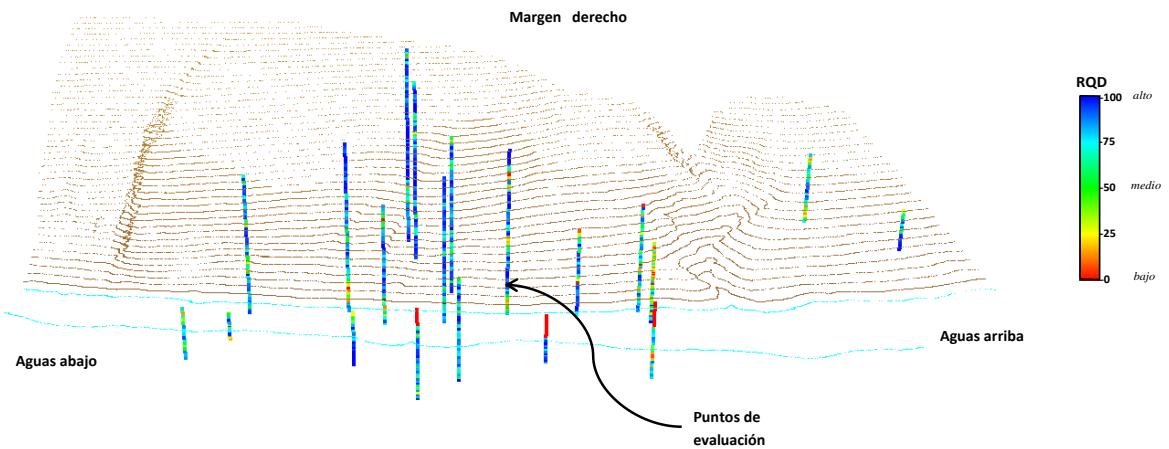


Figura 4.8 Ubicación de los puntos de evaluación de RQD margen derecho

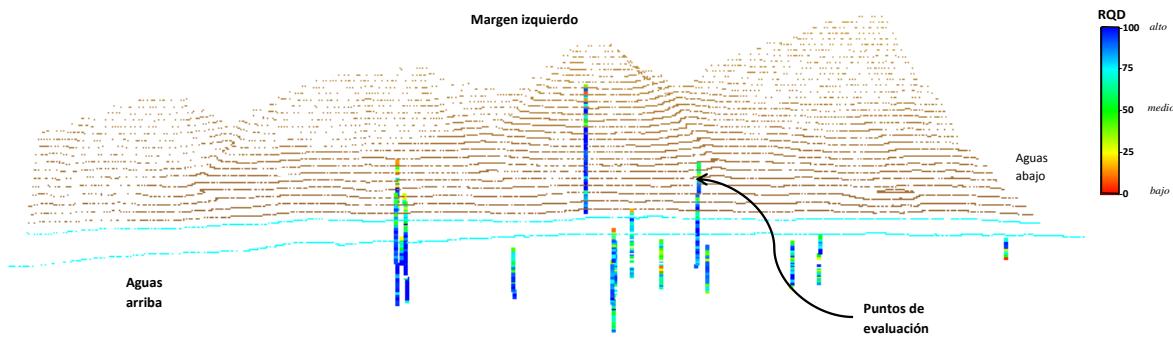


Figura 4.9 Ubicación de los puntos de evaluación de RQD margen izquierdo

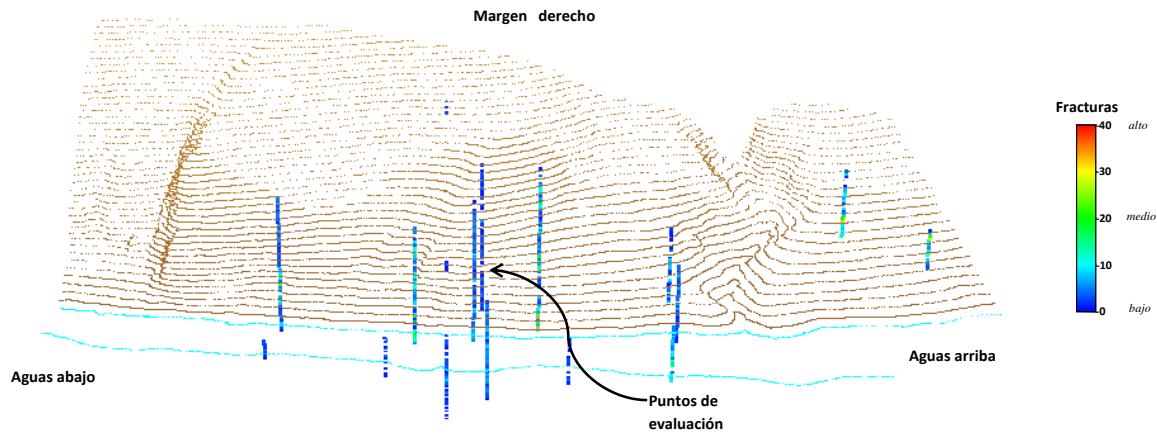


Figura 4.10 Ubicación de los puntos de evaluación de FRAC margen derecho

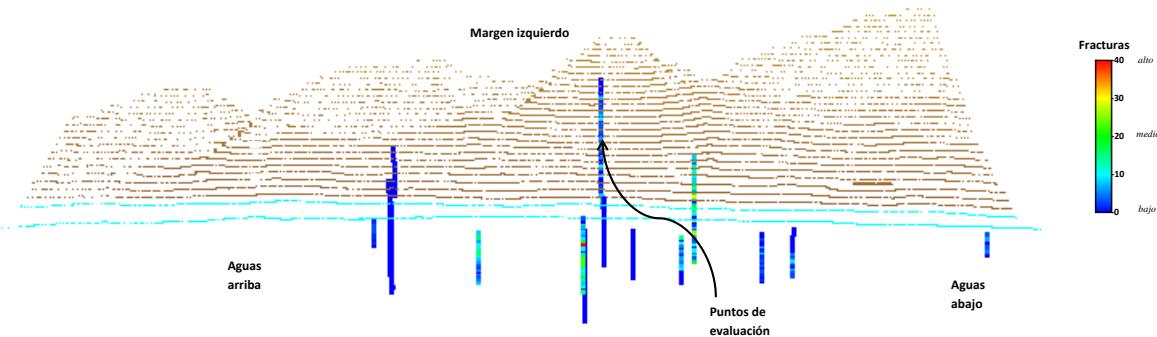


Figura 4.11 Ubicación de los puntos de evaluación de FRAC margen izquierdo

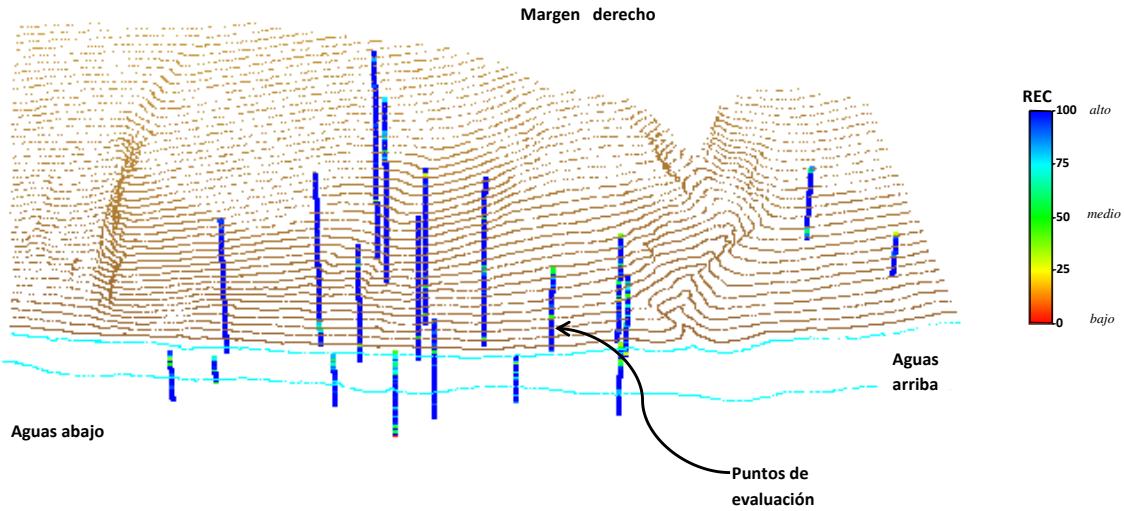


Figura 4.12 Ubicación de los puntos de evaluación de %REC margen derecho

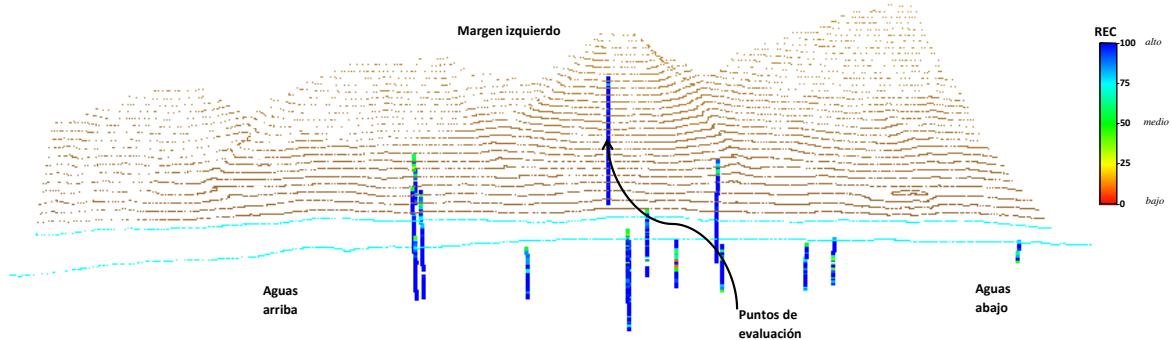


Figura 4.13 Ubicación de los puntos de evaluación de %REC margen izquierdo

4.3 Presentación del aproximador neuronal : generalidades

En el área de estudio se efectuaron 42 barrenos de los que se compilaron 2799 patrones. De este total 1514 fueron seleccionados para construir el modelo neuronal y los restantes 33 se usarán para probar la capacidad de generalización de las redes. A continuación se describen las particularidades topológicas comunes en los modelos que conforman esta investigación.

Arquitectura. Redes tipo Multicapa de Prealimentación (Multilayer Normal Feed Forward). Cada capa es provista con entradas externas en un ordenamiento secuencial: la primera recibe un vector de entrada que es el encadenamiento del vector de entrada y la salida de la primera capa, la segunda capa recibe entradas desde el vector de entrada, y los vectores de salida de ambas capas anteriores. El entrenamiento de la red se detiene cuando se ha llegado a un error mínimo (establecido por el modelador) deseable.

Tipo de error. Para la función de error empleado se utilizó el error cuadrado promedio (ecuación 4.1) el cual mide la distancia entre el vector de salida deseado y el error de salida actual, así el algoritmo de aprendizaje ajusta los pesos en la red para disminuir el error en el conjunto de entrenamiento.

$$E = \sqrt{\frac{\sum(D_{ij} - Y_{ij})^2}{M}} \quad (4.1)$$

dónde:

E : es el error cuadrado promedio

D_{ij} : es la salida deseada para el ejemplo de entrenamiento

Y_{ij} : es la salida de la red actual para el ejemplo

M : es el número de veces de salida el número de ejemplos.

Capa de entrada. Esta capa recibe directamente la información proveniente de las fuentes externas de la red, son internas a la red y no tiene contacto directo con el exterior. Las entradas neuronales de los modelos utilizados son las coordenadas(X, Y, Z) y la variable adherida o geo-parámetros que fueron justificados en la sección anterior.

Capa oculta. En la elección del número de capas ocultas está en función de lo complejo del problema afrontado, el cual le es presentado a la red. En la Figura 4.14 se muestra un ejemplo de las estructuras. La RN desplegada se escribe $3 \times 100 \times 100 \times 1$ y se lee: red de 3 entradas con dos capas ocultas de 100 nodos cada una y una salida (un geo-parámetro).

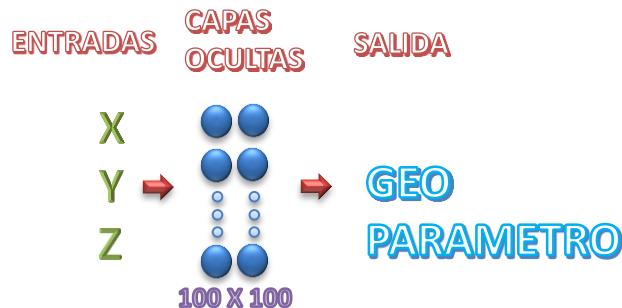


Figura 4.14 Topología Neuronal final

Regla de aprendizaje. En las RNs se optó por el método de aprendizaje algoritmo Quick Propagation (QP) (Fahlman, 1988), con el cual se minimiza el tiempo requerido para encontrar el conjunto de pesos que consiguen las menores diferencias entre los resultados calculados por la red y los objetivos del diseño. Además que, esta técnica automáticamente regula la matriz de pesos, y detecta condiciones que aceleran el aprendizaje. La función de activación en esta capa es producto punto (Dot product), cuya función nodal tiene la función de sumar las entradas más un valor de sesgo para saber qué tan alineados están los vectores entre sí. La función de transferencia fue la *sigmoidal*: función que toma los valores de entrada y restringe las salidas entre cero y uno, de acuerdo con la ecuación 4.2 (Figura 4.15). Por su cualidad diferenciable, esta función es comúnmente usada en redes multicapa con propagación de error hacia atrás.

$$Y = \frac{1}{1 + e^{-x}} \quad (4.2)$$

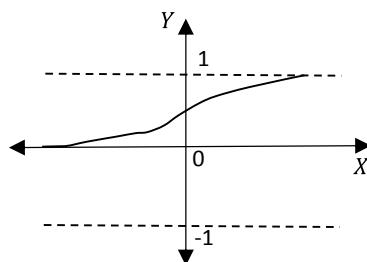


Figura 4.15 Función sigmoidal

Capa de salida. Esta capa transfiere información de la red hacia el exterior. Y para los módulos elaborados se optó por utilizar una variable de salida, siendo el geo-parametro su función de activación la lineal.

4.4 Estimaciones neuronales en fase de entrenamiento/prueba

En las Figuras (4.16, 17 y 18) se presentan los valores de RQD, FRAC y %REC medidos en campo comparados con los estimados con RNs en la etapa de entrenamiento. La relación medido contra evaluado sigue muy cercanamente la línea con pendiente igual a 1. Asociado se encuentra el coeficiente de determinación R^2 (revela en qué grado corresponden los valores estimados con los datos reales) que en los dos casos son muy cercanos a 1.0.

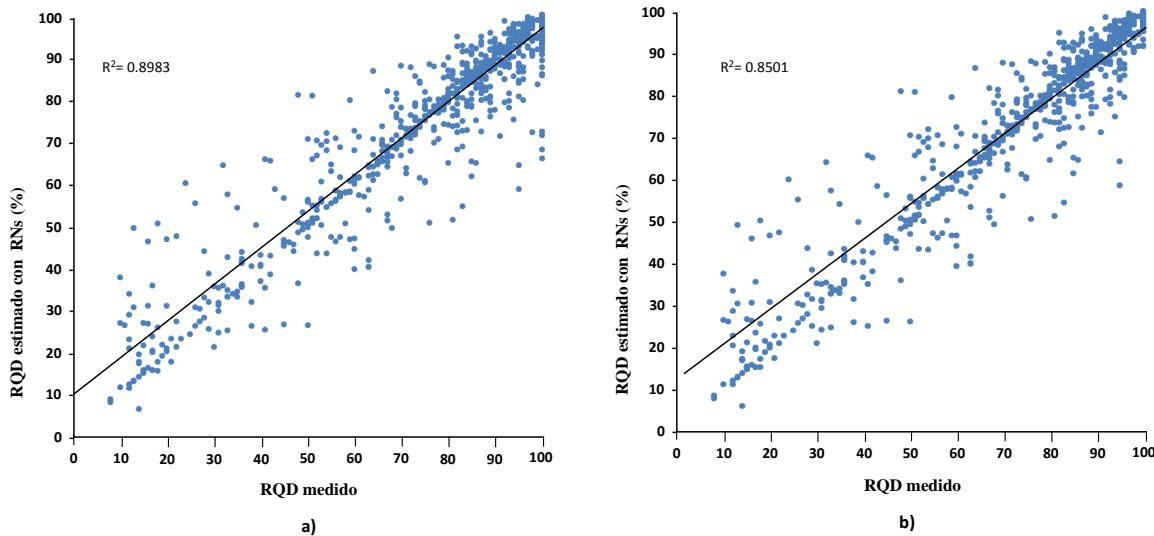


Figura 4.16 Resultados obtenidos para la fase de entrenamiento de los modelos neuronales a) RQD MD, estructura nodal 3x100x100x1, b) RQD MI, estructura nodal 3x100x100x1

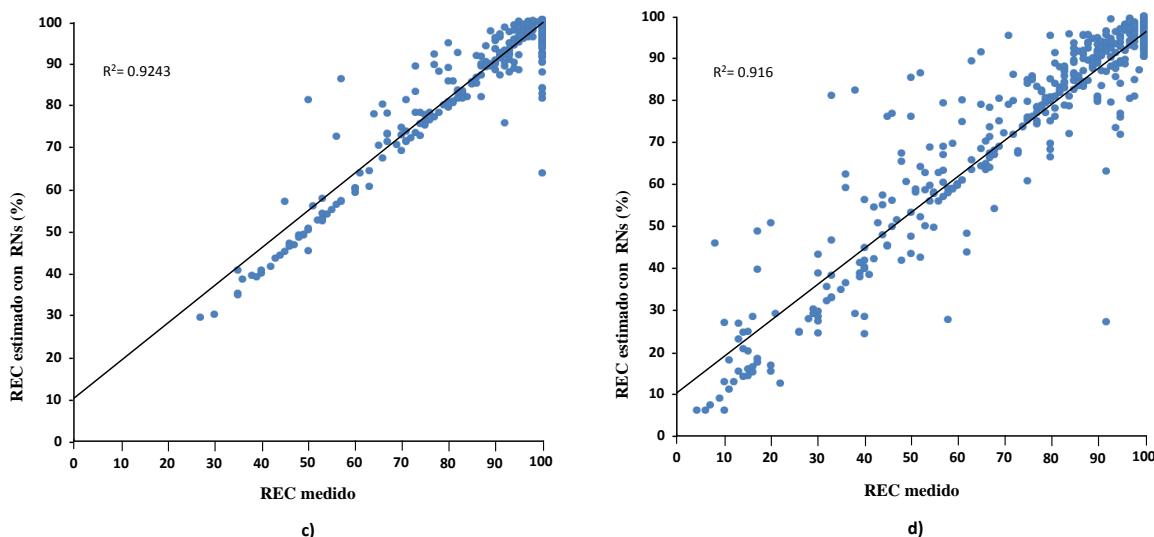


Figura 4.17 Resultados obtenidos para la fase de entrenamiento de los modelos neuronales a) REC MD, estructura nodal 3x300x300x1, b) REC MI, estructura nodal 3x100x100x1

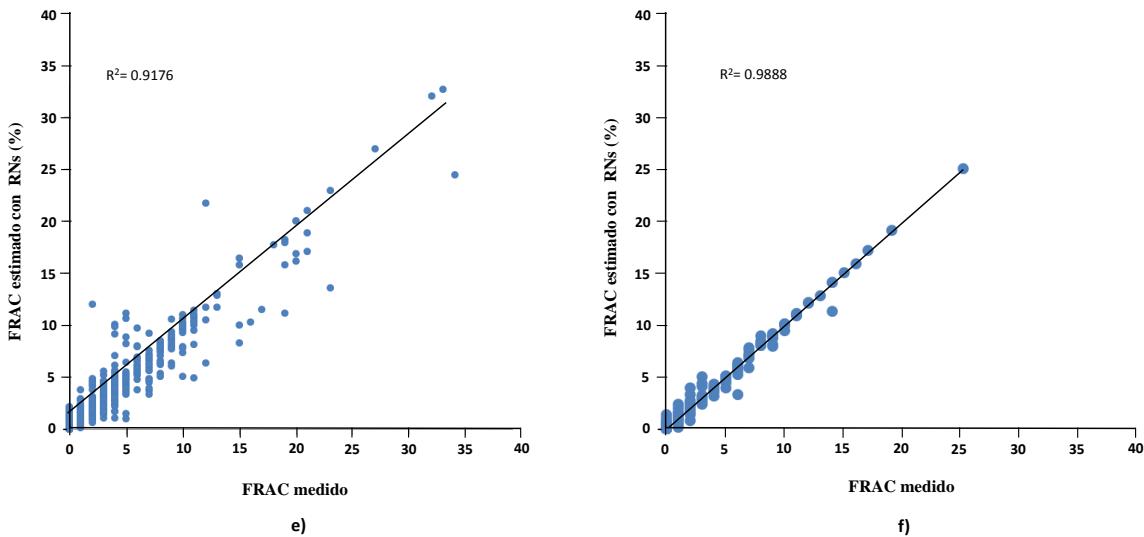


Figura 4.18 Resultados obtenidos para la fase de entrenamiento de los modelos neuronales a) FRAC MD, estructura nodal 3x20x20x1, b) FRAC MI, estructura nodal 3x300x1

En la fase de prueba los valores de RQD, FRAC y %REC ,por los dos módulos pueden considerarse representativos de cada geo-propiedad ya que proporcionan poca dispersión alrededor de la línea (Figuras 4.19, 20 y 21). Las gráficas muestran que la mayoría de los valores predichos se encuentran dentro del intervalo., indicando el notable desempeño en predicción de casos fuera del conjunto de entrenamiento (no incluidos para desarrollar las RNs). Si las entradas y las salidas tienen la suficiente conexión paramétrica, entonces la red converge en un cierto número de iteraciones (manteniendo fijo el número de nodos ocultos) hacia un error global mínimo. A partir de estos resultados se considera que el entrenamiento es óptimo y el error de la variable de salida es mínimo y apropiado. Los resultados de la fase de prueba sustentan la eficacia de la red neuronal propuesta.

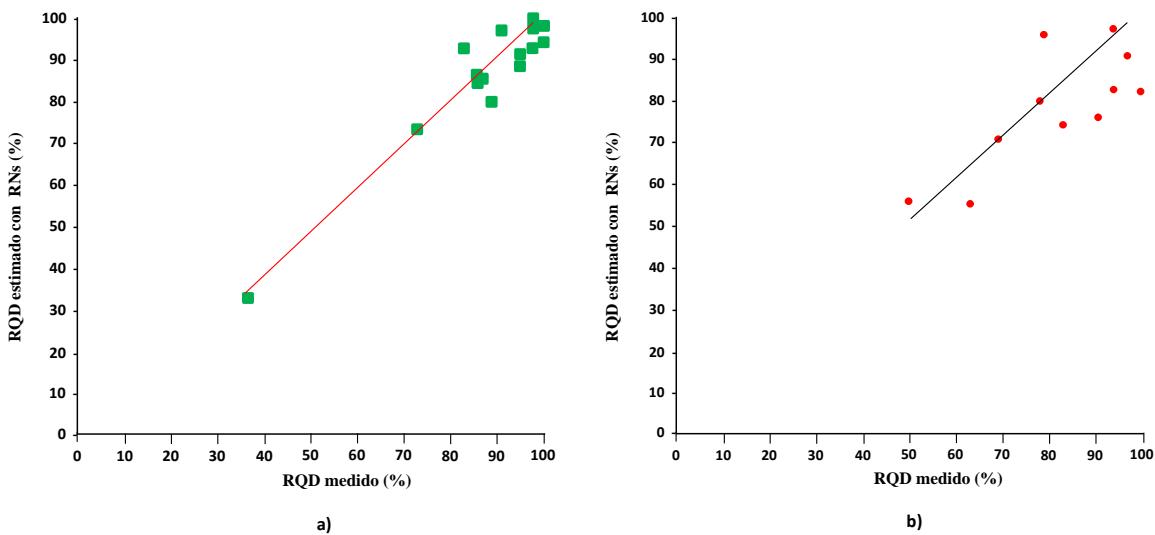


Figura 4.19 Resultados obtenidos para la fase de prueba de los modelos neuronales a) RQD MD, b) RQD MI

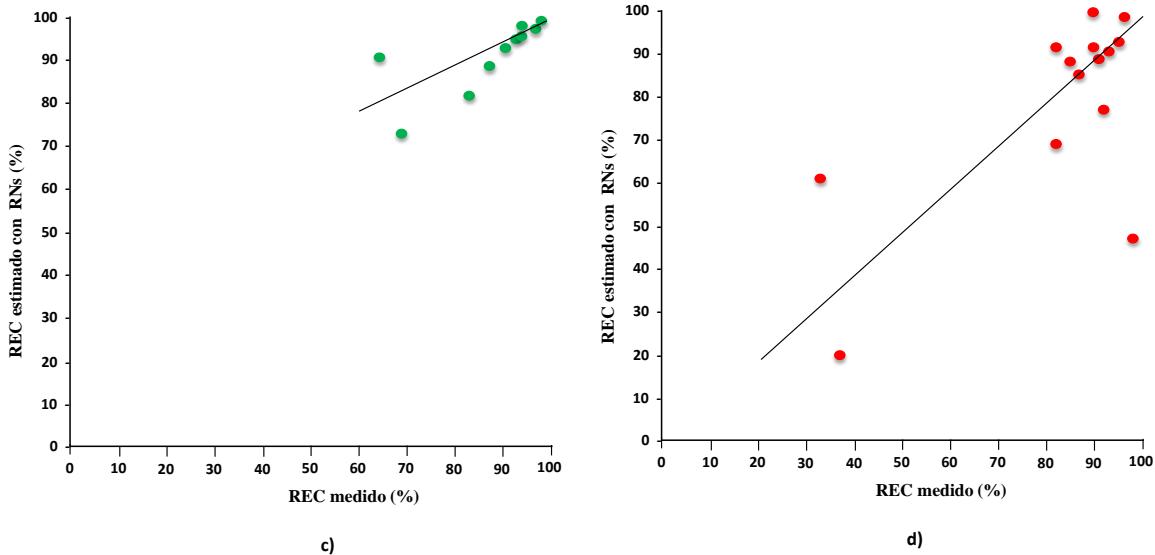


Figura 4.20 Resultados obtenidos para la fase de prueba de los modelos neuronales c) REC MD, d) REC MI

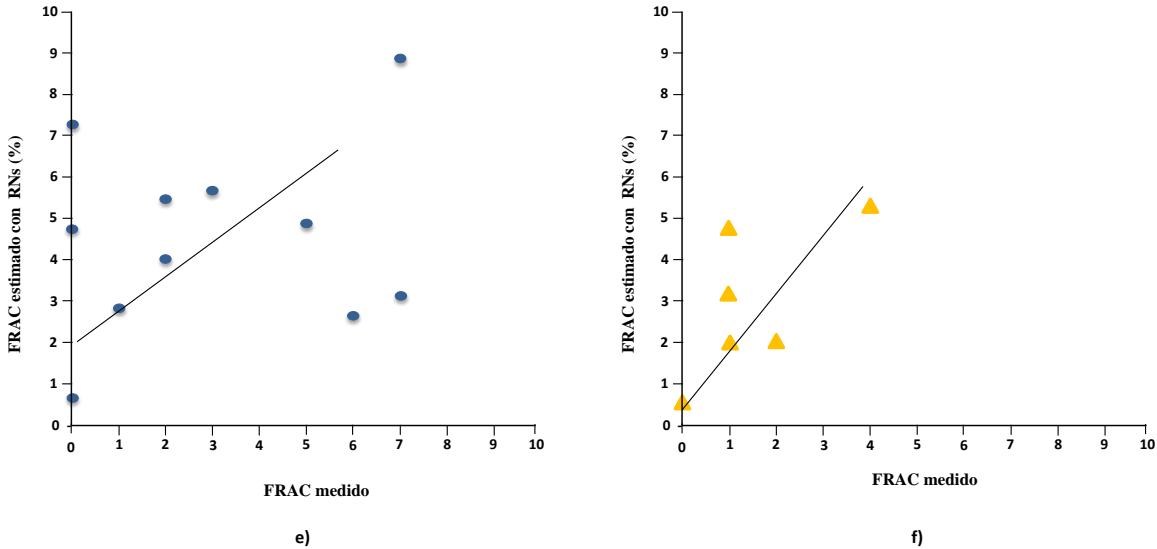


Figura 4.21 Resultados obtenidos para la fase de prueba de los modelos neuronales e) FRAC MD, f) FRAC MI

Se consideran entonces exitosas las RNs presentadas y de acuerdo con toda la operación descrita se resume el método de la siguiente forma:

- 1) Generación de la base de datos incluyendo la identificación del sitio (barrenos) (X, Y – coordenadas geográficas-;y Z elevación de referencia (metros por encima del nivel del mar) y la variable adherida (geo-propiedad)
- 2) Se elige un arreglo de capas y neuronas para entrenarlo hasta que se obtenga una RNs exitosa que sea capaz de predecir valores de salida en casos de prueba con suficiente aproximación.
- 3) Para requerimientos de un ambiente visual adaptativo se construye una densa malla usando patrones de entrenamiento, prueba y cálculos adicionales.
- 4) Se evalúa la congruencia de los resultados en los ambientes de visualización 3D y se generan los perfiles, y/o mapas de contornos.

Por conveniencia a partir de esta sección a las RNs encargadas de definir los valores de propiedad en el espacio se les llama VEN (variador espacial neuronal). A continuación la presentación de algunos esquemas del tipo de resultados que se consiguen con esta metodología y una descripción más puntual de cada VEN.

4.5 VEN RQD margen derecho/izquierdo

Para el análisis espacial de la variable *RQD* la arquitectura neuronal más eficiente (después de intentar más de 13 combinaciones diferentes entre capas y número de nodos) cuenta con 2 capas ocultas (cada una con 100 nodos) cabe mencionar que esta arquitectura se utilizó para ambos márgenes del relieve. En las Figuras 4.22 y 4.23 se muestran los volúmenes con los resultados para RQD margen derecho e izquierdo, respectivamente.

4.6 VEN FRAC margen derecho/izquierdo

Para el análisis espacial de la variable *FRAC* la arquitectura neuronal más eficiente (después de intentar más de 13 combinaciones diferentes entre capas y número de nodos) cuenta con 2 capas ocultas (cada una con 20 nodos) margen derecho y el margen izquierdo con 1 capa oculta (con 300 nodos). En las Figuras 4.24 y 4.25 se muestran los volúmenes con los resultados para *FRAC* margen derecho e izquierdo, respectivamente.

4.7 VEN %REC margen derecho/izquierdo

Para el análisis espacial de la variable *%REC* la arquitectura neuronal más eficiente (después de intentar más de 13 combinaciones diferentes entre capas y número de nodos) cuenta con 2 capas ocultas (cada una con 300 nodos) y el margen izquierdo con 2 capas ocultas (cada una con 100 nodos).En las Figuras 4.26 y 4.27 se muestran los volúmenes con los resultados para *%REC* margen derecho e izquierdo, respectivamente.

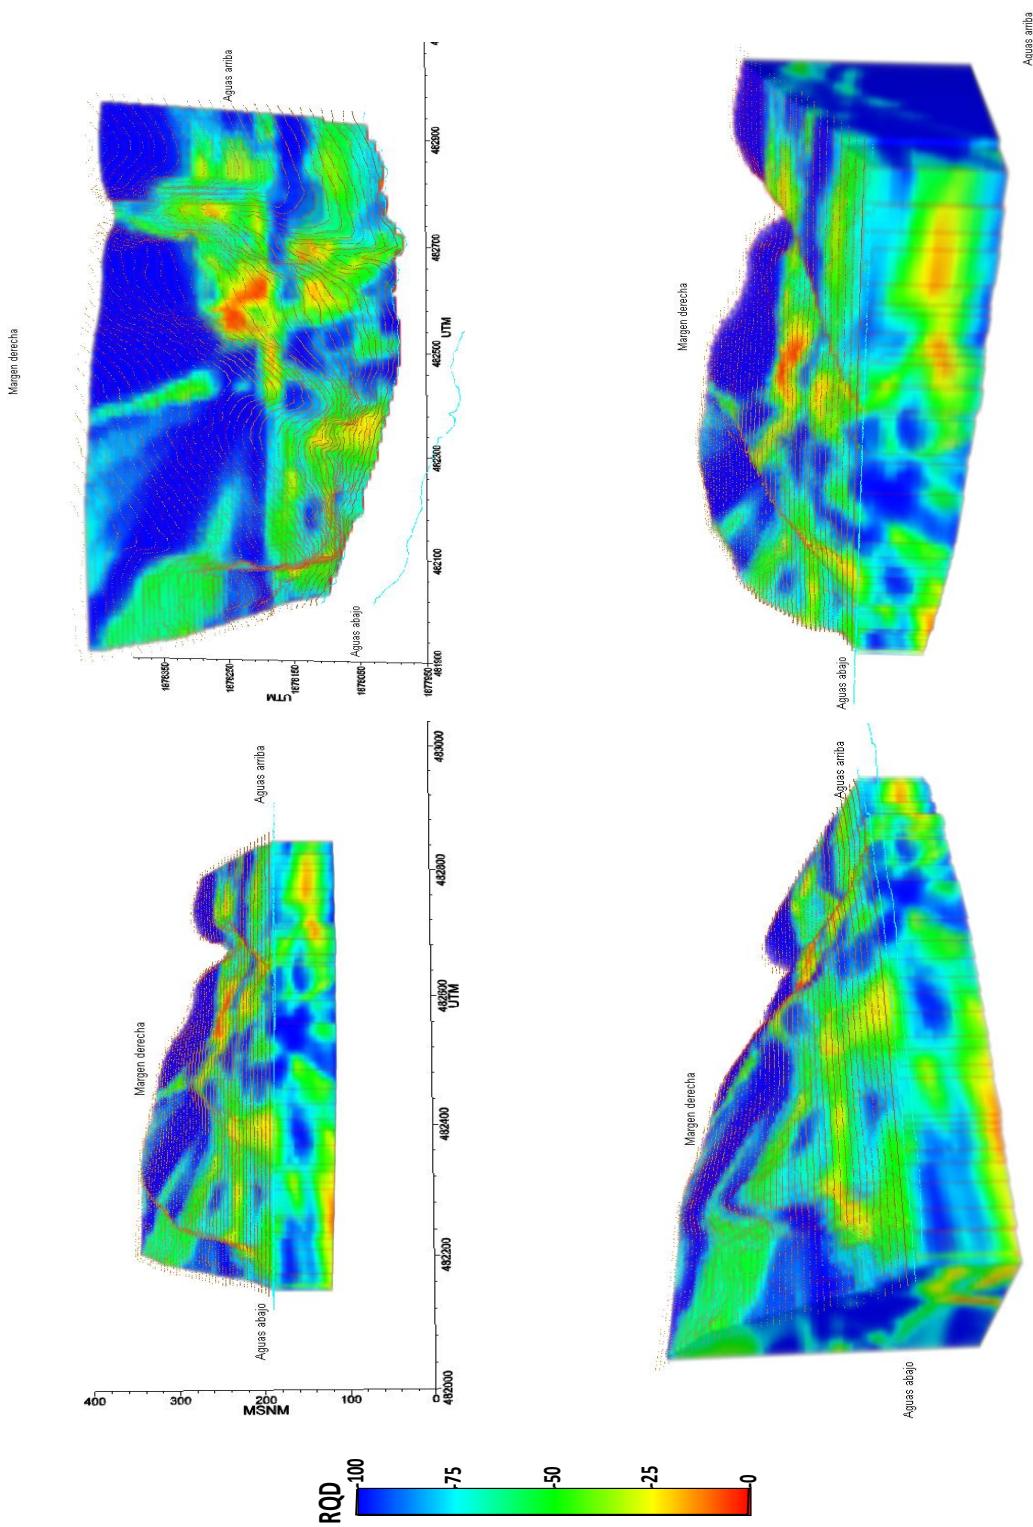


Figura 4.22 Variación espacial de propiedad RQD margen derecho

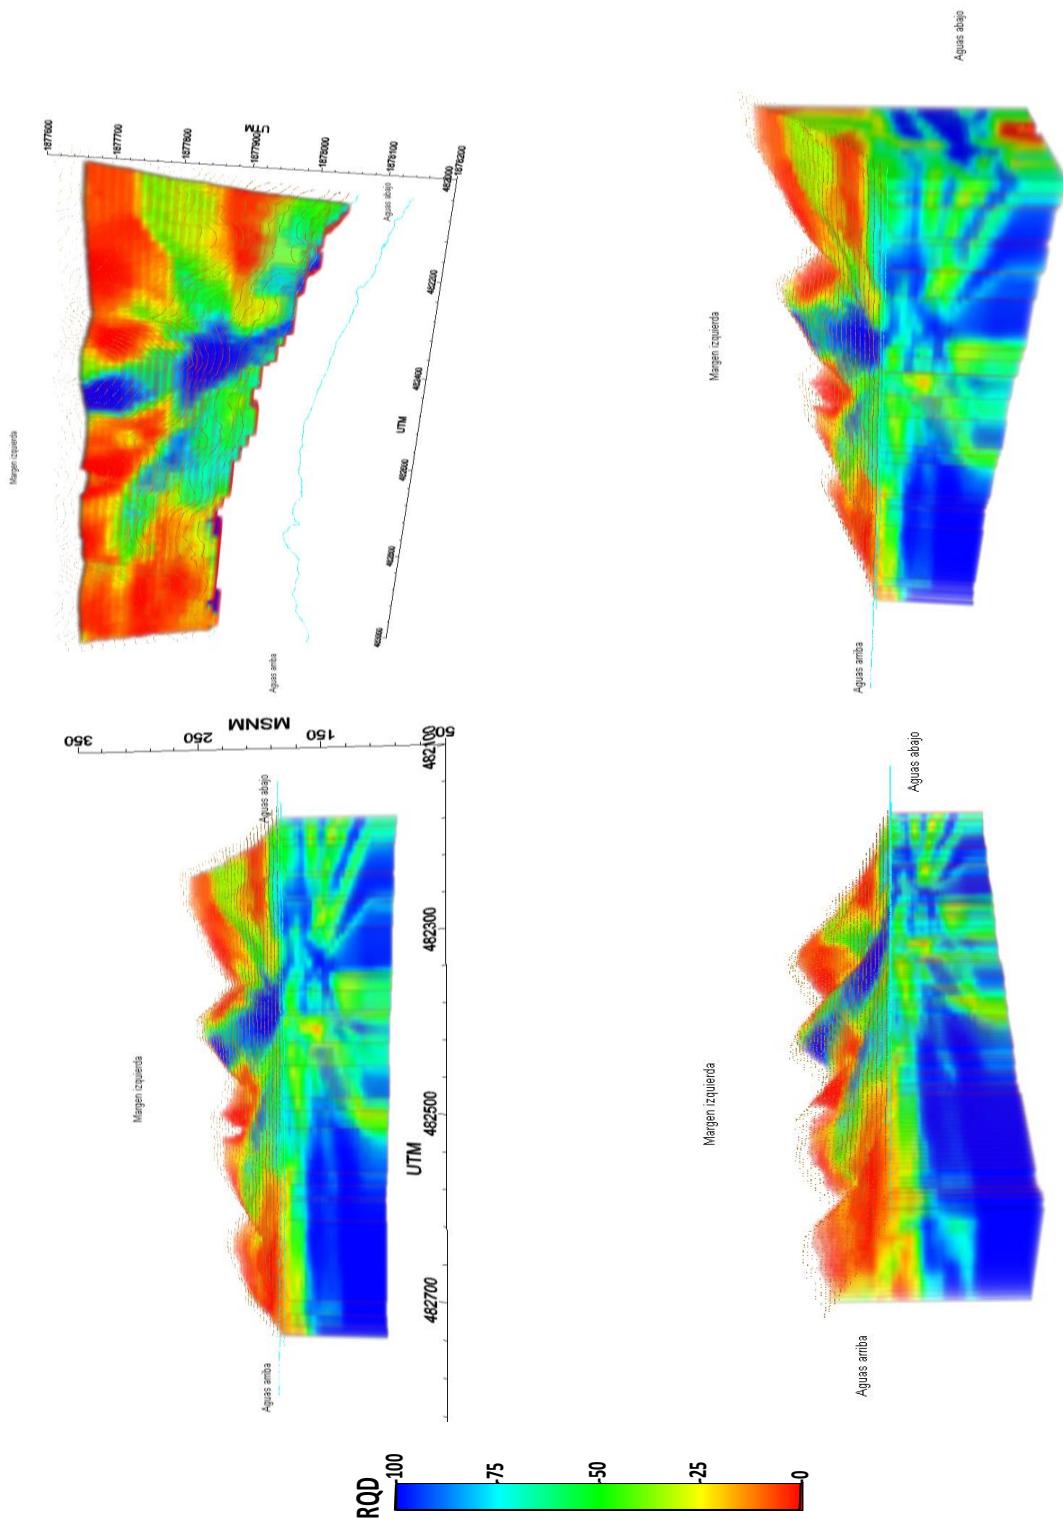


Figura 4.23 Variación espacial de propiedad RQD margen izquierdo

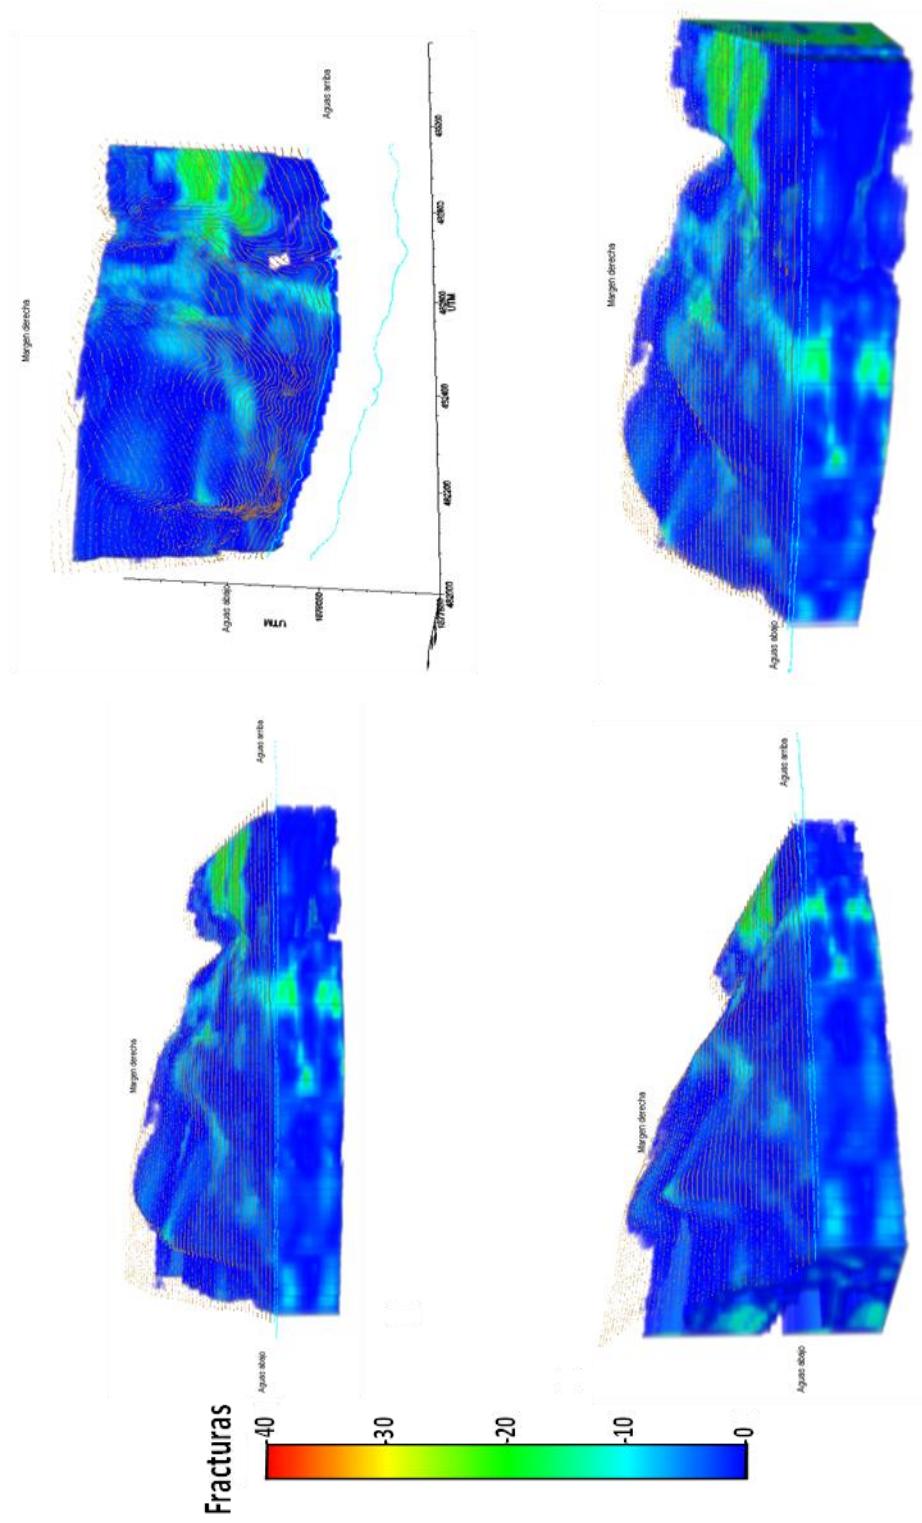


Figura 4.24 Variación espacial de propiedad FRAC margen derecho

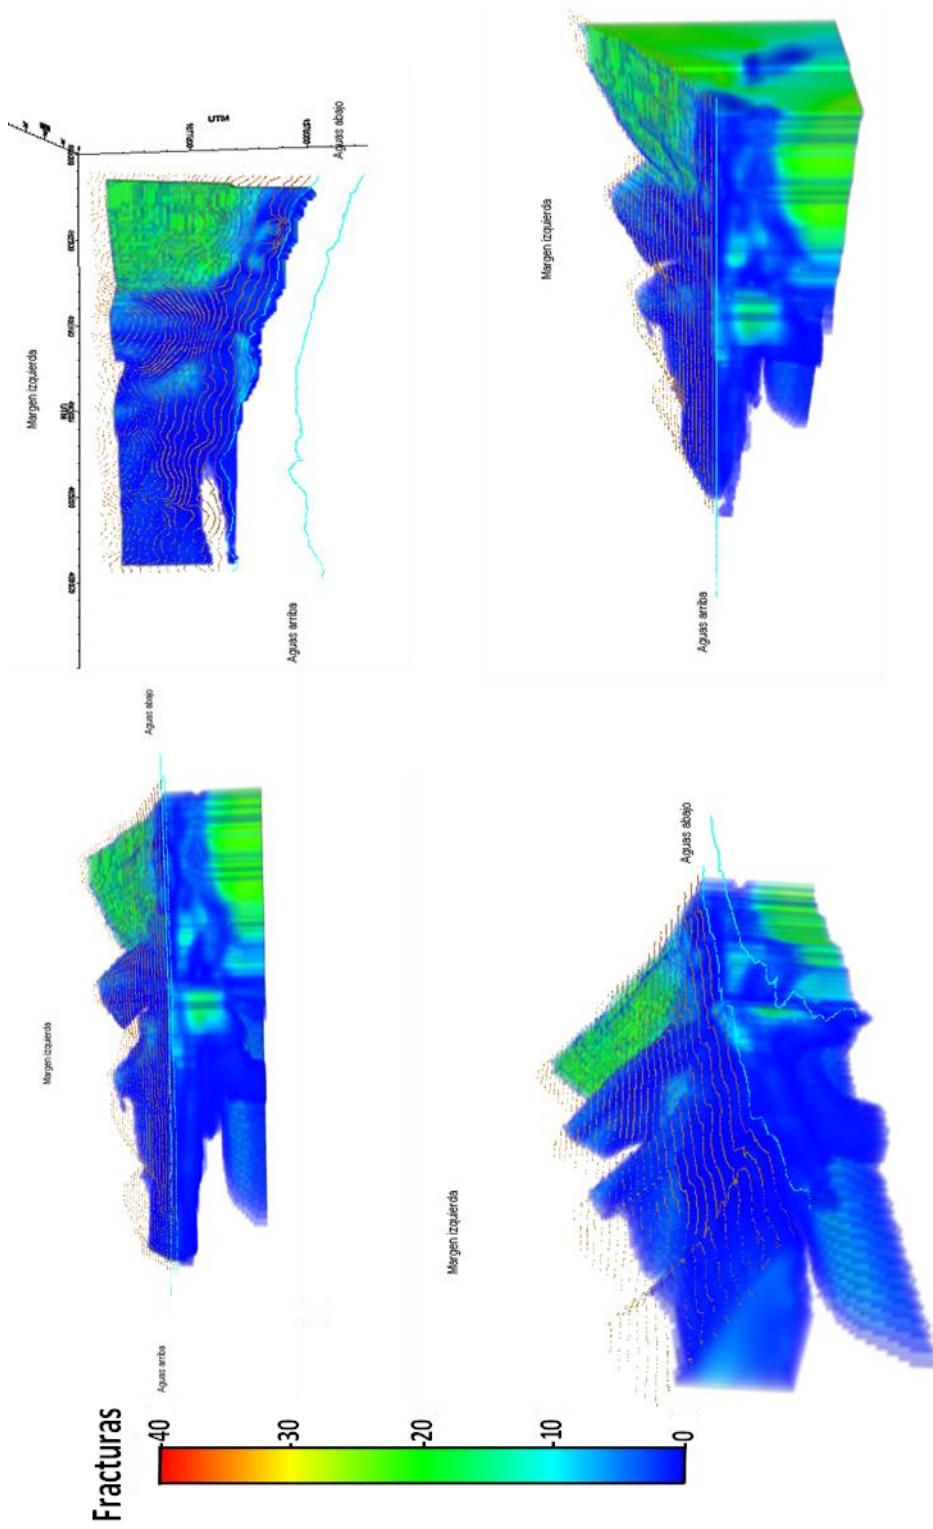


Figura 4.25 Variación espacial de propiedad FRAC margen izquierdo

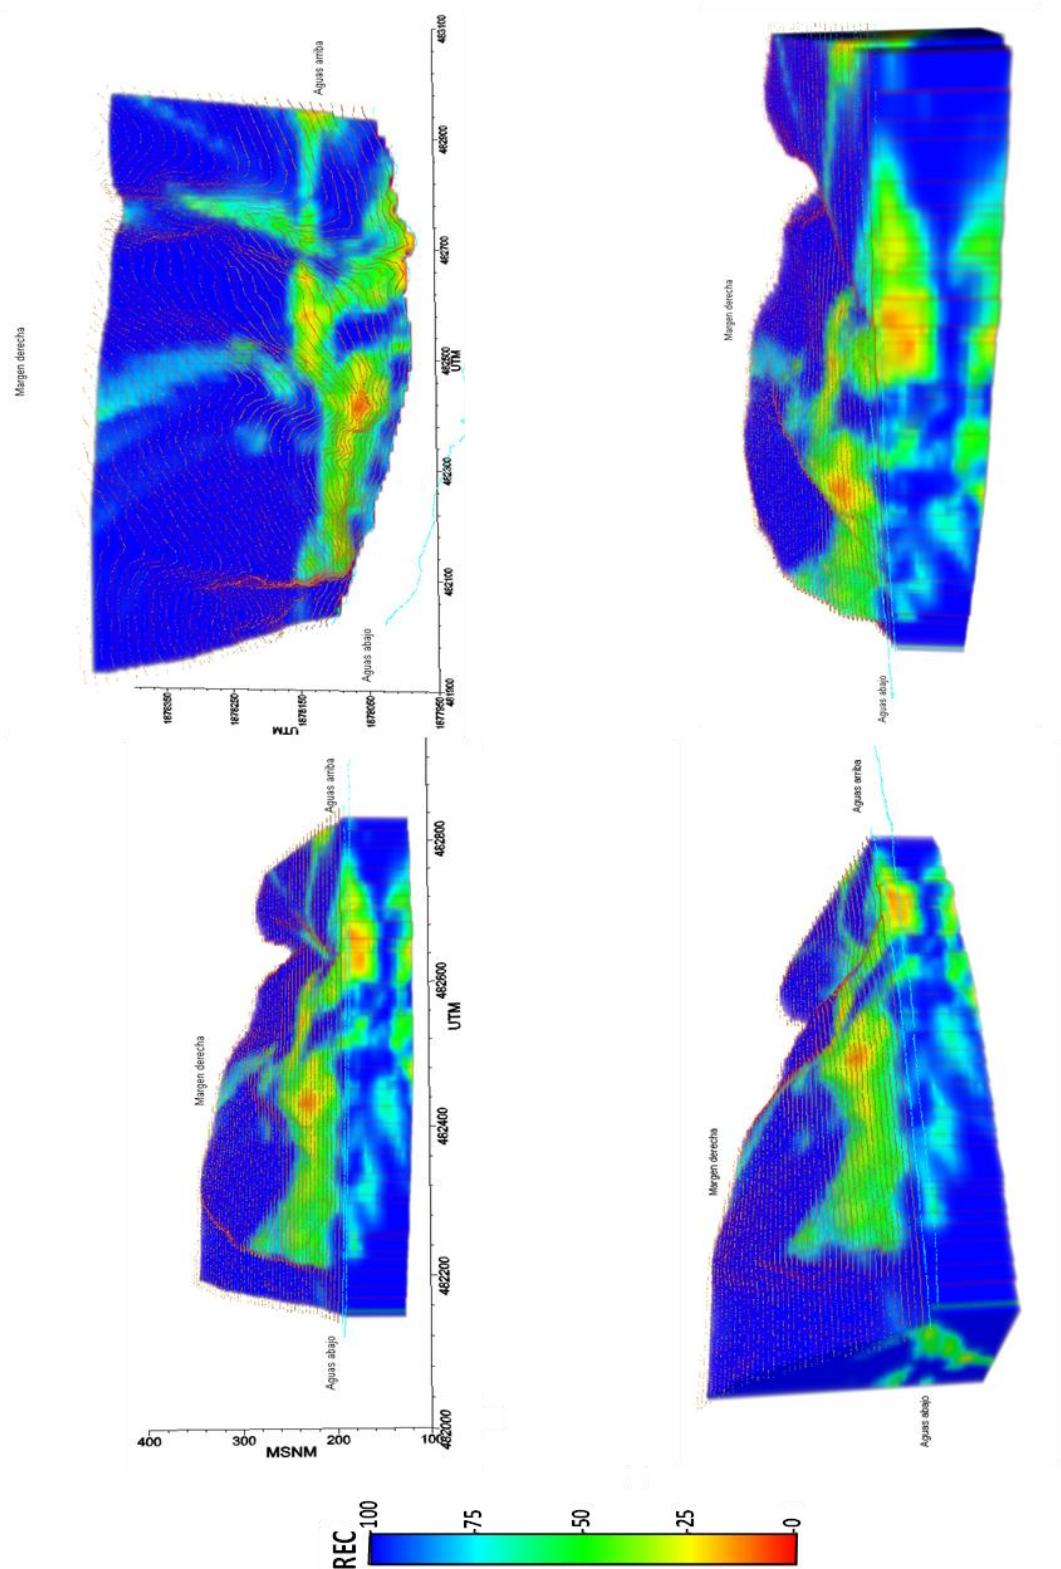


Figura 4.26 Variación espacial de propiedad % REC margen derecho

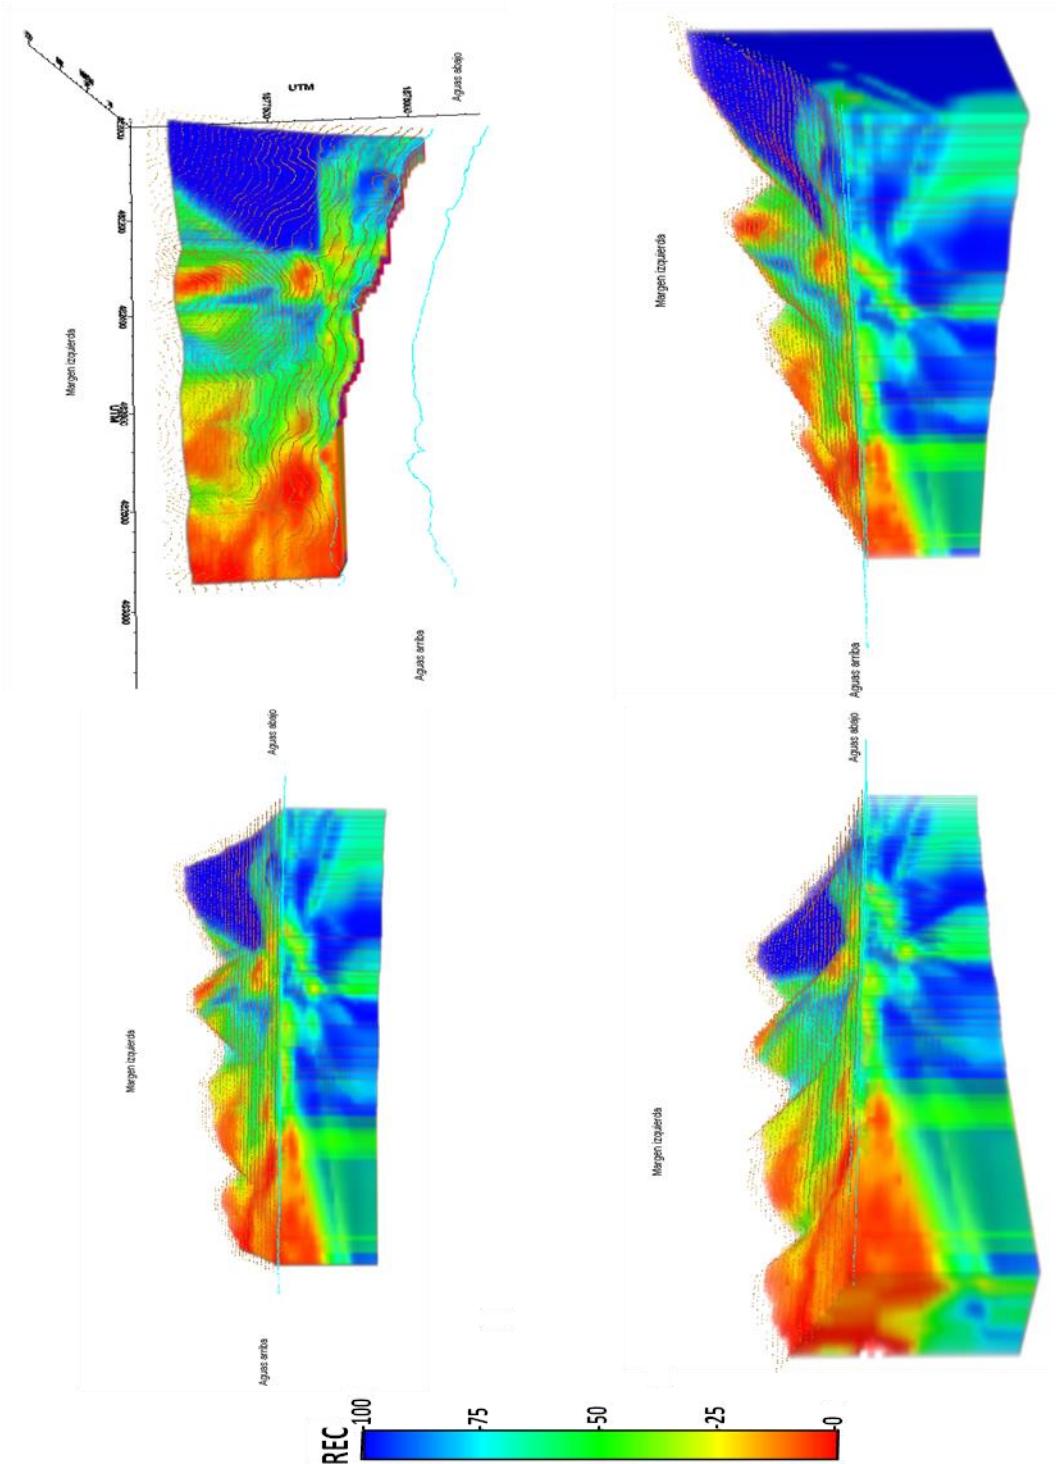


Figura 4.27 Variación espacial de propiedad % REC margen izquierdo

CONCLUSIONES

Las RNs permiten interpretar información geotécnica para evaluar directamente su variación en el espacio y para obtener indirectamente otros parámetros del suelo de importancia práctica/científica.

Emplear RNs puede ser catalogada como una actividad ingenieril sólidamente establecida, con métodos en todas sus etapas de desarrollo viables y asequibles, económica en el empleo de recursos humanos y computacionales y que permite una sencilla actualización conforme se obtengan nuevos datos de pruebas relacionadas con el estudio objetivo.

Se demuestra en este ejercicio la alta capacidad de generalización de las RNs al construir una configuración 3D de geo-propiedades muy cercanos a lo que la práctica en campo y los sondeos *reales* implícitamente mostraban.

REFERENCIAS

- Aronoff, S. (1989), “*Geographical Information Systems: A management perspective*”. WDL Publications, Otawa, 249 p.
- Auvinet, G. (1984), “*Variabilidad de los depósitos de carbón. Un enfoque estocástico*”. Estudio realizado para Minera Carbonífera de Río Escondido, Coahuila, México. pp. 11-20
- Auvinet, G. (1997), “*El concepto de confiabilidad en Geotecnia*”. Memoria, IV Congreso Nacional de Ingeniería Civil, Universidad de las Américas, Cholula, Puebla. pp. 21-30.
- Auvinet, G. (2002), “*Incertidumbre en Geotecnia*”. Decimosexta Conferencia Nabor Carrillo, Sociedad Mexicana de Mecánica de Suelos, Querétaro, México. pp. 21-28
- Auvinet, G. (2009), “*Advances in geotechnical characterization of Mexico City basin subsoil*”. Proceedings, 17th International Conference on Soil Mechanics and Geotechnical Engineering, International Society for Soil Mechanics and Geotechnical Engineering, Alexandria, Egypt, pp. 2679-2682.
- Aymerich, M. & Navarrina, F. (1985), “*Interpolación Mínimo-cuadrática de superficies a partir de datos irregularmente distribuidos*”. Revista Internacional de Métodos Numéricos para cálculo y diseño en ingeniería, Ed cimne, pp. 21-36.
- Barton, N. Lien, R. and Lunde, J. (1974), “*Engineering classification of rock masses for the design of tunnel support*”. Rock Mechanics. Vienna Springer Verlag, vol. 6, pp. 189-236.
- Bieniawski, Z. T. (1973), “*Engineering classification of jointed rock masses*”. Transactions, South African Inst. of Civil Engineers, vol. 15, n. O 12, pp. 335-344.
- Bishop C. M. (1996), “*Neural network for pattern recognition*”, Ed Clarendon Press, Oxford, pp.482.
- Bonetti M. (2013), “*Estimación De La Variación Espacial De La Resistencia Al Corte En Suelos Marinos Usando Redes Neuronales*” Tesis de Maestría en Ingeniería. UNAM. 113 p.
- Burgess, T. & Webster, R. (1980), “*Optimal interpolation and isarithmic mapping of soil properties: The semi-variogram and punctual kriging*”. Journal of Soil Sci., Volumen 31, pp. 315-331.
- Burrough, P. A. (1985), “*Principles of Geographical Information Systems for Land Resource Assessment*”. Ed Clarendon Press, Oxford. 194 p.

D. U. Deere y R. P. Miller. (1966), “*Engineering classification and Index properties for intact rock*”, Tech. Rept. No. AFWL-TR-65-116, Air Force Weapons Lab., Kirtland Air Force Base, Nuevo México. 327 p.

De los Ángeles M. N. (2010), “*Técnicas y Métodos de Análisis Espacial Seminario Análisis Espacial*”. Seminario de análisis espacial. 34 P.

Dr. Martín A. et al. (2004), “*Geoestadística Aplicada Tema: Otros Métodos de Estimación Espacial*” Instituto Mexicano Del Petróleo. 480 p.

Fahlman, S. E. (1988), “*Faster-learning variations on back-propagation: An empirical study*”, proceedings of the 1988 connectionist models summer school CMU. pp 38-51

Fallas J. (2007), “Modelos digitales de elevación: Teoría, métodos de interpolación y aplicaciones”. Costa Rica. 86 p.

García S. et al (2006), “*Variación espacial de las propiedades del suelo usando Cómputo Aproximado*”, publicada por el Centro de Información Tecnológica y el Instituto Iberoamericano de Información en Ciencia y Tecnología, (CIT) con sede Chile. 9 p.

García S. et al (2013), “*Un Procedimiento Para Determinar La Variación Espacial De La Intensidad De Movimientos De Terreno En Áreas Extensas Con Escasa Instrumentación*”. XIX Congreso Nacional De Ingeniería Sísmica. Instituto de ingeniería UNAM. 15 p.

Garcia, S R and Romo M P. (2011), “*Neuro-Spatial Variation of Soil Properties*”, Geotechnical and Geological Engineering Journal.

García, S. (2009), “*Cómputo Aproximado en la Solución de Problemas Geosísmicos*”. D.F.: Tesis de Doctorado en Ingeniería. UNAM. DEPFI-UNAM. 308 P.

García, S. and Romo, M. P. (2004), “*Sistema de Información Geográfica y Redes Neuronales*”. Memorias de la Reunión Nacional de Mecánica de Suelos. Guadalajara-Méjico. 10 p.

García, S., Chimalpopoca, T. R. & Bonetti C. (2012), “*Cognitive-Spatial Variation: Local amplification of Ground Motions*”. Precedings of the 15TH World Conference on Earthquake Engineering WCEE. 10 p.

García, S. et al (2005), “*Spatial variation of soil properties using soft computing*”. Proceedings of the 11th International Conference IACMAG, Turín, Italia. pp. 611-618.

Gómez Laa, G. y Foyo, A. (1979), “*Analysis of «in situ» permeability tests in some spanish dams*”. XIII ICOLD, New Delhi

Gonzales de Vallejo L. et al. (2002), “*Ingeniería Geológica*”. Ed Pearson Educación, Madrid. p.p 744

Goovaerts, P. (1997), “*Geostatistics for Natural Resources Evaluation*”. Ed Press.Oxford Univ. 483 p.

Gutiérrez C. J. (2013), “Interacción Dinámica Suelo Estructura: Una Visión Cognitiva – No Lineal” Tesis de Maestría en Ingeniería. UNAM. 82 p.

Haykin S. (1999), “*Neural networks: A comprehensive foundation*”, (2^{da} ed.), Ed Prentice Hall. New Jersey 842 p.

Herrera J. et al. (2012), “*Utilización de técnicas de sondeos en estudios geotécnicos*”. Universidad politécnica de Madrid, laboratorio de tecnologías mineras. 95 p.

Juárez , M. & Auvinet, G. (2000), “*Caracterización geoestadística del subsuelo del Valle de México*”. Memorias técnicas de la XX Reunión Nacional de Mecánica de Suelos, Sociedad Mexicana de Mecánica de Suelos,Oaxaca, México. Vol. 2, pp. 387-396

Krige, D. G. (1962), “*Statistical application in mine valuation*”. Institute Mine Survey, South Africa. pp 2-3

Leiva G., Valdés R., Aravena Y., Villarroel R. (2000), “*Caracterización Geotécnica-Estructural*”, Mina Radomiro Tomic, Actas 9º Congreso Geológico Chileno, Volumen 1, pp 261 -265.

Matheron, G. (1965), “*Les variables généralisées et leur estimation*”. France, Ed Masson et Cie. 139 p.

McCulloch, W. & Pitts, W. (1943), “*A logical calculus of the ideas immament in nervous activity*”. Bulletin of Mathematical Biophysics, from the university of illinois, college of medicine,departament of psychiatry at the illinois neuropssychiatric institute, and the university of chicago Volumen 7., pp. 115-133.

Minsky, M. & Papert, S. (1969), “*Perceptrons*”. Ed. MIT Press. Massachusetts pp 45-70

OIalla, e y Sopeña, L. (1991), “*Ensayos de campo*”. Monografías nº 5. Máster de Ingeniería Geológica. Departamento de Geodinámica. Universidad Complutense de Madrid.

Peraza D. J. (2013), “*Redes Neuronales Para Determinar La Capacidad De Carga De Pilas*” Tesis de Maestría en Ingeniería. UNAM. 88 p.

Pérez O. J. (2002), “*Modelos Predictivos Basados en Redes Neuronales Recurrentes de Tiempo Discreto*” Tesis Doctoral De La Universidad de Alicante. 177 p.

Priale J. (1989), “*Mecánica de suelos y ciencias afines aplicadas a obras hidráulicas*”. Ed CDPI-CIP, colegio de ingenieros del Perú. 149 p.

Quintero P. J. (2012), “*Modelo de dependencia espacial aplicado al análisis de la distribución del consumo de alcohol en el campus CU, UNAM*” Investigaciones Geográficas, Boletín del Instituto de Geografía, UNAM. pp. 115-148.

Rivapalacio ricardo (1979), “*Geología y geotecnia del proyecto hidroeléctrico de chicoasen, Chiapas*”. Comisión Federal de Electricidad. 238 p.

Rosenblatt, F. (1959), “*Mechanization of Thought Processes: Two Theorems of Statical Separability in the Perceptron*”. Symposium at National Physical Laboratory. HM Stationery Office. London. Volume 1, pp 421–456.

Rumelhart, D. E., Hinton, G. E. & Williams, R. J., (1986). “*Learning representations by back-propagation errors*”. Institute for Cognitive Science, University of California, San Diego. pp. 533-536

Rumelhart, D. E., McClelland, J. & PDP Research Group. (1986), “*Parallel Distributed Processing: Exploration in the Microstructure of Cognition*”. Massachusetts MIT Press, Volumen 1: Foundations, pp. 318-368.

Santoyo, E. (2010), “*Vigésima Conferencia Navor Carrillo: Exploración de suelos, métodos directos e indirectos, muestreo y pruebas de campo*”. Acapulco, Gro., Sociedad Mexicana de Ingeniería de Geotécnica.36 p.

Stagg-zienkiewics. (1970), “*Mecánica de rocas en la ingeniería práctica*” Ed. Blume, Madrid. 398 p.

Terzaghi, K. (1946), “*Rock Defects and Loads on Tunneling Supports, in Rock Tunneling with Steel Supports*”, R.V. Proctor and T. White.. Ed, Commercial Shearing. Youngstown, Ohio. pp. 15-99.

Tobler, W. (1970), “*A computer model simulation of urban growth in the Detroit region*”. Economic Geography no. 46, pp. 234-40.

Van Marcke, E. H. (1983), “*Random Fields: Analysis and Synthesis*”. Massachusetts Institute of Technology, Ed. Press Cambridge, Massachusetts, USA. 393 p.

