



**UNIVERSIDAD NACIONAL AUTÓNOMA DE  
MÉXICO**



**Facultad de Ingeniería  
División de Ingeniería en Ciencias de la Tierra  
Departamento de Geofísica**

**Estimación de Saturaciones de Agua en Carbonatos  
Aplicando Redes Neuronales Artificiales Múltiples**

T E S I S

Que para obtener el título de:

**INGENIERO GEOFÍSICO**

Presenta:

**Elsa Cristina Gutiérrez Martínez**

Director de Tesis:

*Ing. Héctor Ricardo Castrejón Pineda*

Ciudad Universitaria, México DF, 2007.



Universidad Nacional  
Autónoma de México

Dirección General de Bibliotecas de la UNAM

**Biblioteca Central**



**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 esta protegido por la Ley Federal del Derecho de Autor (LFDA) de los Estados Unidos Mexicanos (México).

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.

## AGRADECIMIENTOS

A...

**LA UNAM:** Por permitirme acceder al mundo del conocimiento y por mostrarme que el conocimiento es el arma más efectiva para derribar fronteras.

**Marytere Gutiérrez, Daniel Dorantes y Ambrosio Aquino:** Por darme la oportunidad de llevar a cabo mi tesis aplicando sus tecnologías, por compartir conmigo parte de su conocimiento y experiencia, además de su paciencia, apoyo y comprensión.

**Ricardo Castrejón Pineda:** Por aceptar ser mi tutor y darme a conocer el mundo de los registros geofísicos de pozo, además del apoyo brindado.

**Mis profesores:** Por enseñarme algunas de la gran cantidad de ramas del conocimiento que existen.

**Pahola:** Por todo tu apoyo, por el tiempo que sacrificaste por realizar mis trámites y sobre todo por tu amistad.

**Mis compañeros y amigos:** Por su tiempo y por el apoyo que alguna vez me brindaron o que me siguen brindando, por los buenos y malos momentos, por las experiencias vividas, por aquellas amistades que fueron creciendo con el tiempo y las que se debilitaron con el mismo, a Jazmín, Amanda, Elvia, Xochitl, Agni, Rojas, las “daysis”, y todos aquellos que fueron parte de mi formación y que no menciono porque me necesitaría un libro solo para escribir sus nombres, pero que recuerdo con cariño y aprecio.

**A mis familiares:** Por el apoyo brindado directa o indirectamente ayudando a mis padres, hermanos o a mi.

**A todas las personas que estuvieron conmigo** en algún momento de mi vida aunque ya no las vea y que de algún modo contribuyeron para que yo llegara hasta este punto de mi vida.

## DEDICATORIAS:

**A Dios:** Gracias por estar conmigo en todo momento, por ser mi guía, por haberme dado tanto incluso sin pedirlo, por dejarme llegar hasta aquí, por mi familia, por mis amigos, por esta tesis y porque sigas a mi lado ya que estoy conciente de que es un paso muy importante en mi camino pero no es el último.

**A mi mami:** Por darme la vida y apoyarme en todo momento y por tu fuerza moral.

**A mi papi:** Por darme la vida y por tratar de darme una carrera.

**A mis hermanos:** porque me apoyaron como mis padres, y me cuidaron como hermanos, por todo el apoyo moral y económico que me dieron...

**Héctor:** Porque te preocupaste por nosotros, por tus consejos y porque siempre procuraste ser un buen ejemplo.

**Poncho:** Por tu tiempo, tu sentido del humor y seguirme la corriente en mis gustos e ideas raras que de pronto me llegan.

**Lore:** Por tu tiempo, por estar ahí a mi lado, por tratar de comprenderme y por procurar nuestro bienestar.

**A mi cuñadito y cuñadas:** Por el apoyo y cariño que me han dado.

Por todos esos momentos que hemos pasado, consejos, apoyo, cariño, por creer en mí y porque esta tesis es el reflejo del esfuerzo no solo mío sino de todos nosotros.

# ÍNDICE

<b>RESUMEN</b>	<b>5</b>
<b>CAPÍTULO 1. INTRODUCCIÓN</b>	<b>6</b>
<b>CAPÍTULO 2. CONCEPTOS PETROFÍSICOS GENERALES</b>	<b>8</b>
<b>2.1 Porosidad</b>	<b>8</b>
<b>2.1.1 Tipos de porosidad definidos para interpretación</b>	<b>9</b>
<b>2.1.2 Procesos que afectan la porosidad</b>	<b>10</b>
<b>2.2 Permeabilidad</b>	<b>11</b>
<b>2.3 Saturación de fluidos</b>	<b>11</b>
<b>2.3.1 Saturación de agua irreducible</b>	<b>12</b>
<b>2.3.2 Porosidad con agua y con hidrocarburos</b>	<b>13</b>
<b>2.3.3 Perfil de invasión</b>	<b>13</b>
<b>2.3.4 Cálculo de <math>S_w</math> por Simandoux modificado</b>	<b>14</b>
<b>CAPÍTULO 3. FUNDAMENTOS DE LAS REDES NEURONALES ARTIFICIALES</b>	<b>17</b>
<b>3.1 Historia de las Redes Neuronales Artificiales (RNA)</b>	<b>17</b>
<b>3.2 Redes neuronales biológicas</b>	<b>19</b>
<b>3.3 Elementos de una red neuronal artificial</b>	<b>20</b>
<b>3.4 Funcionamiento</b>	<b>21</b>
<b>3.5 Funciones de activación</b>	<b>22</b>
<b>3.6 Funciones de salida</b>	<b>26</b>
<b>3.7 Formas de conexión</b>	<b>27</b>
<b>3.8 Clasificación de las redes neuronales</b>	<b>29</b>
<b>3.8.1 Clasificación según su topología o estructura de la red</b>	<b>29</b>

3.8.2	Clasificación según su mecanismo de aprendizaje	30
3.9	Tasa de Aprendizaje ( $\eta$ )	31
3.10	Red de propagación hacia atrás ( <i>Red Backpropagation</i> )	32
<b>CAPÍTULO 4. METODOLOGÍA PARA LA APLICACIÓN DE UNA RNA</b>		<b>34</b>
4.1	Recopilación de información	34
4.2	Correlación de eventos	35
4.3	Control de calidad (LQC) y depuración de registros geofísicos	35
4.3.1	Revisión de encabezados	35
4.3.2	Curvas contenidas	35
4.3.3	Depuración de registros geofísicos	36
4.4	Selección de registros geofísicos	36
4.5	Normalización	37
4.6	Entrenamiento de la RNA	37
4.6.1	Control de entrenamiento	37
4.7	Validación de los entrenamientos	39
4.8	Predicción	39
<b>CAPÍTULO 5. APLICACIÓN DEL MÉTODO DE RNA'S A LA PREDICCIÓN DE UNA CURVA DE SATURACIÓN DE AGUA</b>		<b>40</b>
5.1	Geología general del campo Jujo-Tecominoacán	40
5.1.1	Localización	40
5.1.2	Geología general	41
5.1.3	Estratigrafía local	41
5.1.4	Geología estructural local	43
5.1.5	Roca generadora	44

<b>5.1.6 Trampa y Sello</b>	<b>44</b>
<b>5.1.7 Yacimiento</b>	<b>44</b>
<b>5.1.8 Información petrofísica de los pozos</b>	<b>45</b>
<b>5.2 Correlación de eventos</b>	<b>49</b>
<b>5.3 Control de calidad y depuración de registros geofísicos</b>	<b>50</b>
<b>5.4 Selección de registros geofísicos</b>	<b>54</b>
<b>5.5 Normalización</b>	<b>58</b>
<b>5.6 Entrenamiento de la RNA</b>	<b>58</b>
<b>5.6.1 Control del entrenamiento</b>	<b>59</b>
<b>5.7 Validación de los entrenamientos</b>	<b>61</b>
<b>5.7.1 Validaciones del pozo J-1</b>	<b>63</b>
<b>5.7.2 Validaciones del pozo J-2</b>	<b>66</b>
<b>5.7.3 Validaciones del pozo J-3</b>	<b>69</b>
<b>5.8 Predicción</b>	<b>72</b>
<b>CAPÍTULO 6. CONCLUSIONES Y RECOMENDACIONES</b>	<b>73</b>
<b>BIBLIOGRAFÍA</b>	<b>75</b>

## RESUMEN

El trabajo que se presenta en esta tesis tiene como objetivo la obtención de la curva de saturación de agua, aplicando redes neuronales, a pozos del campo Jujo-Tecominoacán de la región sur de México. Para el ejemplo de aplicación se contó con la información proveniente de tres pozos de éste campo, gracias a la interpretación Petrofísica con la que se contaba se sabía de antemano la existencia del “contacto” entre calizas y dolomías, a partir del cuál se definió el intervalo de interés.

Para entrenar redes neuronales artificiales (RNA's) es necesario contar con la información de entrada (en este caso fueron los registros GR, LLD y LLS) y la información de salida (la curva SW), mientras que en el caso de la validación y de la estimación solo es necesaria la información de entrada. El objetivo al utilizar RNA's responde a la necesidad de ver que tan confiables son los resultados de las redes neuronales, cuando no se tienen registros de porosidad en el intervalo de interés, comparando con los resultados provenientes de una evaluación con registros completos, con la finalidad de proponer esta metodología como una alternativa cuando se presentan estos casos o bien como un tipo de interpretación rápida con resultados confiables.

Pese a que hay muchas reservas respecto al uso de las redes neuronales en carbonatos, dado que las propiedades petrofísicas pueden variar considerablemente de un pozo a otro, en este campo se obtuvieron resultados confiables gracias a que las características de los pozos analizados no cambiaron abruptamente. Aunque las predicciones generadas por las RNA's pueden ser utilizadas como apoyo en la toma de decisiones, no dejan de ser modelos computacionales, lo cual implica que no suplantán a las curvas obtenidas con fórmulas matemáticas a partir de datos reales.



# CAPÍTULO 1.

## INTRODUCCIÓN

Los registros geofísicos de pozo son representaciones de alguna propiedad física o química del sistema roca fluido; el propósito de los registros es determinar las propiedades petrofísicas (porosidad, permeabilidad, saturación de fluidos, etc.) de las rocas del yacimiento. Sin embargo, ya sea por razones económicas o por características ambientales del pozo, no siempre se poseen todos los registros necesarios para determinar las características del yacimiento, ya que en algunas ocasiones uno o más registros vienen dañados, demasiado ruidosos o están ausentes; es por esto que se han desarrollado algunas metodologías con las que se busca desde la reconstrucción del registro faltante o dañado, hasta la obtención de propiedades calculadas, sin que esto implique que sustituyan al registro tomado en campo ni a su interpretación convencional. Algunas de estas metodologías están basadas en el empleo de métodos estadísticos, redes neuronales artificiales o combinaciones de éstas.

Las redes neuronales artificiales o RNA's son “un *modelo computacional* con un conjunto de propiedades específicas, como son la habilidad de adaptarse o aprender, generalizar u organizar la información, todo ello basado en un procesamiento eminentemente paralelo... inspirado en el funcionamiento del cerebro humano” (Gómez, 1999), comúnmente son utilizadas para reconocer patrones, incluyendo imágenes, manuscritos, secuencias de tiempo, tendencias financieras, entre otras; además tienen la capacidad de aprender y mejorar su funcionamiento, es por esto que se ha buscado la forma de aplicar estos modelos matemáticos para la solución de problemas de Geofísica.

Las RNA's son cada vez más utilizadas dentro de la exploración Geofísica, pues hasta 1994 se entrenaban solo con datos sintéticos y se validaban con datos de campo, desde 1995 se han utilizado en áreas como la caracterización de yacimientos, dada su capacidad de resolver problemas que no tienen solución algorítmica o que el algoritmo es demasiado complejo (Van der Baan, et. al., 2000). Dentro de los registros geofísicos, las

redes neuronales, se han aplicado a la predicción de curvas faltantes en los pozos con muy buenos resultados; con el tiempo se ha ido más allá en la búsqueda de nuevas aplicaciones de las RNA's que puedan ayudar a disminuir el tiempo de proceso de los datos, por lo cual se ha buscado no solo hacer la predicción de registros sino además hacer la predicción de propiedades que se obtienen de la interpretación de los mismos (Zhang,1999), como es el caso de la saturación de agua.

## CAPÍTULO 2.

### CONCEPTOS PETROFÍSICOS GENERALES

De acuerdo con la definición tradicional un Registro Geofísico de Pozo es una representación digital o analógica de una propiedad física que se mide contra la profundidad. El registro geofísico representa alguna propiedad física o química de las roca, ya sea la resistencia al paso de la corriente, radiactividad natural, transmisión de ondas acústicas, respuesta de neutrones por efecto de contenido de Hidrógeno, entre otras. El propósito de estos registros es determinar las propiedades petrofísicas, es decir, las propiedades físicas y químicas del sistema roca-fluido del yacimiento.

#### 2.1 Porosidad

La porosidad es la fracción del volumen total de roca ocupada por fluidos (espacio poral); es un valor adimensional con un rango que va de 0 a 1 y así se utiliza en los cálculos, aunque para fines de representación se le suele multiplicar por 100 para expresarlo en unidades de porosidad o pu (“*porosity units*”).

La porosidad se expresa matemáticamente como:

$$\phi = \frac{V_p}{V_t} \quad (\text{ec. 2.1})$$

donde:

$\phi$  es la porosidad

$V_p$  es todo el volumen del espacio poral

$V_t$  es el volumen total de una roca; incluye los sólidos y fluidos.

En formaciones poco consolidadas, la porosidad depende más de la distribución del tamaño de grano que del tamaño absoluto del mismo. La porosidad será alta (en el rango de 0.35 a 0.40) si todos los granos son de tamaño similar; será menor (alrededor de 0.25) si hay una gran variedad de tamaños de grano, ya que los granos pequeños ocuparán el espacio poral entre los granos mayores. Valores de porosidad menores (llegando virtualmente a cero) ocurren cuando las partículas están cementadas entre sí con material silíceo o calcáreo, resultando en formaciones consolidadas y el valor máximo (0.45) se alcanza para granos esféricos y de tamaño uniforme, en un arreglo cúbico.

En la figura 2.1 se muestra un bloque en el cual se supone que toda la porosidad está concentrada en el fondo del mismo, dejando la matriz compacta encima. Por la definición de porosidad, si se elige la escala de manera tal que la altura  $h$  sea una unidad,  $x$  representa la porosidad.




Figura 2.1 En el bloque a) se muestra un esquema de la proporción de la porosidad con respecto a la matriz de la roca. El bloque b) es una porción de roca donde se muestra la distribución de los poros y la matriz, los fluidos se concentran en la parte porosa.

### 2.1.1 Tipos de porosidad definidos para interpretación

Pueden especificarse los siguientes tipos de porosidad:

- a) Porosidad primaria: (intergranular o intercristalina), la porosidad primaria es el espacio dejado entre los sedimentos o los cristales en el momento de la formación de la roca. Se representa por  $\phi_1$ , su valor depende principalmente de la forma, tamaño y clasificación de granos por lo cual es mayor en las rocas clásticas que en los carbonatos.
- b) Porosidad secundaria: es la porosidad que se ha desarrollado después de la formación de la roca, está constituida por porosidad vugular (vacuolar) generada comúnmente por disolución y por la porosidad de fracturas generadas mecánicamente. Se representa por  $\phi_2$ . Esta porosidad es más común en los carbonatos, aunque también se llega a presentar en rocas clásticas.
- c) Porosidad total: representada por  $\phi_t$ , es la relación entre el volumen de todo el espacio poral existente en la roca (poros, fisuras, fracturas, vugulos) y el volumen total de la roca; este parámetro se puede expresar en términos de la porosidad primaria y secundaria como:

$$\phi_t = \phi_1 + \phi_2 \quad (\text{ec. 2.2})$$

- d) Porosidad conectada: representada como  $\phi_{\text{con}}$ , es la porosidad de los poros interconectados en el volumen de la roca. Puede ser mucho menor que la porosidad total, si parte de los poros no están conectados.

- e) Porosidad potencial: representada por  $\phi_{pot}$ , es la porosidad conectada de sección transversal mayor que un valor límite, debajo del cual los fluidos no se desplazan. Esta porosidad puede ser mucho menor que la porosidad conectada como ocurre en las lutitas que generalmente presentan una porosidad conectada bastante alta (0.4 a 0.5 para lutitas compactadas) pero los fluidos no pueden ser desplazados debido a las secciones transversales tan pequeñas, por lo que  $\phi_{pot}$  es prácticamente cero.
- f) Porosidad efectiva: representada por  $\phi_e$ , es la porosidad accesible a los fluidos libres para desplazarse, excluyendo la porosidad no conectada y el espacio ocupado por el agua absorbida e inmovilizada en las lutitas. Esta definición es exclusiva para los intérpretes y se representa como:

$$\phi_e = 1 - V_{sh} \quad (\text{ec. 2.3})$$

### 2.1.2 Procesos que afectan la porosidad

Existen varios procesos que aumentan o disminuyen la porosidad de una roca, entre éstos destacan:

- a) Acomodamiento de los granos: Se refiere al acomodo que sufren las partículas al momento de la depositación, si los granos son esféricos y todos del mismo tamaño habrá más porosidad que si son de diferente tamaño ya que entonces dependerá del grado de llenado y acomodo de éstos.
- b) Cementación: Es el proceso de deposición de componentes minerales disueltos en los intersticios de los sedimentos. Este es un importante factor en la consolidación de los granos en las rocas sedimentarias durante la litificación en los procesos diagenéticos. El cementante puede ser sílice, carbonatos, óxidos de hierro o minerales de arcilla.
- c) Granulación: Es un proceso por el cual los granos son quebrados por presión. En general, aumenta la porosidad debido a que la superficie del grano también se incrementa, reduciendo de esta manera la permeabilidad.
- d) Disolución: Proceso mediante el cuál un mineral o un compuesto reacciona químicamente provocando la disolución de la roca, formando grietas o cavernas de disolución lo cual provoca un aumento en la porosidad de la misma.
- e) Recristalización: La formación de nuevos cristales (neocrystalización) y el crecimiento cristalino (recristalización), permiten el endurecimiento y disminución de la porosidad de los depósitos, por unión de cristales individuales.
- f) Compactación: Cuando un depósito queda enterrado por la acumulación de nuevos materiales depositados, tiene lugar un asentamiento local bajo la carga, con

expulsión del exceso de agua. Finalmente se establece una ligazón entre los granos o se fortalece la que ya existía y el sedimento adquiere un grado apreciable de solidez.

## 2.2 Permeabilidad

Es la medida de la facilidad con la cual los fluidos se desplazan a través de una formación, es decir, se refiere a la facultad que posee la roca para permitir que los fluidos se muevan a través de la red de poros interconectados entre sí a partir de un gradiente de presión especificado. Esta propiedad tiene unidades de darcies, pero debido a que el Darcy es muy grande para los valores que se presentan comúnmente en las rocas, comúnmente se manejan milidarcies. La unidad Darcy ha sido estandarizada por el American Petroleum Institute en términos de unidades cgs como: “un Darcy equivale a uno, cuando un fluido monofásico de un centipoise de viscosidad que llena por completo los huecos del medio, se mueve un centímetro cuadrado de sección transversal, bajo un gradiente de una atmósfera por centímetro”.

La permeabilidad está determinada por el tamaño de las partículas de la roca, así, cuando una roca tiene granos relativamente grandes, sus poros también serán grandes y tendrá un alto valor de permeabilidad; si por el contrario se tiene una roca de grano fino, sus poros serán pequeños y sus valores de permeabilidad también ya que el movimiento del fluido será más tortuoso.

Los métodos para medir la permeabilidad son:

- a) Pruebas de pozo
- b) Pruebas de Producción
- c) Núcleos convencionales

Cuando nos referimos a la permeabilidad de una roca que contiene un solo fluido en los poros se le denomina permeabilidad absoluta, cuando se presentan dos o más fluidos se le llama efectiva y, a la relación que existe entre la efectiva con un fluido específico y la absoluta, se le llama relativa.

## 2.3 Saturación de fluidos

La fracción del espacio poral que contiene agua es denominado “saturación de agua” y representado por  $S_w$ . El valor de  $S_w$  es un número adimensional con valores entre 0 a 1 y, como la porosidad, puede ser representado en porcentaje. La saturación de agua se expresa matemáticamente como:

$$S_w = \frac{V_w}{V_p} \quad (\text{ec. 2.4})$$

donde:

$S_w$  es la parte de la porosidad que contiene agua

$V_w$  es el volumen del espacio poral que está ocupado por agua

$V_p$  es todo el volumen de espacio poral.

La figura 2.2 muestra que el bloque de formación porosa puede contener agua e hidrocarburos y se hace la suposición de que toda el agua está concentrada en el fondo del mismo.




Figura 2.2 Los fluidos están contenidos dentro de los poros, en este caso se esquematizan los fluidos hidrocarburo (gas y/o aceite) y agua, ya que son los de interés.

Cuando todo el espacio poroso está ocupado por agua,  $V_w$  es igual a  $V_p$ , resultando  $S_w=1$ . Cuando parte de la porosidad está ocupada por agua, la otra parte estará ocupada por hidrocarburos. Puede entonces definirse la “saturación de hidrocarburos”, representada por  $S_{hy}$ , como:

$$S_{hy} = \frac{V_{hy}}{V_p} \quad (\text{ec. 2.5})$$

donde:

$S_{hy}$  es la parte de la porosidad que contiene hidrocarburos

$V_{hy}$  es el volumen del espacio poral que está ocupado por hidrocarburos y es igual a  $V_p - V_w$

$V_p$  es todo el volumen del espacio poral

Teniendo en cuenta todas las definiciones anteriores de saturación de agua, hidrocarburos y volumen podemos decir que:

$$S_w + S_{hy} = 1 \quad (\text{ec. 2.6})$$

### 2.3.1 Saturación de agua irreducible

En general se asume que el yacimiento fue generado en un ambiente acuífero y que los hidrocarburos, que fueron generados en la roca madre, migraron dentro del espacio poral, desplazando el agua de los poros mayores, sin embargo, no toda el agua de la roca es desplazada; al agua retenida por tensión superficial alrededor de los granos se le llama agua irreducible.

### 2.3.2 Porosidad con agua y con hidrocarburos

El valor de la “porosidad con agua” se obtiene multiplicando la porosidad efectiva por la saturación de agua en la zona:

$$\phi_w = \phi_e \cdot S_w \quad (\text{ec. 2.7})$$

donde:

$\phi_w$  es la porosidad con agua en la zona virgen

De la misma manera, el valor de la “porosidad con hidrocarburos” se obtiene multiplicando la porosidad efectiva por la saturación de hidrocarburos:

$$\phi_{hy} = \phi_e \cdot S_{hy} = \phi_e \cdot (1 - S_w) \quad (\text{ec. 2.8})$$

### 2.3.3 Perfil de invasión

Cuando el lodo de perforación invade una formación permeable, éste desplaza los fluidos de la formación y se mezcla con el agua de la misma. La invasión altera la distribución de los fluidos alrededor del pozo y subsecuentemente crea zonas donde la distribución de los fluidos (y subsecuentemente las resistividades) difieren de la distribución original dentro de la formación.

En la figura 2.3 se muestra un esquema de la distribución de las zonas que se forman después de que el lodo de perforación se filtra en una formación permeable (en las impermeables no hay invasión).  $x_o$  corresponde a la zona invadida por el lodo que se filtra en la formación ( $m_f$ ), también llamada zona lavada, en ésta zona los fluidos de la formación son desplazados quedando únicamente el lodo filtrado y el fluido irreducible;  $i$  es la zona donde el lodo no alcanzó a desplazar todos los fluidos y como consecuencia se mezcla con ellos, es llamada zona de transición;  $t$  se refiere a la zona no invadida por el lodo o virgen, en ésta los fluidos no se han mezclado o desplazado por el lodo; el enjarre es el lodo que se solidifica en la pared del pozo formando una pequeña capa impermeable que puede ser desprendida al ademar el pozo. Cabe destacar que entre más permeable sea la formación mayor será el perfil de invasión y viceversa; aunque este proceso depende además de otros factores.



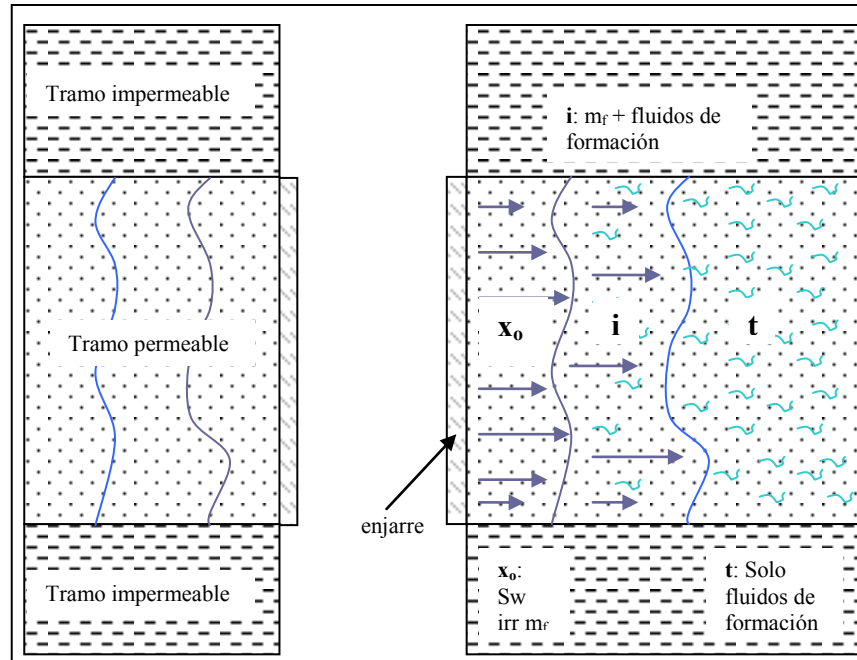


Figura 2.3 Perfil de invasión de un pozo en una formación permeable.

### 2.3.4 Cálculo de $S_w$ por Simandoux modificado

Existen diferentes métodos para hacer el cálculo de la saturación de agua dependiendo de el tipo de formación que tengamos, ya sea arcillosa (volumen de arcilla mayor o igual al 15%) o limpia (volumen de arcilla menor al 15%). Para formaciones limpias el cálculo de saturación de agua se hace por el método de Archie y para arcillosa se utiliza Doble Agua, Indonesia, Simandoux, Simandoux modificado, entre otros.

En los pozos estudiados se interpretó con Simandoux modificado para hacer el cálculo de  $S_w$ .

El método de Simandoux modificado emplea las porosidades de los registros neutrón-densidad y el volumen de arcilla a partir de los registros GR o SP. Es aplicable para arcilla dispersa o laminar ya que considera la arcilla como un medio conductivamente homogéneo. Con este modelo el cálculo de saturación del agua se hace con la ecuación:

$$\frac{1}{R_t} = \frac{V_{sh}^2 \cdot S_w^{n/2}}{R_{sh}} + \frac{\phi_e^m \cdot S_w^n}{a \cdot R_w \cdot (1 - V_{sh})^2} \quad (\text{ec. 2.9})$$

que es la ecuación modificada de Simandoux, donde:

- $S_w$  saturación de agua
- $V_{sh}$  volumen de arcilla
- $R_t$  resistividad de la formación
- $R_{sh}$  resistividad de la arcilla
- $R_w$  resistividad del agua de formación

- m factor de cementación
- a factor de tortuosidad
- $\phi_e$  porosidad efectiva
- n exponente de saturación de agua (se considera igual a 2)

Despejando  $S_w$  de la ecuación anterior queda:

$$S_w = \frac{-\frac{V_{sh}}{R_{sh}} + \sqrt{\left(\frac{V_{sh}}{R_{sh}}\right)^{2.0} - 4.0 \frac{\phi_e^m}{a R_w} \left(-\frac{1.0}{R_t}\right)}}{2 \left(\frac{\phi_e^m}{a R_w}\right)}; 0.0 \leq S_w \leq 1.0 \text{ (Mera, 2005) (ec. 2.10)}$$

$R_{sh}$  se lee del registro de resistividad profunda en la zona de lutitas.

$R_t$  se lee del registro de resistividad profunda; en el punto de cálculo, corregida por invasión.

Los factores  $m$  y  $a$  son difíciles de determinar ya que  $a$  varía principalmente con la geometría del poro y  $m$  con el grado de consolidación (Timur, 1972); por esta razón y gracias a los experimentos de Winsauer y Carothers, los valores de  $m$  y  $a$  se consideran como:

	Arenas (Winsauer, 1952)	Carbonatos (Carothers, 1968)
$a$	0.62	1.0
$m$	2.15	2.0

Fórmulas para la obtención de los parámetros:

El  $V_{sh}$  se calcula por medio de la fórmula de Larionov para rocas antiguas (anteriores a las terciarias) y se expresa como sigue:

$$V_{sh} = 0.33(2^{2I_{sh}} - 1) \quad \text{(ec. 2.11)}$$

donde  $I_{sh}$  es el índice de arcillosidad calculado, para nuestro caso, del registro GR como:

$$I_{sh} = \frac{\gamma_{log} - \gamma_{min}}{\gamma_{sh} - \gamma_{min}} \quad \text{(ec. 2.12)}$$

$\gamma_{log}$  es la lectura del registro en el punto que se quiere calcular,  $\gamma_{sh}$  es el valor de rayos gamma para la arcilla y  $\gamma_{min}$  es el valor mínimo de rayos gamma.

La porosidad efectiva se calcula con la fórmula:

$$\phi_e = \sqrt{\frac{(\phi_{dc})^2 + (\phi_{nc})^2}{2}} \text{ (Arroyo, 1996) \quad (ec. 2.13)}$$

donde  $\phi_{dc}$  es la porosidad densidad y  $\phi_{nc}$  es la porosidad neutrón ambas corregidas por arcilla, lo cuál se hace por medio de las siguientes relaciones:

$$\phi_{dc} = \phi_d - V_{sh} \cdot \phi_{dsh} \quad (\text{ec. 2.14})$$

$$\phi_{nc} = \phi_n - V_{sh} \cdot \phi_{nsh} \quad (\text{ec. 2.15})$$

Para obtener  $R_w$  primero se tiene que calcular la resistividad del agua equivalente  $R_{we}$  con la ecuación:

$$R_{we} = \frac{R_{mfe}}{10^{\frac{-SSP}{K}}} \quad (\text{ec. 2.16})$$

$R_{mfe}$  es la resistividad del lodo filtrado equivalente; en la cual se considera que:

Sí  $R_{mf} > 0.1 \Omega\text{m}$ ,  $R_{mf} = R_{mfe}$ ;

Sí  $R_{mf} \leq 0.1 \Omega\text{m}$ ,  $R_{mfe}$  se calcula gráficamente.

SSP es la lectura de máxima deflexión del registro de Potencial Espontáneo (SP), en miliVolts, corregida por espesor de capa y por diámetro de invasión.

K es un coeficiente que depende de la temperatura, tiene unidades de miliVolts y se obtiene como:

$K = 65.5 + 0.24T$  , si la temperatura (T) está dada en grados Celsius y,

$K = 61.3 + 0.133T$  , si la temperatura (T) está dada en grados Fahrenheit.

Una vez que se calcula  $R_{we}$ , por medio de gráficas se obtiene el valor de  $R_w$ .

Es necesario destacar que para hacer el cálculo de  $S_w$  por Simandoux modificado es necesario tener *cuando menos* los registros SP, GR, Resistividad profunda y dos registros de porosidad.

## CAPÍTULO 3.

### FUNDAMENTOS DE LAS REDES NEURONALES ARTIFICIALES

Las redes neuronales artificiales (RNA) son modelos computacionales que simulan las propiedades observadas en los sistemas neuronales biológicos (como la capacidad de aprendizaje, organización, reconocimiento, procesamiento y reproducción de información) a través de modelos matemáticos recreados mediante mecanismos artificiales cuya unidad básica de procesamiento esta inspirada en la neurona, la cual es la célula fundamental del sistema nervioso humano. Con esto se tiene como objetivo conseguir que las máquinas den respuestas similares a las que daría el cerebro.

Una RNA esta compuesta por elementos simples (usualmente adaptativos) interconectados masivamente en paralelo y con organización jerárquica, de los cuales se pretende que interactúen con los objetos del mundo real del mismo modo que lo haría el sistema nervioso biológico. Este tipo de redes son una de las alternativas más usadas cuando se tienen problemas que no tienen soluciones que respondan a fórmulas o probabilidades o bien que la programación de estas sea demasiado compleja.

#### 3.1 Historia de las Redes Neuronales Artificiales

La construcción y el diseño de máquinas inteligentes ha sido uno de los principales objetivos científicos a lo largo de la historia. En la actualidad se han desarrollado sistemas capaces de realizar procesos similares a las funciones inteligentes del ser humano, estos sistemas se encuadran dentro de la llamada Inteligencia Artificial (IA). No se trata de construir máquinas que compitan con los seres humanos, sino que realicen ciertas tareas con rango intelectual con que ayudarle, de ahí la importancia de la IA.

Las primeras explicaciones teóricas sobre el cerebro y el pensamiento fueron dadas por Platón (427-347 a.C.) y Aristóteles (422-346 a.C.). Estas ideas las mantuvo Descartes (1569-1650) y los filósofos empiristas del siglo XVIII.

Herón (100 a.C.) construyó un autómatas hidráulico.

Alan Turing (1936) Fue el primero en estudiar el cerebro como una forma de ver el mundo de la computación.

Warren McCulloch y Walter Pitts (1943) lanzaron una teoría acerca de la forma de trabajar de las neuronas, concibieron los fundamentos de la computación neuronal y modelaron una red neuronal simple mediante circuitos eléctricos.

Donald Hebb (1949) escribió el libro “La organización del comportamiento” en este se establece una conexión entre la Psicología y la Fisiología. Hebb fue el primero en explicar los procesos de aprendizaje (que es el elemento básico de la inteligencia humana) desde un punto de vista psicológico. Su idea fue que el aprendizaje ocurría cuando ciertos cambios en una neurona eran activados. Los trabajos de Hebb forman las bases de la Teoría de las Redes Neuronales.

Karl Lashley (1950) En sus series de ensayos, encontró que la información no era almacenada en forma centralizada en el cerebro sino que era distribuida encima de él.

Frank Rosenblatt (1957) Comenzó el desarrollo del Perceptrón. Esta es la red neuronal más antigua, aunque se sigue utilizando como reconocedor de patrones. Este modelo era capaz de generalizar, es decir, después de haber aprendido una serie de patrones podía reconocer otros similares, aunque no se le hubiesen presentado anteriormente. Sin embargo tenía una serie de limitaciones, por ejemplo, su incapacidad de clasificar clases no separables linealmente. En 1959, escribió el libro Principios de Neurodinámica, en el que confirmó que, bajo ciertas condiciones, el aprendizaje del Perceptrón convergía hacia un estado finito (Teorema de Convergencia del Perceptron).

Bernard Widrow/ Marcial Hoff (1960) desarrollaron el modelo Adaline (ADAPtative LINear Elements). Esta fue la primera red neuronal aplicada a un problema real (filtros adaptativos para eliminar ecos en líneas telefónicas) que se ha utilizado comercialmente durante varias décadas.

Marvin Minsky/ Seymour Papert (1969), ambos pertenecientes al Instituto Tecnológico de Massachussets (MIT), publicaron el libro “Perceptrons”, en él demostraron matemáticamente que el Perceptrón no era capaz de aprender una función no lineal. Esto demostró que el Perceptrón era muy débil, ya que las funciones no lineales son ampliamente utilizadas en computación. A pesar del libro, algunos investigadores continuaron su trabajo, pero en general el crecimiento de las redes se detuvo hasta 1982.

James Anderson ideó y aplicó un modelo lineal, llamado Asociador Lineal, que se basa en el principio de que las neuronas son reforzadas cada vez que son activadas.

Paul Werbos (1974) desarrolló la idea básica del algoritmo de propagación hacia atrás (backpropagation).

Stephen Grossberg (1977) estableció la Teoría de Resonancia Adaptativa (ART por sus siglas en inglés) por medio de la cual la arquitectura de la red puede simular habilidades del cerebro como la memoria a corto y a largo plazo.

Teuvo Kohonen (1977) creó un modelo similar al de Anderson pero independientemente llamados mapas auto-organizados por su capacidad de aprender sin necesidad de enseñarle cuál es la salida deseada.

Kunihiko Fukushima (1980) desarrolló un modelo neuronal para el reconocimiento de patrones visuales.

John Hopfield (1985) provocó el renacimiento de las redes neuronales con su libro "Computación Neuronal de Decisiones en Problemas de Optimización".

David Rumelhart/G. Hinton (1986) redescubrieron el algoritmo de aprendizaje de backpropagation. A partir de 1986 se reanudaron las investigaciones y el desarrollo de las redes neuronales. En la actualidad se siguen haciendo mejoras encontrando nuevas aplicaciones con estos algoritmos.

1988- 2002 se publicaron más de 550 artículos sobre la aplicación de redes neuronales a cualquier aspecto de la Geofísica. La aplicación de las redes neuronales a la exploración Geofísica se puede dividir en dos eras. En la primera se enfocó en estudiar el modo en que las redes aprendían, se entrenaban con datos sintéticos y se validaban con datos reales. La segunda, que comenzó en 1995 al presente, se ha enfocado en la aplicación a áreas específicas como la caracterización de yacimientos.

### **3.2 Redes neuronales biológicas**

Se estima que el cerebro humano contiene más de cien mil millones de neuronas. Es por medio de las neuronas y las conexiones entre ellas, llamadas sinapsis, que se lleva a cabo el procesamiento de la información.

Algunos elementos a destacar de la estructura histológica son:

- a) Las dendritas: Son la vía de entrada de las señales que se combinan en el cuerpo de la neurona y a partir de ellas elabora una salida.
- b) El axón: Es el camino de salida de la señal generada por la neurona. Su función es transmitir una señal electroquímica a otras neuronas.
- c) Las sinapsis: Son uniones especializadas mediante las cuales las células del sistema

nervioso envían señales de unas a otras, estas permiten a las neuronas del sistema nervioso central formar una red de circuitos neuronales. Son cruciales para los procesos biológicos que subyacen bajo la percepción y el pensamiento (Figura 3.1).

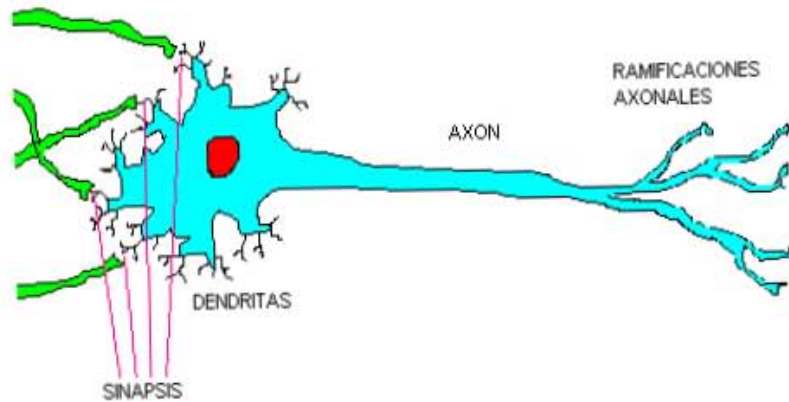


Figura 3.1 Elementos de una neurona biológica.

Lo que ocurre, básicamente, en una neurona biológica es: la neurona es estimulada o excitada a través de sus entradas y, cuando alcanza un cierto umbral, la neurona se dispara o activa, pasando una señal hacia el axón. El axón lleva la información por medio de diferencias de potencial u ondas de corriente que dependen del potencial de la neurona. La neurona recoge las señales por su sinapsis sumando todas las influencias excitadoras o inhibitoras. Si dominan las influencias positivas, la neurona da una señal positiva y manda este mensaje a otras neuronas por medio de las sinapsis de salida.

### 3.3 Elementos de una red neuronal artificial

Una red neuronal artificial se compone de unidades llamadas neuronas. Las neuronas se modelan mediante unidades de proceso. Se componen de un núcleo encargado de los cálculos, una red o vector de conexiones de entrada y una salida. Tal como sucede en el cerebro, a partir de las neuronas se pueden generar representaciones específicas, de tal forma que un estado conjunto de ellas puede significar una letra, un número o cualquier otro objeto. El aprendizaje de estas se produce mediante la variación de la efectividad de la sinapsis, de esta manera cambia la influencia que ejercen unas neuronas sobre otras. Las RNA se dividen en tres partes principales o capas, cada capa esta compuesta de un número de neuronas y dicho número puede variar de una capa a otra.

A las capas que reciben estímulos externos, es decir, que toman la información de entrada para su posterior procesamiento, se les llama “de entrada”.

La información recibida se transmite a los elementos internos que se ocupan de su procesamiento. En este segundo nivel es donde se genera la representación interna de la información, se aprende y/o se procesa. Al no tener relación directa con la información de entrada ni con la de salida se denominan “capas ocultas”. En una red neuronal se pueden tener una o varias capas ocultas.

Una vez que se ha aprendido y/o procesado la información, esta llega a la capa de salida, cuya finalidad es dar la respuesta del sistema, al exterior (interfaz grafica, numérica, etc.), de acuerdo a las entradas que le fueron asignadas.

Cabe mencionar que la información que posee cada neurona es transmitida a todas las neuronas de la siguiente capa (excepto en la capa de salida) y, a su vez, las neuronas de la siguiente capa reciben información de todas las neuronas de la capa anterior (excepto en la capa de entrada).

En la figura 3.2 se muestra el acomodo de las capas en una RNA y como viaja la información a través de ellas.

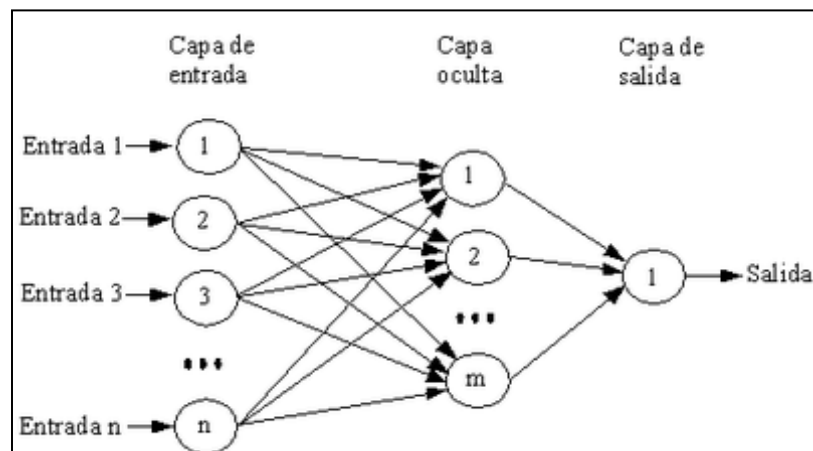


Figura 3.2 Elementos de una red neuronal artificial.

### 3.4 Funcionamiento

Las neuronas artificiales pretenden simular, de manera simple, las características más importantes de las neuronas biológicas, como la forma en que reciben la información, la procesan y la transmiten a otras neuronas. Cada neurona esta caracterizada en cualquier instante por un valor numérico denominado valor o estado de activación  $a_i(t)$  asociado a cada unidad, existe una función de salida,  $f_i$ , que transforma el estado actual de activación en una señal de salida. Dicha señal es enviada a través de los canales de comunicación unidireccionales a otras unidades de la red; en estos canales se modifica la señal de acuerdo al peso,  $w_{ji}$ , asociado a cada uno de ellos (sinapsis). Las señales moduladas que



llegan a la unidad  $j$ -ésima se combinan entre ellas, generando así la entrada total de la red,  $Net_j$ .

$$net_j = \sum y_i w_{ji} \quad (\text{ec. 3.1})$$

Cada neurona recibe una serie de entradas a través de interconexiones y emite una salida que esta dada por dos funciones:

- a) Una función de propagación (también conocida como función de excitación), esta función calcula la entrada total a la unidad mediante la sumatoria de cada entrada multiplicada por el peso de su interconexión. Si el peso es positivo, la conexión se denomina excitatoria; si es negativo, se denomina inhibitoria.

Los pesos de las interconexiones o conexiones ponderadas, hacen el papel de las conexiones sinápticas, el peso de la conexión equivale a la fuerza o efectividad de la sinapsis. La existencia de las conexiones determina si es posible que una unidad de proceso (neurona) influya sobre otra, el valor de los pesos y el signo de los mismos definen el tipo (excitatorio/inhibitorio) y la intensidad de la influencia. Normalmente se considera que el efecto de cada señal es aditivo, de tal forma que la entrada neta que recibe la neurona  $net_j$ , es la suma de cada señal individual por el valor de la sinapsis que conecta ambas neuronas:

$$net_j = \sum_i^N w_{ji} * y_i \quad (\text{ec. 3.2})$$

- b) Una función de activación, se encarga de calcular el nivel o estado de activación de la neurona en función de la entrada total. Una función de activación,  $F$ , determina el nuevo estado de activación  $a_j(t+1)$  de la neurona, teniendo en cuenta la entrada total calculada y el anterior estado de activación. Las funciones de activación son de gran importancia para el funcionamiento de la neurona y de la red en general por lo cual serán explicadas mas ampliamente en el siguiente tema (3.5)

### 3.5 Funciones de activación

Para que una red funcione se requiere una regla que combine las entradas con el estado actual de la neurona para producir un nuevo estado de activación. Esta función  $F$  produce un nuevo estado de activación en la neurona a partir del estado ( $a_i$ ) que existía y la combinación de las entradas con los pesos de las conexiones ( $net_i$ ).

Dado el estado de activación  $a_i(t)$  de la unidad  $U_i$  y la entrada total que llega,  $Net_i$ , el estado de activación siguiente,  $a_i(t+1)$ , se obtiene aplicando una función F, llamada *Función de activación*.

$$a_i(t+1) = F(a_i(t), Net_i) \quad (\text{ec. 3.3})$$

La función de activación no siempre esta centrada en el origen del eje, sino que existe cierto desplazamiento debido a las características internas de la neurona y que no es igual en todas ellas. Este valor se denota como  $\theta_i$  y representa el umbral de activación de la neurona i.

A continuación se mencionan las funciones de activación usadas con mayor frecuencia en las redes neuronales artificiales:

a) Función de activación escalón

Si el conjunto de estados de activación esta dado por  $E=\{0,1\}$ , la función estará dada por:

$$y_i(t+1) = \begin{cases} 1 & \text{si } [Net_i > \theta_i] \\ y(t) & \text{si } [Net_i = \theta_i] \\ 0 & \text{si } [Net_i < \theta_i] \end{cases} \quad (\text{ec. 3.4})$$

y su representación será como la que se muestra en la figura 3.3.

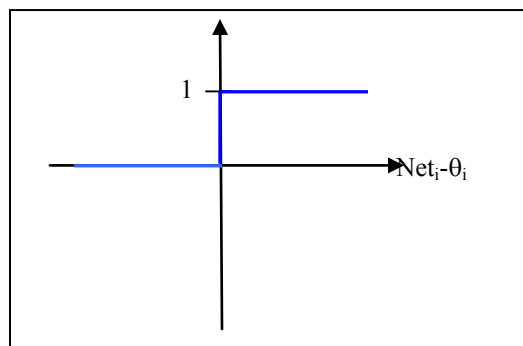


Figura 3.3 Función de activación escalón .

Si el conjunto esta dado por  $E=\{-1,1\}$ , entonces la función será:

$$y_i(t+1) = \begin{cases} 1 & \text{si } Net_i \geq \theta_i \\ -1 & \text{si } Net_i < \theta_i \end{cases} \quad (\text{ec. 3.5})$$

y su gráfica será como la que se muestra en la figura 3.4.




Figura 3.4 Función de activación escalón.

b) Función de activación lineal o identidad

El conjunto de estados E puede contener cualquier número real; cuando el estado de activación coincide con la entrada total que ha llegado a la unidad, es decir,  $y_i(t+1) = Net_i - \theta_i$ , y cuya representación gráfica es la siguiente:




Figura 3.5 Función de activación lineal o identidad

c) Función de activación lineal mixta

Con esta función, el estado de activación de la unidad está obligado a permanecer dentro de un intervalo de valores reales prefijados. Para lograr esto la función tiene la forma

$$y_i(t+1) = \begin{cases} \infty & [Net_i - \theta_i < -b] \\ Net_i - \theta_i & [b + \theta_i < Net_i < B + \theta_i] \\ B & [Net_i \geq B] \end{cases}, \quad (\text{ec. 3.6})$$

y su representación gráfica es como la que se muestra en la figura 3.6




Figura 3.6 Función de activación lineal mixta.

d) Función de activación sigmoideal

Es una función continua, por lo tanto el espacio de los estados de activación es un intervalo del eje real. Esta función de activación está dada por:

$$y_i(t+1) = \frac{1}{(1 + e^{-(Net_i - \theta_i)})}, \text{ su gráfica toma la forma que se presenta en la figura 3.7}$$




Figura 3.7 Función de activación sigmoideal.

Para simplificar la expresión de la salida de la neurona  $i$ , es habitual considerar la existencia de una neurona ficticia, con valor de salida igual a la unidad, asociada a la entrada de cada neurona  $i$  mediante una conexión con peso de valor  $-\theta_i$ . De esta forma la expresión de salida será:

$$y_i(t+1) = f\left(\sum_{j=1}^N w_{ij} y_j(t) - \theta_i * 1\right) = f\left(\sum_{j=1}^N w_{ij} y_j(t)\right) = f(\text{Net}_i) \quad (\text{ec. 3.7})$$

### 3.6 Funciones de salida

Asociada a cada neurona  $U_i$  hay una función de salida  $f_i(a_i(t))$ , que transforma el estado actual de activación en una señal de salida:  $y_i(t) = f_i(a_i(t))$ .

Existen cuatro funciones de transferencia típicas que determinan distintos tipos de neuronas:

#### a) Neurona de función escalón

La función escalón se asocia a neuronas binarias en las cuales cuando la suma de las entradas es mayor o igual a cierto umbral de la neurona la activación es 1 y, si es menor, la activación es 0 (o menos 1). La función escalón únicamente se utiliza cuando las salidas de la red son binarias. La salida de una neurona se activa solo cuando el estado de activación es mayor o igual a cierto umbral. La función lineal o identidad equivale a no aplicar función de salida. Las funciones mixtas y sigmoideal son las más apropiadas cuando queremos como salida información “analógica”. Las redes formadas por este tipo de neuronas son fáciles de implementar en hardware, pero sus capacidades son limitadas.

#### b) Neurona de función lineal o mixta

La función lineal o mixta corresponde a la función  $F(x)=x$ . En las neuronas con función mixta si la suma de las señales de entrada es menor que un límite inferior, la activación se define como 0 (ó -1). Si dicha suma es mayor o igual que el límite superior, entonces la activación es 1. Si la suma de entrada esta comprendida entre ambos límites, la activación se define como una función lineal de suma de las señales de entrada.

c) Neurona de función continua (sigmoideal)

Cualquier función definida simplemente en un intervalo de posibles valores de entrada, con un incremento monótonico y que tengan ambos límites superiores e inferiores (por ejemplo la función sigmoideal y arco tangente), podrá realizar la función de activación o transferencia.

Con la función sigmoideal, para la mayoría de los valores del estímulo de entrada, el valor dado por la función es cercano a uno de los valores asintóticos. Esto hace posible que, en la mayoría de los casos, el valor de salida este comprendido en la zona alta o baja del sigmoide. Cuando la pendiente es muy elevada, la función sigmoide tiende a la función escalón. La importancia de esta función radica en que es continua, tiene derivada en todo el intervalo y su derivada es cercana a cero para valores altos tanto positivos como negativos; además toma su valor máximo cuando  $x$  es cero. Esto hace que se puedan utilizar las reglas de aprendizaje definidas para la función escalón, con la ventaja respecto a esta función, que la derivada esta definida en todo el intervalo.

d) Neurona de función de transferencia gaussiana

Los centros y anchura de estas funciones pueden ser adaptados, lo cual las hace mas adaptativas que las funciones sigmoideales.

### 3.7 Formas de conexión

La conectividad entre nodos de una RNA esta relacionada con la forma en que las salidas de las neuronas están canalizadas para convertirse en entradas de otras neuronas.

Cuando ninguna salida de las neuronas es entrada de neuronas del mismo nivel o de niveles precedentes, la red se describe como propagación hacia adelante o *feedforward* (Figura 3.8).




Figura 3.8 Conexiones hacia delante.

Cuando las salidas pueden estar conectadas a las salidas como a las entradas de neuronas de niveles previos, la red es de propagación hacia atrás o *feedback* (Figura 3.9).




Figura 3.9 Conexiones hacia atrás.

Cuando las redes de propagación hacia atrás dan además información a neuronas de la misma capa se llaman sistemas recurrentes y cuando la señal de salida de un nodo puede ser una entrada de otro elemento de proceso, o incluso de si mismo se les llama conexiones auto-recurrentes (Figura 3.10).




Figura 3.10 Conexiones auto-recurrentes.

### 3.8 Clasificación de las redes neuronales

Según sus características más notables, las redes neuronales se pueden clasificar con dos criterios:

#### 3.8.1 Clasificación según su topología o estructura de la red

La topología de una red consiste en la organización de las neuronas de la red formando capas o agrupaciones de neuronas más o menos alejadas de la entrada y la salida de la red. Los parámetros fundamentales de la red son: el número de capas, el número de neuronas por capa, el grado de conectividad y el tipo de conexiones entre las neuronas. Esta clasificación esta basada en función del patrón de conexiones que presenta, en esto términos podemos clasificar a las redes: en redes de una sola capa y las redes con capas múltiples capas o multicapa.

- a) Redes monocapa. las redes monocapa son redes que, como su nombre o dice, poseen una sola capa. Las redes más representativas son la red de Hopfield, la red memoria asociativa y las máquinas estocásticas de Botzman y Cauchy. Entre las redes neuronales monocapa, existen algunas que permiten que las neuronas tengan conexiones auto-recurrentes. Las redes monocapa se utilizan en tareas relacionadas con la auto-asociación, por ejemplo para regenerar informaciones de entrada que se presentan distorsionadas o incompletas: también han sido utilizadas en circuitos eléctricos por su facilidad para ser implementadas mediante hardware.
- b) Redes multicapa. Son aquellas que disponen de neuronas agrupadas en varias capas. Dentro de las redes multicapa están aquellas que tienen conexiones hacia adelante (*feedforward*) y hacia atrás (*feedback*).
  - i) Redes con conexiones hacia adelante. Las señales se propagan hacia adelante a través de las capas de la red. No existen conexiones hacia atrás y tampoco auto-recurrentes. Las redes *feedforward* mas conocidas son: Perceptrón, Adaline, Madaline, *Linear Adaptive Memory*, *Backpropagation*.
  - ii) Redes con conexiones hacia adelante y hacia atrás (*feedforward/feedback*). En estas redes el flujo de información circula tanto hacia adelante como hacia atrás durante el funcionamiento de la misma. Algunas redes tienen un funcionamiento basado en la resonancia en la cual la información de las neuronas de la primera y segunda capa interactúa hasta que se alcanza un estado estable. Las redes que más conocidas que trabajan bajo este esquema son la red ART (*Adaptive*



Resonate Theory) y la red BAM (Bidirectional Associative Memory).

### 3.8.2 Clasificación según su mecanismo de aprendizaje

El aprendizaje de una red neuronal es el proceso de presentar los patrones a aprender a la red y el cambio de los pesos de las conexiones sinápticas usando una regla de aprendizaje. La regla de aprendizaje consiste en algoritmos basados en formulas matemáticas que modifican el valor de los pesos sinápticos en función de las entradas disponibles para optimizar la respuesta de la red. En el mecanismo de aprendizaje es importante conocer como se modifican los valores de los pesos, o sea, cuales son los criterios para cambiar el valor asignado a las conexiones cuando se pretende que la red aprenda una nueva información, estos criterios determinan la regla de aprendizaje. Se suelen considerar tres tipos de reglas de aprendizaje, las que corresponden a lo que se conoce como aprendizaje supervisado, aprendizaje no supervisado y aprendizaje híbrido.

- a) Redes con aprendizaje supervisado: Se le llama supervisado al tipo de aprendizaje en el cual la red necesita un conjunto de datos de entrada previamente clasificado o cuya respuesta objetivo se conoce.

En este tipo de redes se consideran dos tipos de aprendizaje:

- i) Aprendizaje por corrección de error: consiste en ajustar los pesos de las conexiones de la red en función de la diferencia entre los valores deseados y los obtenidos en la salida de la red, es decir, en función del error cometido en la salida. Dentro de esta clasificación se encuentran redes como el Perceptrón Simple, el Perceptrón Multicapa y la *Backpropagation* de la cual se hablará mas adelante.
  - ii) Aprendizaje estocástico: este tipo de aprendizaje consiste en realizar cambios aleatorios en los valores de los pesos de las conexiones de la red y evaluar su efecto a partir del objetivo deseado y de distribuciones de probabilidad. A este tipo de redes pertenecen la Máquina de Boltzman y la Máquina de Cauchy.
- b) Redes con aprendizaje no supervisado: Este tipo de aprendizaje no necesita patrones objetivo con los cuales comparar la salida, ya que el algoritmo y la regla de modificación de las conexiones producen patrones de salida consistentes, es decir, si la red procesa patrones con un alto grado de similitud, dará la misma salida para ambos por medio de una clasificación de los patrones en categorías. Se puede decir que la red mide cuanto se parecen el patrón de entrada y los ya almacenados y, de acuerdo a ello, los agrupa en una categoría determinada. Entre

las redes que utilizan el aprendizaje no supervisado podemos distinguir aquellas que utilizan el aprendizaje por componentes principales y el aprendizaje competitivo.

- i) Aprendizaje por componentes principales: Se basa en encontrar las características principales (componentes) que son comunes en todos o la mayoría de los patrones de entrada, esto se consigue por medio de un reducido número de neuronas que tratan de representar el patrón de entrada.
- ii) Aprendizaje competitivo: En este tipo de aprendizaje las neuronas “compiten” entre si para representar un patrón de entrada. La neurona seleccionada es aquella cuyos pesos incidentes se asemejan más al patrón de entrada. Una vez que se ha seleccionado la neurona ganadora, la red aprenderá reforzando las conexiones de esta neurona y debilitando las otras con la finalidad de que los pesos de la ganadora se asemejen cada vez más al patrón de entrada. Dentro de esta clasificación destacan las redes ART (Adaptative Resonance Theory).
- c) Aprendizaje híbrido o por refuerzo: Se basa en la idea de no disponer de un ejemplo completo del comportamiento deseado, es decir, de no indicar durante el entrenamiento cual es la salida que se desea; en este caso la función del supervisor es indicar si la salida obtenida se aproxima a la deseada, esto lo consigue mediante una función de éxito y fracaso, en la cual éxito=1 y fracaso=-1, y de acuerdo al resultado se ajustan los pesos basándose en un mecanismo de probabilidades. Un ejemplo de red que utiliza este tipo de aprendizaje es la red llamada Adaptative Heuristic Critic.

### 3.9 Tasa de aprendizaje ( $\eta$ )

Un factor muy importante en el entrenamiento de una RNA es la selección de la tasa de aprendizaje o control de convergencia, la cual comúnmente se representa con la letra  $\eta$ . La correcta selección de esta tasa depende tanto del problema que se esté tratando de resolver como de la arquitectura de la red, sin embargo no es un problema trivial ya que, si seleccionamos un valor alto de  $\eta$  la red aprenderá y convergerá más rápidamente pero podría alejarnos de los valores óptimos de los pesos de ésta. Si, al contrario, escogemos valores muy pequeños encontraremos los valores ideales pero la red tardará demasiado en aprender y en converger.

No existe una fórmula para determinar el valor óptimo de  $\eta$ , sin embargo una aproximación aceptable que asegura la convergencia durante el proceso de aprendizaje

está dada por:

$$\frac{0 < \eta < 2}{\text{número de neuronas de la capa anterior}}$$

### 3.10 Red propagación hacia atrás (*Red Backpropagation*)

En una red *backpropagation* existe una capa de entrada con  $n$  neuronas, una capa de salida con  $m$  y por lo menos una capa de neuronas oculta. Cada una de las neuronas de cada capa de la red, recibe información de todas las neuronas de la capa anterior, excepto las neuronas de la capa de entrada, y transmite su salida a todas las neuronas de la capa posterior, excepto las neuronas de salida.

El funcionamiento de la red *backpropagation* (BPN) consiste en el aprendizaje de un conjunto predefinido de pares de entradas-salidas dados, para que esto suceda el algoritmo esta dividido en fases:

- a) Durante la primera fase el patrón de entrada es presentado a la red y propagado a través de las capas hasta llegar a la capa de salida.
- b) Una vez que se obtuvieron los valores de salida de la red se comparan estos valores con la salida esperada y se obtiene un error, entonces comienza la segunda fase.
- c) En esta fase se ajustan los pesos de la última capa proporcionalmente al error, se pasa a la capa anterior con una retropropagación (*backpropagation*) del error ajustando los pesos y así sucesivamente hasta llegar a la primera capa.
- d) Basándose en el valor de error recibido, se reajustan los pesos de la conexión de cada neurona de modo que cuando se vuelva a presentar el mismo patrón, la salida sea más cercana a la deseada.
- e) Una vez que se han modificado los pesos de las conexiones de la red y los errores se han estabilizado se puede asumir que la red está entrenada.

Es importante destacar que el hecho de que los errores se propaguen de la capa final hacia las intermedias, no implica que las neuronas de la red *backpropagation* sean

“feedback” o que tenga conexiones laterales, lo que la red hace es convertir las salidas en entradas y de esta manera propagarlas hacia delante.

La técnica *Backpropagation* requiere el uso de neuronas cuya función de activación sea continua y diferenciable, por lo cual la función típicamente utilizada para este tipo de redes es la tipo sigmoideal como la que se muestra en la fig. 3.7.

La importancia de la *backpropagation* radica en su capacidad de autoadaptar los pesos de las neuronas de las capas intermedias para aprender la relación que existe entre un conjunto de patrones de entrada y sus salidas correspondientes. Otra ventaja que ofrece la red es su capacidad de *generalización* que es la capacidad de dar respuestas satisfactorias a entradas que el sistema no ha visto antes, para que esto suceda la red debe de encontrar una representación interna que le permita generar las salidas deseadas cuando se le dan entradas de entrenamiento, y que además pueda generar dichas salidas con entradas no presentadas en el aprendizaje.

## **CAPÍTULO 4.**

### **METODOLOGÍA PARA LA APLICACIÓN DE UNA RNA**

La predicción de una curva de registros geofísicos de pozo por medio de RNA's fue propuesta originalmente para reconstruir curvas donde el registro venía dañado o no existía. Conforme se ha ido avanzando en el estudio de las redes se han tratado de reconstruir no solo los registros convencionales, sino que también se ha implementado la metodología en la predicción de propiedades petrofísicas. Todos los procesos de tratamiento de información, incluyendo las redes neuronales, requieren una metodología básica a seguir para, de este modo, optimizar el tiempo y calidad del procesado.

Para la hacer la predicción de una curva de registro por medio de RNA's se sugieren los siguientes pasos:

- Recopilación de información
- Correlación de eventos
- Análisis de calidad y depuración de registros
- Selección de registros
- Normalización
- Entrenamiento de la RNA
- Validación de los entrenamientos
- Predicción

#### **4.1 Recopilación de información**

La etapa de recopilación consiste en obtener la mayor cantidad de información posible, referente al tema en cuestión. Para este caso la información con la que es deseable contar es:

- Registros geofísicos de pozo: los registros de pozo son básicos, en este caso, ya que éstos son los datos que serán ingresados a la RNA tanto para el entrenamiento como para las validaciones y predicciones.
- Información geológica: esta dará un panorama general del contexto estratigráfico y estructural en el que nos encontramos, así como información base para entender el comportamiento de los registros.
- Interpretación Petrofísica: la interpretación Petrofísica es necesaria cuando la aplicación de una RNA va enfocada a la estimación de una propiedad calculada, como puede ser la permeabilidad, saturación de agua, volúmenes, entre otras.
- Trabajos previos en general: estos ayudarán a conocer las características del campo y/o del método que se está empleando, también a obtener un panorama sobre si la

metodología es aplicable y a que pozos, así como algunas consideraciones que será necesario tomar en cuenta durante el desarrollo del entrenamiento.

- Datos de núcleos: estos son útiles para calibrar los registros, entrenamientos y validaciones.

Es importante mencionar que esta búsqueda es un proceso constante ya que, conforme se avanza en el desarrollo del trabajo aparecen nuevas incógnitas que necesitan ser resueltas.

## **4.2 Correlación de eventos**

Para realizar la correlación es necesario graficar los registros y buscar los eventos más destacados en el intervalo de interés con éstas gráficas, esto brinda una visión muy clara de que curvas reproducen mejor los eventos buscados, que tan desfasados están en profundidad, en valores y la respuesta de cada curva y de cada pozo a los eventos de interés, si no hay ninguna correlación, se presentan desfasamientos muy grandes debidos a fallas o a algún otro evento geológico, es mejor no aplicar la red ya que no hay una buena correlación y no habrá una buena respuesta por parte de ésta.

También es de utilidad hacer gráficas cruzadas (crossplots) de las curvas entre los diferentes pozos para ver la similitud de las respuestas entre ellos; esto dará una aproximación de que pozos se correlacionan mejor entre sí.

## **4.3 Control de calidad (LQC) y depuración de registros geofísicos**

El control de calidad se hace con la finalidad de conocer las condiciones en las que viene la información y si sirve o no para los fines establecidos. Aquí se busca principalmente en qué zonas hay desplazamientos, derrumbes o ausencia de datos debida a que la herramienta no midió, presencia de datos incoherentes, etc.

### **4.3.1 Revisión de encabezados**

Para realizar el LQC lo primero que se hace es revisar que la información de los encabezados sea coherente con el contenido de los registros, es decir, que cuente con los nombres de los registros, las herramientas con las que fueron adquiridos, la profundidad de éstos, etc.

### **4.3.2 Curvas contenidas**

Es conveniente hacer una lista con las curvas que contiene cada pozo. Después de eso se buscan las curvas que se tengan en común en los pozos que se van a analizar (hay que recordar que la curva objetivo faltará parcial o totalmente en el pozo de predicción). Ya que

al momento de validar (o predecir) se necesita ingresarle el mismo conjunto de curvas que se le proporcionó al entrenar.

Una vez que se tiene una lista de las curvas comunes entre los pozos, se analiza la calidad de éstas, es decir, en que intervalos tiene datos, si éstos vienen afectados por derrumbes en el pozo, son ruidosos o incoherentes; ya que si se ingresa información que no refleje los eventos buscados a la red, esta información será la que tomará como patrón y los errores de la información contenida en cada curva se sumaran a la respuesta de salida, provocando que los resultados no sean confiables. Además es importante que el intervalo o intervalos en que se encuentren, coincidan con el tramo en el que se tiene la curva que se va a predecir en los pozos de entrenamiento y validación, y en el caso del pozo de predicción que el conjunto de curvas de entrada se encuentren en el intervalo de interés.

#### **4.3.3 Depuración de registros geofísicos**

Con base en el control de calidad se descartan las curvas que vienen dañadas y se hace una depuración de los registros que no tienen las características para ser entrenados, ya sea por las afectaciones que se analizaron anteriormente o por que de antemano se sabe que no van a dar información que vaya directamente relacionada con el fenómeno a estudiar.

El caso de las curvas que, por su naturaleza, no son aptas para ser entrenadas puede ejemplificarse con la curva del CALIPER o la DRHO ya que, aunque nos proporcionan datos importantes sobre las características del pozo e incluso de las formaciones, en el primer caso, y sobre la curva de RHOB en el segundo, no guardan necesariamente una relación entre pozos cercanos y con las mismas formaciones geológicas.

#### **4.4 Selección de registros geofísicos**

Una vez que se han depurado los registros que, por su calidad y/o características no son útiles, se procede a hacer la selección de los registros que serán la información de entrada para el entrenamiento, la validación y predicción, de aquí la importancia de escoger cuidadosamente cuáles serán éstas curvas.

Los registros que se seleccionarán para el entrenamiento y aplicar la metodología, son aquellos que han pasado el control de calidad y que le proporcionen información suficiente a la red sobre la curva que se quiere predecir, es decir, se escogerán aquellos registros que reflejen mejor las características de la curva que se quiere predecir.

Un método que nos brinda información importante son los *crossplots* de las curvas que se tienen contra la que se quiere predecir, para darnos una idea de la relación que guardan las curvas entre si; ya que si alguna de las curvas de registro muestra una correlación lineal con la curva objetivo no es necesario aplicar la red y si por el contrario la nube de puntos es muy dispersa, esa propiedad no responderá a los mismos eventos, por lo cual no brindará la información necesaria para la predicción.

## 4.5 Normalización

Para optimizar el aprendizaje de una RNA es necesario que todos los datos se encuentren dentro de un intervalo de valores (en este caso  $[0, 1]$ ), ya que, en el caso de los registros de pozo, estos pueden tener variaciones tan grandes que llega a ser necesario el uso de escalas logarítmicas para facilitar su análisis. Al proceso de re-escalamiento de valores se le llama normalización.

La fórmula que permite normalizar los valores de cada registro es:

$$X_n^x = \frac{X_n - X_{\min}}{X_{\max} - X_{\min}} \quad (\text{ec. 4.1})$$

donde:

$X_n$  es el valor del registro en cada punto

$X_{\min}$  valor mínimo de  $X$

$X_{\max}$  valor máximo de  $X$

$X_n^x$  valor normalizado de  $X$

Cuando se tienen registros con rangos muy amplios, su normalización será:

$$X_n^x = \frac{\log_{10}(X_{\min}) - \log_{10}(X_n)}{\log_{10}(X_{\min}) - \log_{10}(X_{\max})} \quad (\text{ec. 4.2})$$

Hay que tener en cuenta que los valores máximos y mínimos deben abarcar a todos los pozos a los que será aplicada la metodología, es decir, los valores obtenidos de la normalización de registros, serán utilizados para todos los pozos que se van a procesar.

## 4.6 Entrenamiento de la RNA

El entrenamiento de la red es la parte medular de éste método pues de los parámetros de entrenamiento dependerá la calidad de la predicción, por lo cual es necesario que se busque cuáles serán los parámetros óptimos para que el aprendizaje de la red sea el más eficiente.

Es conveniente que si se tienen dos o más pozos disponibles, es de gran utilidad realizar el entrenamiento en ambos para así poder escoger el que brinde mejores resultados.

### 4.6.1 Control del entrenamiento

La forma en que una red neuronal aprende está en función de la normalización, del *peso* que se le dé a la información de entrada, *número de ciclos*, *número de ventanas*, etc.; esto repercutirá en el tiempo que tarde la RNA en realizar su entrenamiento y en la calidad del mismo.



Cuando se diseña una red muy sencilla el aprendizaje será rápido, se ganará tiempo pero se sacrificará calidad; sin embargo si la red es muy compleja se sacrificará mucho tiempo de máquina y no necesariamente se ganará calidad, pues llega un momento en que la red deja de aprender y comienza a “memorizar”, tal como sucedería con la memoria a corto plazo en el cerebro humano; cuando una red llega a este punto se dice que se está sobre-entrenando.

Durante el entrenamiento de una RNA la respuesta de salida se va aproximando cada vez más a la deseada, por lo que disminuye el error de la misma, hasta que llega a un valor mínimo, si este proceso continúa la red comienza a sobre-entrenarse y a su vez, la respuesta empieza a alejarse de la esperada. Éste efecto puede observarse en la figura 4.1 en la cual se muestra una gráfica de control en la que el eje X representa el número de ciclos del entrenamiento y el Y el error; se puede observar como el error va disminuyendo y llega a la etapa de sobre-entrenamiento donde el valor comienza a aumentar a partir de los 15600 ciclos.

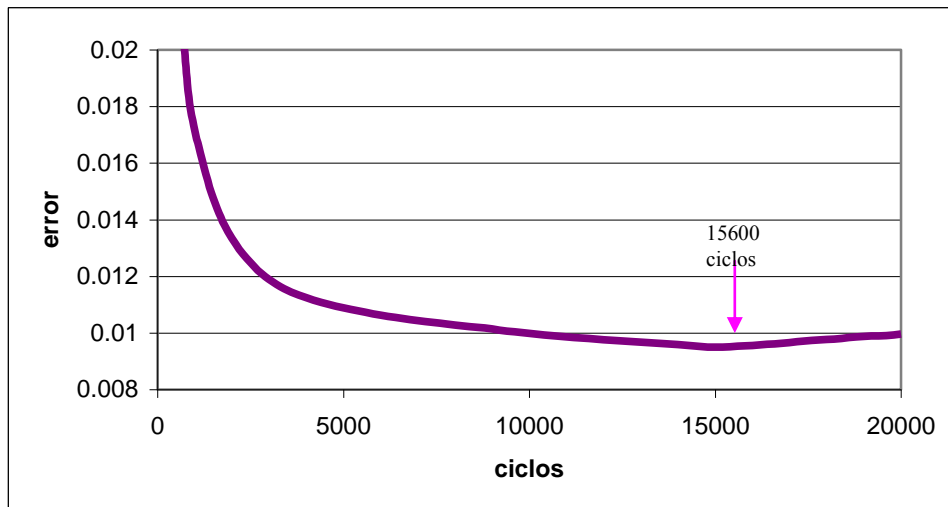


Figura 4.1 Gráfica de la evolución del error durante un entrenamiento, se observa como el error llega a un valor mínimo y después comienza a aumentar.

Existen softwares que permiten varias RNA's en un mismo entrenamiento cambiando una o más características de las mismas, esto ofrece la posibilidad de elegir cuál red se ajusta más al objetivo sin necesidad de hacer varios entrenamientos, cuando esto suceda, la red óptima o “mejor red” será aquella que haya tenido el menor error al final del entrenamiento, lo cual será de gran utilidad al momento de hacer el análisis de resultados durante la validación del entrenamiento.

En la figura 4.2 se observa la gráfica de error de 6 redes entrenadas simultáneamente, en este caso la mejor red sería la número tres pues es la que mostró menos error durante el entrenamiento.

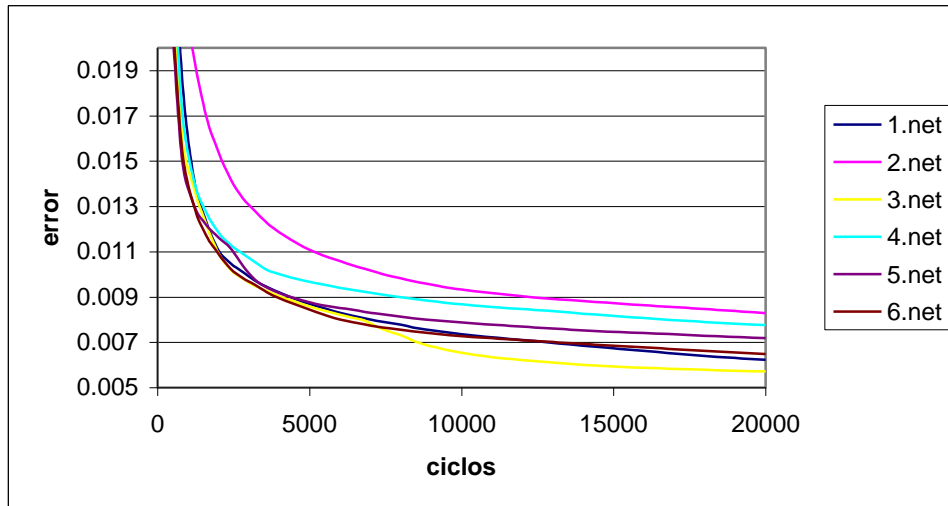


Figura 4.2 Gráfica de error para un entrenamiento de redes simultáneas.

#### 4.7 Validación de los entrenamientos

En la etapa de validación se evalúa si lo aprendido por la RNA durante el entrenamiento es útil para hacer la predicción y cuáles serán sus características. Para esto se hace la predicción de la curva en otro pozo en un intervalo en el que ésta sea conocida (en el caso de que no se tenga otro pozo se hace la comparación en un intervalo diferente al de entrenamiento en el mismo pozo); este método nos ayudará a hacer análisis de calidad de la predicción, ya que podemos compararla con un resultado conocido y así hacer análisis de correlación tanto de valores como de eventos, así como obtener una idea de sobreestimación o subestimación de valores, entre otras características. En otras palabras, se hace una comparación de la curva objetivo, tomada en campo, contra la curva objetivo sintética obtenida de la red, para identificar el grado de confiabilidad de la RNA.

#### 4.8 Predicción

Una vez que se tienen validados los entrenamientos, se escoge cuál red es la que proporciona mejores resultados y con ella se hace la predicción del registro en el intervalo de interés. Como la predicción final se hace en un intervalo en el que no se tiene la curva objetivo, es importante destacar que la manera de calibrar los resultados para saber que tanto se apegan a la realidad, será con datos de núcleo, historias de perforación o datos que nos puedan proporcionar información sobre la propiedad buscada en el pozo.

## CAPÍTULO 5.

### APLICACIÓN DEL MÉTODO DE RNA'S A LA PREDICCIÓN DE UNA CURVA DE SATURACIÓN DE AGUA

Con la finalidad de analizar la respuesta de las redes neuronales a la obtención de curvas de saturación de agua en carbonatos, se analizaron 3 pozos del campo Jujo-Tecominoacán, localizado en el sureste de México. Estos pozos serán referidos en este análisis como J-1, J-2 y J-3, de los cuales J-1 y J-3 son pozos productores de hidrocarburo y el J-2 es no productor además de ser desviado.

Para llevar a cabo este ejemplo se hizo la suposición de que tenemos un pozo en el que se quiere saber cuál sería su curva de saturación de agua y no se tienen curvas de porosidad en la zona que contiene roca caliza, dolomía y la transición entre éstas.

Antes de aplicar la metodología es necesario recopilar la información necesaria para conocer las características geológicas del campo.

#### 5.1 Geología general del campo Jujo-Tecominoacán

##### 5.1.1 Localización

El campo Jujo – Tecominoacán pertenece al activo petrolero del mismo nombre el cual se localiza a 63 kilómetros de Villahermosa, Tabasco, en el sureste de la República Mexicana, por lo que se considera como parte de la región sur del país (Figura 5.1 y 5.2).



Figura 5.1 Cobertura geográfica de la Región Sur. Su extensión comprende los estados de Guerrero, Oaxaca, Veracruz, Tabasco, Campeche, Chiapas, Yucatán y Quintana Roo. (Las Reservas de Hidrocarburos de México. PEMEX. México, 1999.)



Figura 5.2 Localización del campo Jujo-Tecominoacán. (Las Reservas de Hidrocarburos de México. PEMEX. México, 1999.)

### 5.1.2 Geología general

La ubicación geológica del mismo es en las cuencas Terciarias del Sureste, específicamente, en el área central del denominado alto de Chiapas-Tabasco. La litología de la zona está constituida principalmente por dolomías y calizas. Las rocas del Yacimiento son dolomías en una trampa de tipo estructural. Fue descubierto en 1980 y se compone de un yacimiento de edades del Jurásico Superior Kimmeridgiano, Tithoniano y Cretácico Inferior. Este campo es el segundo más importante productor de aceite de la región sur (7,000 MMBLS de aceite volátil de 38° API), contando con un área total de 74 kilómetros cuadrados (Rosillo, 2001).

### 5.1.3 Estratigrafía local

En el campo Jujo se atravesó una columna sedimentaria que va del Jurásico Superior Kimmeridgiano al Terciario. La columna del Jurásico superior Kimmeridgiano hasta el Cretácico Inferior está constituida por dolomías fracturadas de color café y crema con presencia de cavidades de disolución. Las rocas del Cretácico Medio tienen espesores reducidos variables por haber participado en un evento discordante, por esta razón en la correlación se consideran a estos remanentes dentro del Cretácico Inferior. El Cretácico Superior se compone de calizas mudstone a wackestone arcilloso y margas.

El Terciario se encuentra representado por una secuencia de lutitas con intercalaciones de arenas y areniscas, cuyas edades van del Paleoceno al Mioceno Superior.

En la Figura 5.4 se muestra la columna geológica tipo y en la Tabla 5.1 los datos de la columna estratigráfica del mismo.




Figura 5.3 Columna geológica tipo del campo Jujo-Tecominoacán. (Las Reservas de Hidrocarburos de México. Volumen II. Los Principales Campos de Petróleo y Gas de México, Primera Edición, PEMEX Exploración y Producción)

Tabla 5.1 Columna estratigráfica del campo Jujo-Tecominoacán.

Formación	Edad (periodo y época)	Cima (mbmr)
Paraje Solo	Mioceno Superior	Aflora
Filisola	Mioceno Superior	800
Concepción Superior	Mioceno medio	1 080
Concepción Inferior	Mioceno Inferior	1 250
Encanto	Mioceno Inferior	1 400
Depósito	Mioceno Inferior	1 990
Oligoceno	Oligoceno	3 200
Eoceno	Eoceno	3 998
Paleoceno	Paleoceno	4 312
Méndez	Cretácico Superior	4 595
San Felipe	Cretácico Superior	4 797
Agua Nueva	Cretácico Superior	4 883
Cretácico Inferior	Cretácico Inferior	4 895
Jurásico Superior Tithoniano	Jurásico Superior Tithoniano	5 102
Jurásico Superior Kimmeridgiano	Jurásico Superior Kimmeridgiano	5 418

### 5.1.4 Geología estructural local

La estructura del campo Jujo-Tecominoacán es un anticlinal con orientación noroeste a sureste, limitado al oriente por una falla inversa que corre en dirección noroeste a sureste. Al oeste y sureste se presenta un cierre estructural, mientras que al norte y sur, se encuentran 2 intrusiones salinas de regulares dimensiones. El yacimiento sigue la tendencia regional de un gran rasgo tectónico llamado Horst Reforma-Akal, donde la mayoría de los campos Mexicanos costeros y en tierra han sido descubiertos (Rosillo, 2001).

El campo está subdividido en varios bloques originados por una serie de fallas normales que están conectados entre sí hidráulicamente como se puede ver en la figura 5.4.




Figura 5.4 Sección estructural tipo del campo Jujo-Tecominoacán que muestra la distribución de los contactos de las formaciones y bloques formados por las fallas. (Las Reservas de Hidrocarburos de México. PEMEX. México, 1999).

Este campo terrestre ha sido considerado como naturalmente fracturado donde la producción viene de una red de fracturas paralelas a las fallas. Sin embargo, un análisis detallado de la secuencia estratigráfica e interpretación sísmica estructural 3D (ver figura 5.5) correlacionada con patrones de producción, muestran primero, la presencia de fallas lítricas que controlan el espesor de las secuencias y, segundo, gran cantidad de movimientos diferenciales verticales dado el diapirismo pasivo debido a dichas fallas a través del Kimmeridgiano y Tithoniano, el cual volteó o erosionó completamente las secuencias (Villaseñor-Rojas, 2005).



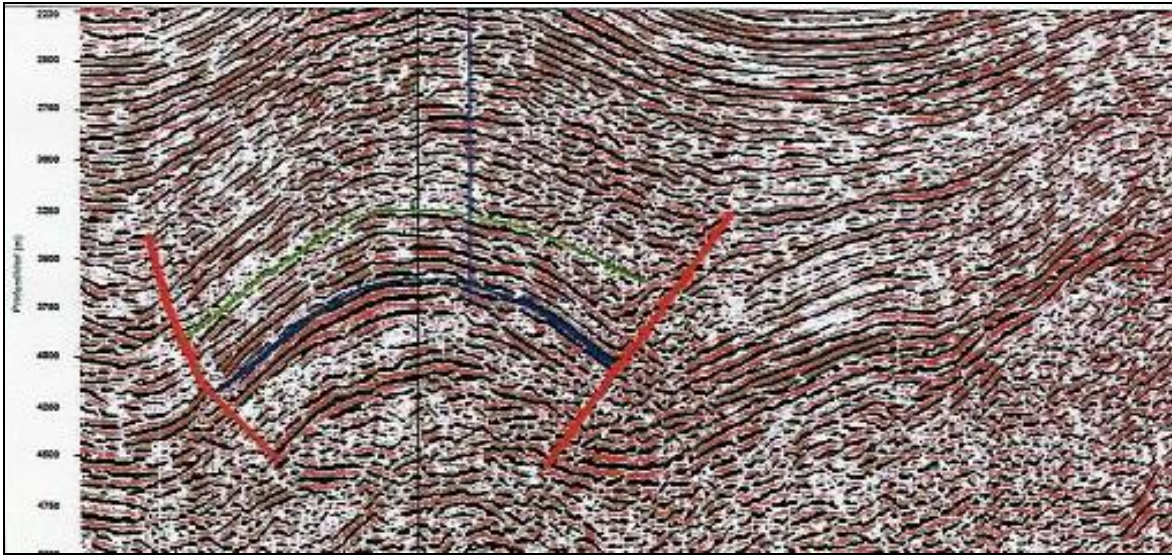


Figura 5.5 Sección sísmica tipo del campo Jujo-Tecominoacán. La línea verde sólida corresponde a la cima del Cretácico y la azul a la del Jurásico. (Las Reservas de Hidrocarburos de México. PEMEX. México, 1999.)

### 5.1.5 Roca generadora

Se ha determinado que la principal roca generadora de hidrocarburos, en la Región Sur, corresponde al Jurásico Superior Tithoniano que consiste en lutitas bituminosas y calizas arcillosas con abundante materia orgánica.

### 5.1.6 Trampa y sello

La trampa, para los yacimientos del Jurásico Superior y del Cretácico Inferior, es de tipo estructural, constituido por dolomías y calizas dolomitizadas, fracturadas y afectadas por fallamiento de tipo inverso que sirve de cierre, y fallamiento normal que divide la trampa en varios bloques.

Las rocas que sirven de sello son las calizas arcillosas del Cretácico Superior y los cierres debido a la presencia de fallas.

### 5.1.7 Yacimiento

Se tienen definidos en el campo varios bloques, con producción de aceite volátil en rocas del jurásico Superior Kimmeridgiano, Tithoniano y Cretácico Inferior. El yacimiento se encuentra a profundidades que varían de los 5,100 a los 6,400 metros bajo el nivel del mar. Como ya se mencionó, el yacimiento consiste de dolomías que han incrementado su porosidad y permeabilidad debido al fracturamiento y los procesos diagenéticos. El espesor promedio de la zona impregnada de hidrocarburos es de 787 metros, esta zona tiene porosidad principalmente intercrystalina y por fracturas (porosidad secundaria) con un

rango del 2 al 3.3%. La saturación de agua promedio es de 25% con una salinidad de 240,000 partes por millón. La permeabilidad promedio es de 80 a 100 milidarcies.

### **5.1.8 Información petrofísica de los pozos**

Diversos registros geofísicos que han sido adquiridos en los pozos en el campo Jujo-Tecominoacán son con la finalidad de determinar las propiedades petrofísicas de las rocas del yacimiento. Así, los registros más comunes son el de densidad, neutrón, rayos gamma, resistividad somera y profunda y los sínicos<sup>1</sup>.

Algunos pozos del campo Jujo cuentan con cálculos de porosidad y porcentajes de arcilla, caliza, dolomía y saturación de agua, entre otros.

La figura 5.6, 5.7 y 5.8 muestran el intervalo en el que se encuentran calculadas las curvas de saturación de agua, los volúmenes litológicos, matriz, fracturas y la porosidad, entre otras de los pozos J-1, J-2 y J-3, respectivamente; también podemos ver que nos encontramos en una transición litológica y su ubicación en profundidad, también se resalta con un recuadro púrpura cuáles intervalos se utilizaron para los entrenamientos en cada pozo. En las figuras se puede observar que se tomó una parte que solo contiene caliza, una de transición y otra de solo dolomía, esta última no aparece en el pozo J-2 debido a que es un pozo direccional (inclinado).

---

<sup>1</sup> PEMEX Exploración y Producción. Las reservas de hidrocarburos en México. Volumen II. México 1999. pag. 327.



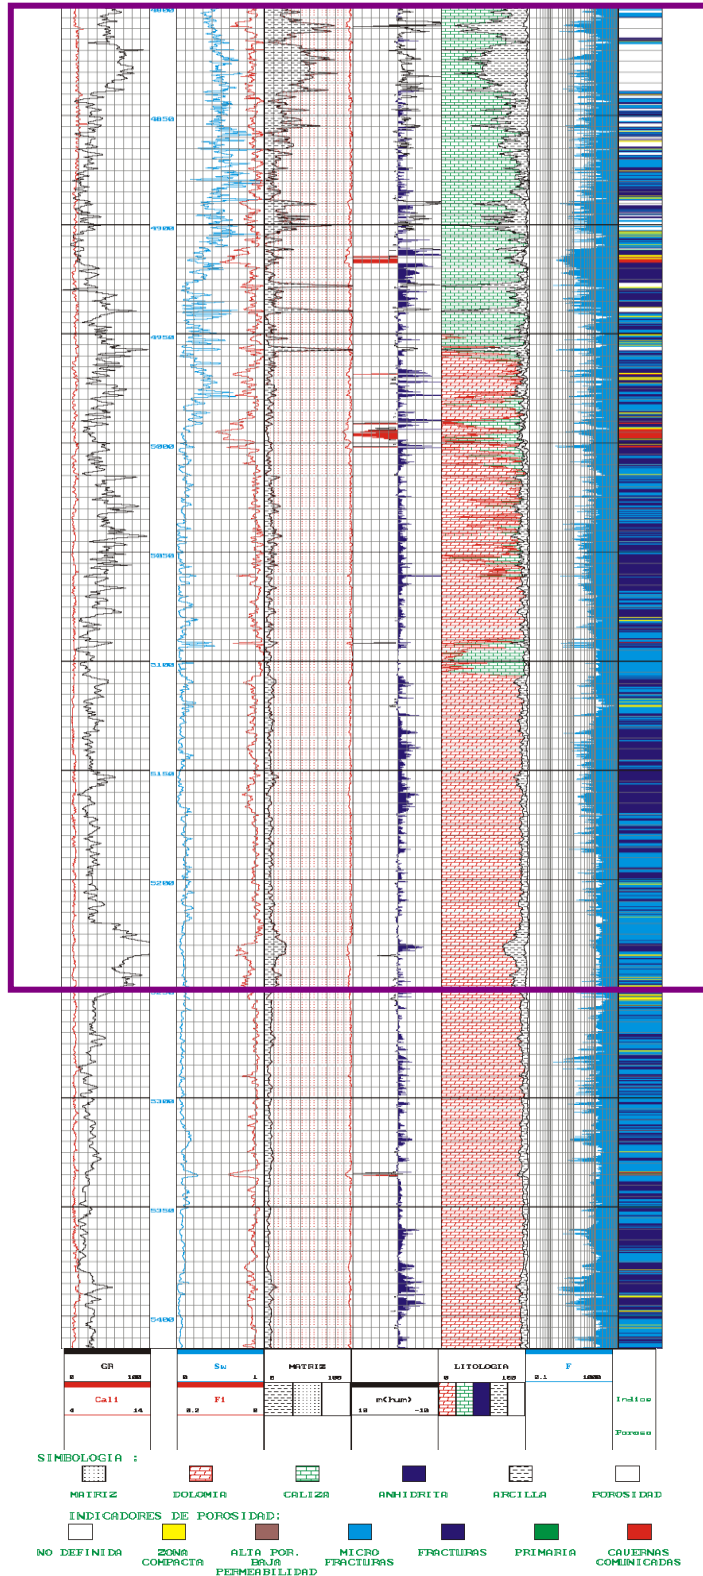


Figura 5.6 Información petrofísica del pozo J-1.




Figura 5.7 Información petrofísica del pozo J-2.




Figura 5.8 Información petrofísica del pozo J-3.

## 5.2 Correlación de eventos

Para realizar la correlación lo primero que se hace es ubicar geográficamente los pozos y buscar si había fallas, discordancias o algún evento geológico que afectara gravemente las características litológicas de los mismos; aunque en este caso, gracias a que ya se tenía la ubicación y la interpretación petrofísica se sabía de antemano que había concordancia y a que profundidad se encontraba el contacto litológico en cada uno de los pozos.

También se construyeron *crossplots* (gráficas cruzadas) para analizar la similitud entre las curvas de saturación de agua entre los pozos. En las figuras 5.9 a) y b) se muestran los *crossplots* que se construyeron para analizar similitud entre las curvas de SW entre los pozos J-1, J-2 y J-3, se puede observar que para valores de saturación de agua bajos (menores al 20%) se presenta la mejor correlación entre los tres pozos y para valores mayores se presenta mayor dispersión, otro punto a destacar es que el pozo J-2 tiene pocos valores de SW menores al 10% y que la mejor correspondencia de puntos es entre los pozos J-1 y J-3 en las bajas saturaciones (zona de dolomías).




Figura 5.9 a) *Crossplots* de correlación de la curva SW entre los pozos J-1, J-2 y J-3.



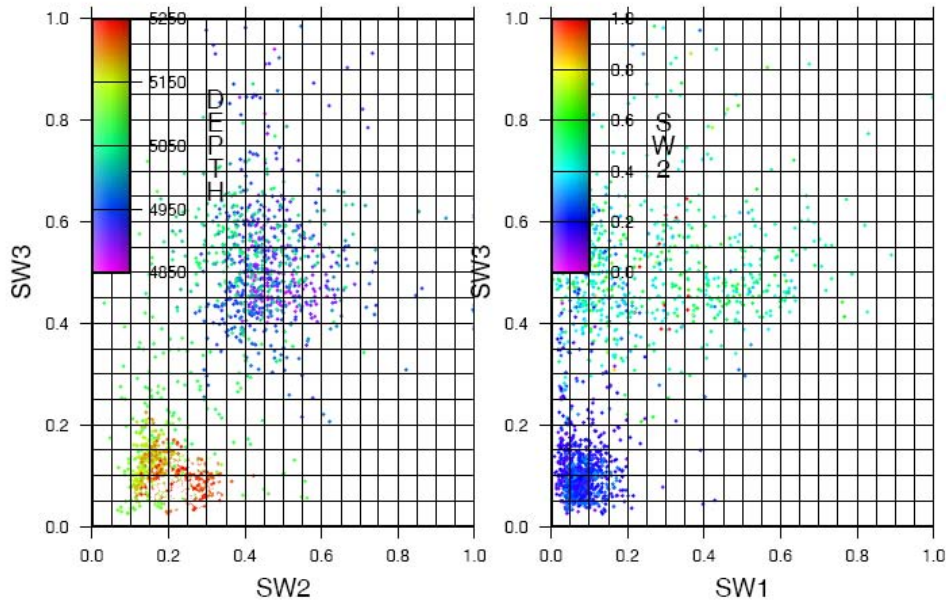


Figura 5.9 b) *Crossplots* de correlación de la curva SW entre los pozos J-1, J-2 y J-3.

### 5.3 Control de calidad y depuración de registros geofísicos

Para realizar el control de calidad de los registros geofísicos se hizo lo siguiente:

1. Se revisó que la información que contienen los encabezados, buscando que esta fuera coherente con la contenida en los registros, es decir, que el intervalo de datos correspondiera al que decía, las curvas declaradas fueran las mismas que las contenidas, las unidades en que estaban tomadas las propiedades, entre otras.
2. Se hizo una lista de las curvas que contenía cada pozo con la finalidad de conocer aquellas que fueran comunes entre los pozos, ya que el conjunto de información usado para el entrenamiento y las predicciones debe ser el mismo.
3. Se seleccionaron las que tenían en común los tres pozos y cuales eran las condiciones de estas en el intervalo de interés.

En la figura 5.10 se observa en el recuadro rosa dos derrumbes marcados por el CALIPER, la curva de RHOB y MSFL están afectadas por el derrumbe, en el recuadro azul se puede ver que el SP y la ILD están afectadas sin haber anomalías aparentes en el pozo. También se puede observar un valor incoherente de la LLD, aunque fuera del intervalo, este valor se dispara hasta los 100,000 ohms\*metro.

En la figura 5.11 se ve que la ILD no tiene lecturas en el intervalo, en el primer recuadro rosa hay un derrumbe y dos en el segundo, en el recuadro azul se observa que el SP, la LLD y la LLS están afectadas en una zona fuera del intervalo de interés, también es notorio que la curva RHOB está demasiado corregida y muy ruidosa.

En la figura 5.12 en este pozo las curvas tienen buena calidad en general, la ILD no tiene lecturas después de los 4,850 metros, el CALIPER muestra dos pequeños derrumbes sin embargo, solo la curva de RHOB y la MSFL muestran pequeñas afectaciones debido a ellos.




Figura 5.10 Gráfica de los registros del Pozo J-1 a partir de la cual se realizó el control de calidad de los datos.




Figura 5.11 Registros del Pozo J-2 de los 4700 a los 5800 metros de profundidad.






Figura 5.12 Registros del Pozo J-3 en el intervalo que va de 4700 a 5700 metros de profundidad.



Como resultado del control de calidad se construyó la tabla 5.2 en la cual se resumen las condiciones de las curvas para hacer la depuración de registros.

Tabla 5.2 Tabla de calidad de los registros.

Curva Pozo	SP	CALIPER	GR	LLD	LLS	MSFL	ILD	-DT	RHOB	NPHI
J-1										
J-2										
J-3										

- No entrena por características de la curva (sección 4.3.3)
- Ausente en el tramo de interés
- Regular calidad en el intervalo
- Mala calidad en el intervalo
- Buena calidad en el intervalo

#### 5.4 Selección de registros geofísicos

Para analizar la relación de los eventos de los registros escogidos después del control de calidad y la curva de SW se construyeron *crossplots* en cada uno de los pozos. Los *crossplots* de las curvas LLS y LLD muestran una nube de puntos compacta lo cual indica que tiene buena correlación con la curva SW, sin llegar a ser lineal; se puede notar que los valores de ambas curvas aumentan conforme aumenta la profundidad y a su vez disminuye el valor de saturación. En el pozo J-3 es donde se tiene menor correlación.

El registro de rayos gamma se muestra más disperso pero también se considerará en el entrenamiento ya que proporciona información importante sobre la arcillosidad de la roca, cabe mencionar que en este caso el rayos gamma no ha sido corregido por uranio, sin embargo en las calizas no está tan afectado, por lo cual será de mucha ayuda en ese intervalo.

Las figuras 5.13, 5.14 y 5.15 muestran los *crossplots* que se construyeron para conocer la correlación que existía entre las curvas GR, LLD, LLS y SW en cada uno de los pozos.

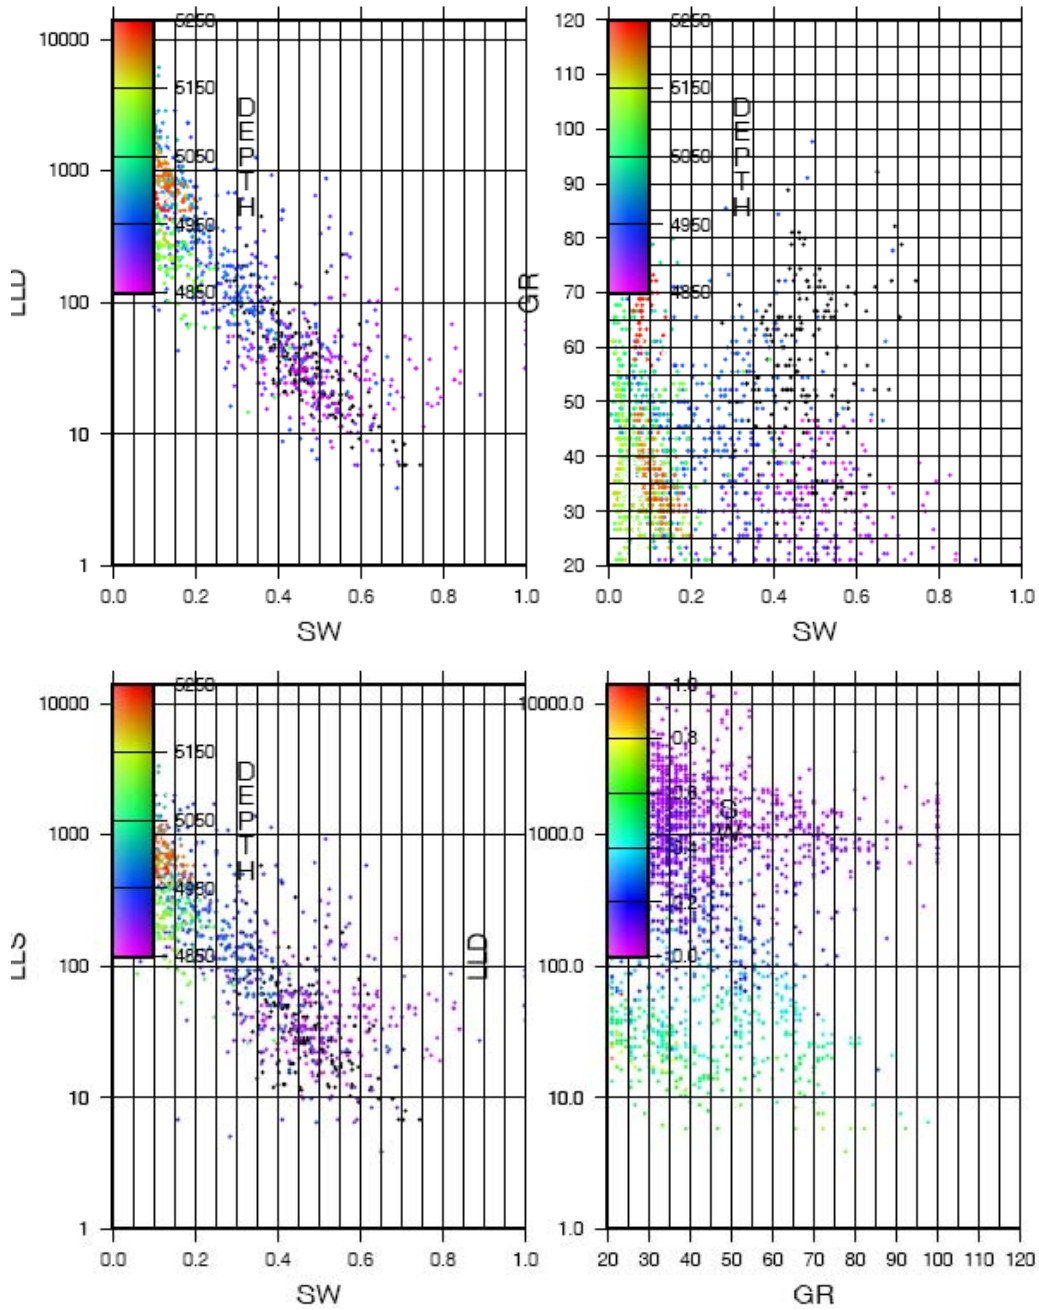


Figura 5.13 *Crossplot* de las curvas de registros de GR, LLS y LLD en relación con el cálculo de SW en el Pozo J-1. Se observa que las curvas resistivas guardan una correlación casi lineal con la SW mientras la GR se muestra dispersa, sin embargo al hacer el *crossplot* de una curva resistiva con GR y SW aparecen marcadas zonas que indican los cambios en los valores de saturación.

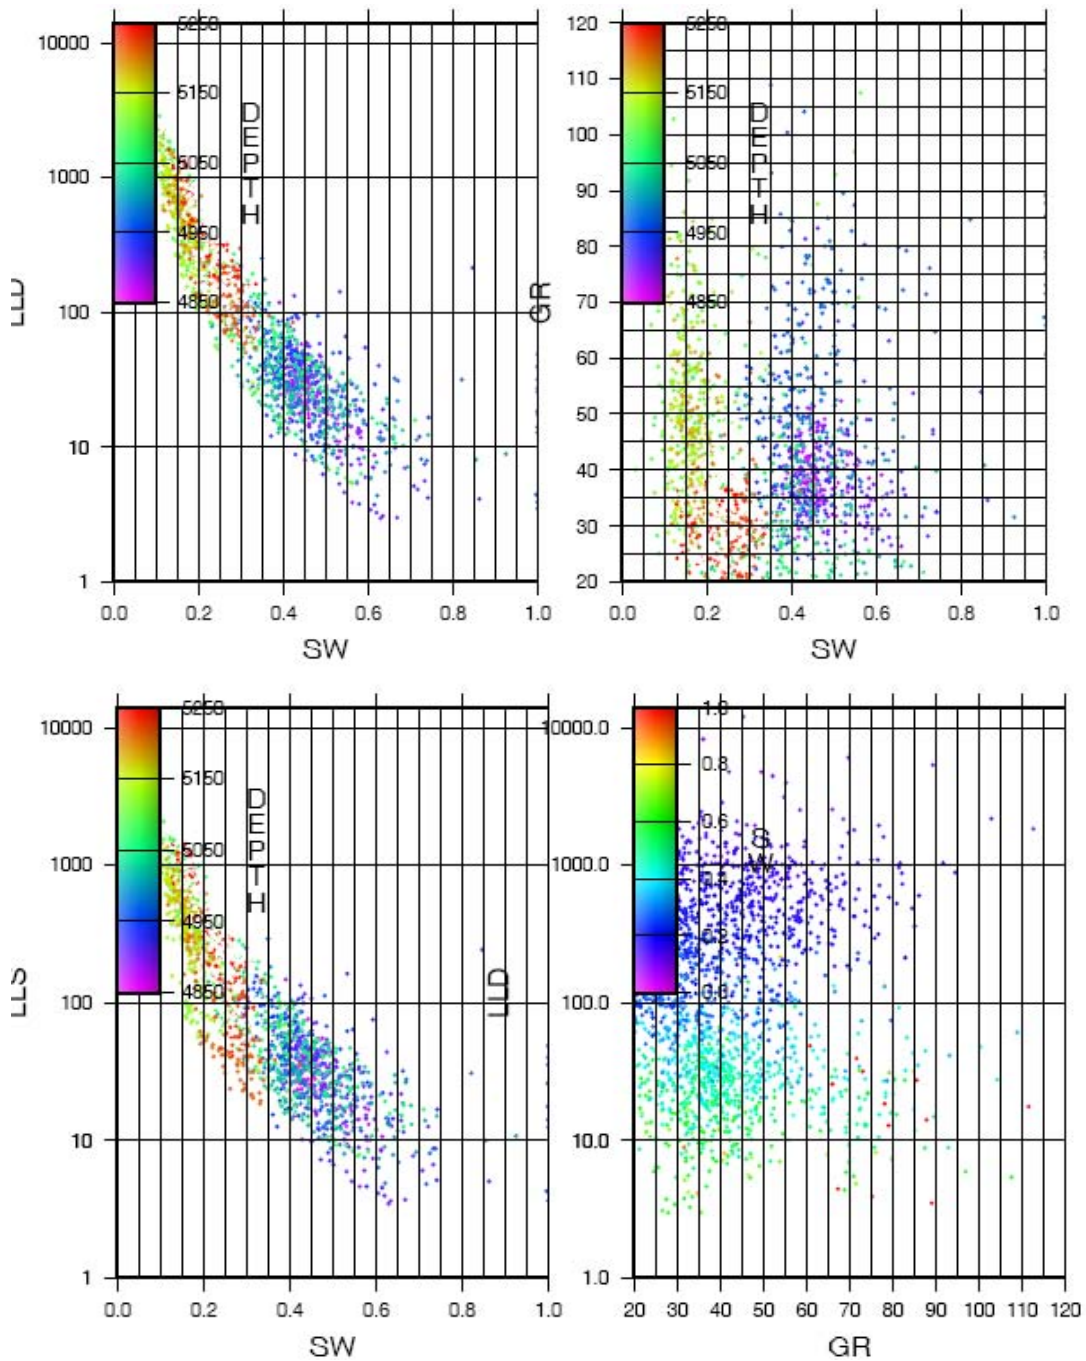


Figura 5.14 *Crossplot* de las curvas de GR, LLS y LLD en relación con la SW del pozo J-2. A pesar de mostrar menor dispersión de SW con respecto al rayos gamma, la nube sigue siendo difusa en este registro, nuevamente las curvas resistivas indican mejor correlación, además, como en el pozo 1, al hacer la combinación de un registro resistivo con el rayos gamma y el de SW se consiguen diferenciar zonas de distintas saturaciones.

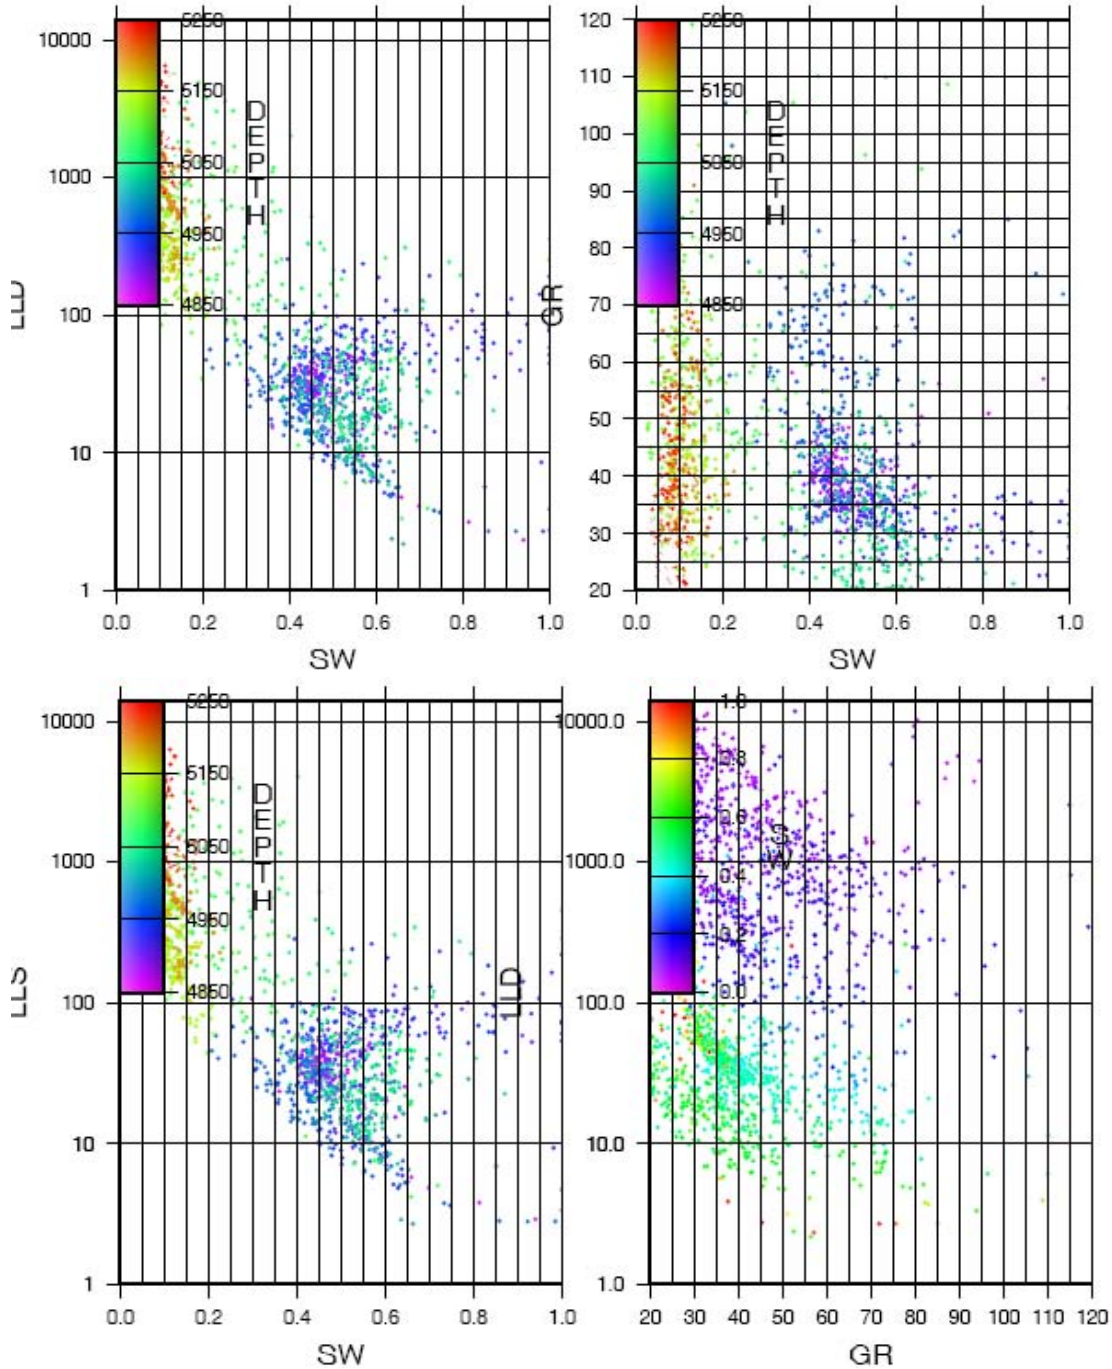


Figura 5.15 *Crossplot* de correlación de los registros GR, LLS y LLD con el cálculo de SW para el pozo J-3. Aunque la nube de puntos de las curvas resistivas con la SW es más dispersa, aún se observa que la nube de puntos está agrupada en ciertos intervalos indicando de forma clara la correspondencia de de altos valores de resistividad con bajos valores de saturación.

Después del control de calidad se tiene que los registros con las mejores condiciones para realizar el entrenamiento son GR, LLD, LLS, DT y NPHI, sin embargo la metodología se está proponiendo para casos en que los datos de porosidad, en el intervalo de interés, están

dañados o muy ruidosos por lo cual las curvas consideradas para el entrenamiento fueron GR, LLS y LLD, es decir, considerando que tenemos registros limitados.

## 5.5 Normalización

A continuación se presenta una tabla (Tabla 5.3) con los valores que fueron utilizados para la normalización de valores y su escala.

<b>Curva</b>	<b>GR</b>	<b>LLS</b>	<b>LLD</b>	<b>SW</b>
<b>Valor mínimo</b>	9.00	2.00	1.00	0.00
<b>Valor máximo</b>	100.00	12600	13600	1.00
<b>Tipo de normalización</b>	Lineal	Logarítmica	Logarítmica	Lineal

Tabla 5.3 Valores máximos y mínimos utilizados para la normalización.

Es necesario recalcar que la normalización de la red es independiente de la normalización de la graficación, pues, lo que se pretende es optimizar la calidad de los resultados y a su vez el tiempo de cómputo.

## 5.6 Entrenamiento de la RNA

El software que se utilizó para entrenar la red permite asignar características como el número de ciclos de entrenamiento y el número de ventanas, este número indica cuantos valores leerá la red antes y después del punto en que se va asignar un valor; entre más grande sea la ventana la curva predicha presentará menos “ruido” o picos. El peso que se le da a la información de entrada lo asigna el software mediante un método llamado “semilla variable”, esto es, que el programa va asignando el peso que se le da a la información de manera aleatoria, de este modo se evita que haya dos redes iguales y se pueda elegir aquella que reproduzca mejor las características que se están buscando. Cabe mencionar que la principal ventaja del software utilizado es que permite el entrenamiento de n-redes simultáneas.

La estructura de la red fue construida con las siguientes características:

Ciclos: 10,000

Número de ventanas: 7

Peso: Variable.

Número de Redes que construirán: 20

Los tres pozos analizados fueron entrenados con éstos parámetros y la normalización obtenida anteriormente.

### 5.6.1 Control del entrenamiento

Como se mencionó en el capítulo 4 el control del entrenamiento se hace construyendo gráficas que nos indican cuál es el avance del mismo, para tratar de evitar la memorización (equivalente al aprendizaje a corto plazo) de las redes. En las figuras 5.16, 5.17 y 5.18 se presentan las gráficas hechas para el control de los pozos J-1, J-2 y J-3, respectivamente, en las que se muestra en el eje X el número de ciclos y en el Y el error del aprendizaje, se puede notar que no hay sobre-entrenamiento por que el error sigue disminuyendo.

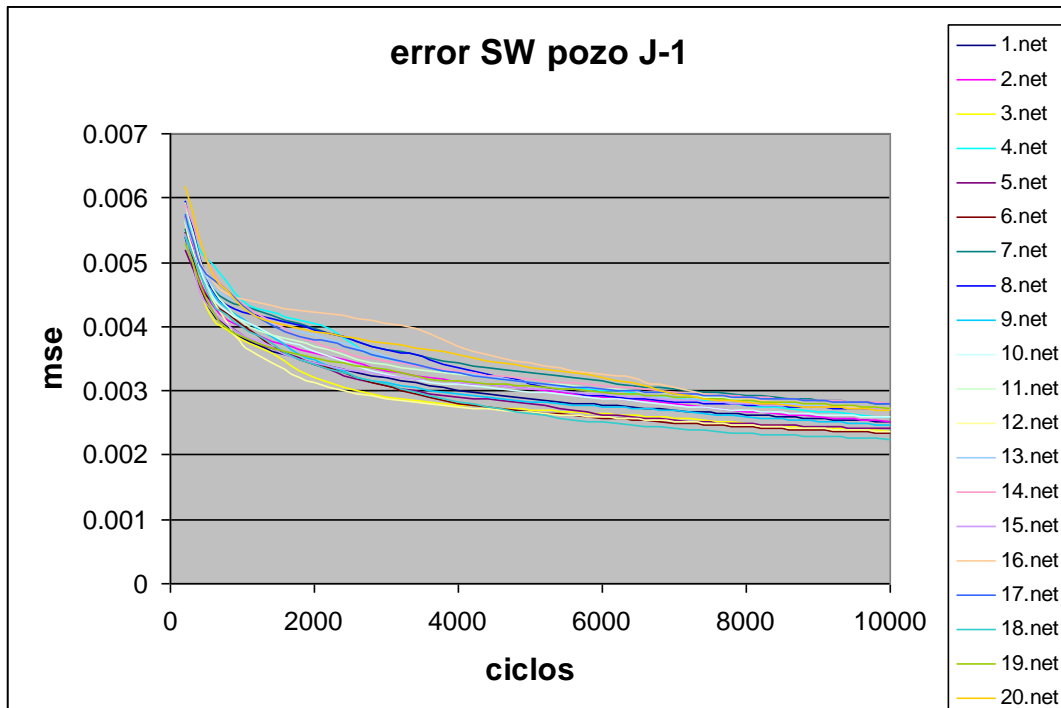


Figura 5.16 Gráfica de error del pozo J-1, se puede observa que hasta el ciclo 10,000 el error sigue disminuyendo de manera relativamente estable y no se presenta sobre-entrenamiento.

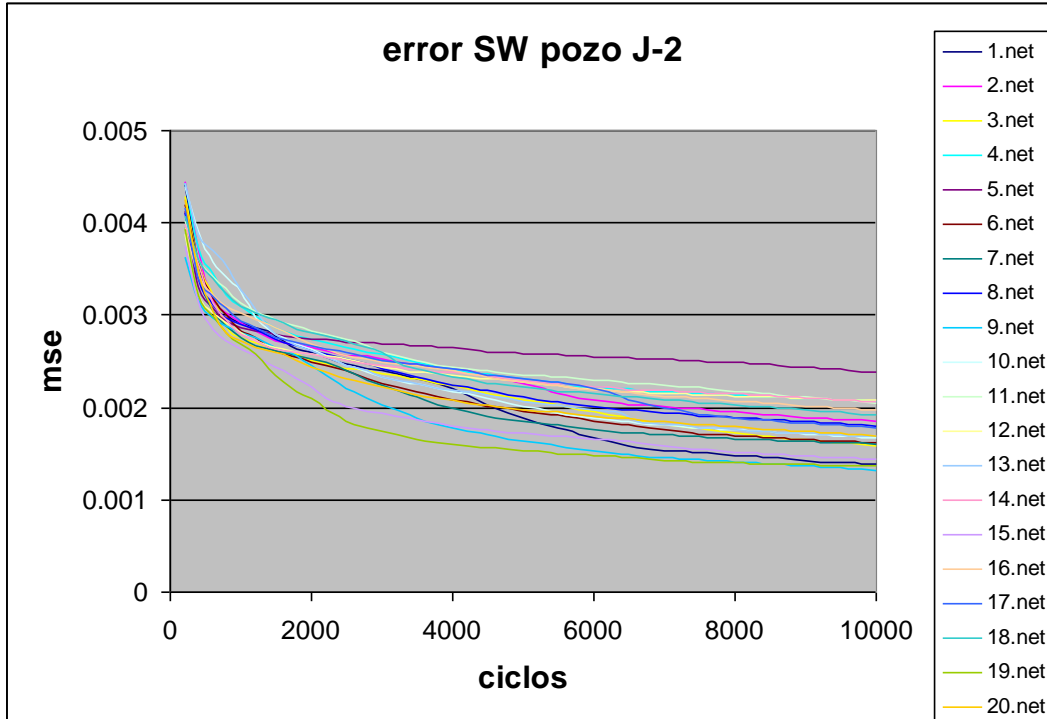


Figura 5.17 Gráfica de error del pozo J-2, al igual que en el pozo anterior, se puede observa que hasta el ciclo 10,000 el error sigue disminuyendo y no se presenta sobre-entrenamiento.




Figura 5.18 Gráfica de error del pozo J-3, en este caso el error se estabilizó más rápido, aunque sigue disminuyendo y al igual que en los pozos anteriores, no hay sobre-entrenamiento.



Estas gráficas son útiles, no solo para constatar que las redes estén aprendiendo correctamente, sino que también sirven para escoger la red que va a ser utilizada para llevar a cabo las validaciones, esta red será aquella que haya alcanzado el menor error al final del entrenamiento. La tabla 5.4 muestra la mejor red resultante de los entrenamientos con cada pozo.

Pozo Entrenado	J-1	J-2	J-3
Mejor Red	18	9	1

Tabla 5.4 Mejor red por cada pozo entrenado.

### 5.7 Validación de los entrenamientos

Antes de realizar una predicción es necesario validar el aprendizaje alcanzado por las redes, para esto se hace la predicción de la curva en un pozo donde se conozca la curva objetivo, de este modo se podrá analizar la calidad de la predicción ya que comparamos la sintética obtenida con RNA y la original del pozo. El conjunto de datos ingresado para la predicción fueron las curvas GR, LLS y LLD, en intervalos que se mencionarán posteriormente y se hizo la predicción con las 20 redes. El control de calidad de la validación se hizo únicamente con las dos redes más representativas con la finalidad de analizar los resultados que brindaba cada una, tanto a nivel de correlación de eventos, es decir, que tan bien reproducía los cambios en las tendencias de la saturación, como de valores (diferencia entre el valor predicho y el real). Las redes utilizadas para el control de la validación fueron la mejor red (BN), que fue escogida a partir de las gráficas de error y la traza media (meantrace) que es obtenida del promedio de las predicciones de todas las redes. A las redes se les aplicaron dos tipos de análisis de confiabilidad de resultados, uno de tipo estadístico, considerando que las redes dan una predicción que se puede estudiar como una distribución poblacional y otro de error numérico, es decir, que tanto se acercan los valores dados por la red a los valores calculados en la interpretación.

El análisis estadístico consistió en obtener la desviación estándar de los valores de las predicciones, partiendo de la consideración de que presentan una distribución normal y de que los valores que se encuentren en mas o menos tres veces la desviación estándar (llamadas mean+3sigma y mean-3sigma) a partir de la traza media son confiables. Los valores fueron agrupados según su grado de confiabilidad, es decir, los valores contenidos dentro de una desviación estándar son los más confiables, después los de dos, y al último los de tres, después de eso, valores mayores a +/- 3 sigma se consideran como una mala predicción, en la Tabla 5.5 se muestra como fueron agrupados los valores de las predicciones en intervalos de calidad en cada punto de la predicción.



Rango de valores de SW	calidad de la predicción	nombre del intervalo
$mean-3sigma > SW\ calculated$	mala por valores sobreestimados	MENOR
$mean-1sigma \leq SW\ calculated \leq mean+1sigma$	muy buena	1s
$mean-2sigma \leq SW\ calculated \leq mean+2sigma$	Buena	2s
$mean-3sigma \leq SW\ calculated \leq mean+3sigma$	Aceptable	3s
$mean+3sigma < SW\ calculated$	mala por valores subestimados	MAYOR

Tabla 5.5 Intervalos asignados para el control de calidad de las predicciones.

Donde:

mean se refiere al valor de la traza media en el punto

Nsigma a N veces la desviación estándar

SWcalculated el valor de SW calculado, durante la interpretación, en ese punto

Debido a que en algunas ocasiones las predicciones presentan escalamientos, es decir, están sobre-estimando o subestimando valores de manera constante en un intervalo definido, se calculó el error de la predicción (EP) de cada red analizada para tener más argumentos para elegir cuál red sería utilizada para definir la predicción, este error se obtuvo de la resta del valor real menos el valor de la predicción en valor absoluto, es decir:

$$|SW_{calc} - SW_{net}|$$

donde:

SW<sub>calc</sub> es la saturación de agua calculada en la interpretación petrofísica del pozo.

SW<sub>net</sub> es la saturación de agua sintética dada por la red.

A partir de éste cálculo es posible ver más fácilmente cuando una predicción presenta un escalamiento, más o menos constante, debido a las características de las curvas y no a un mal aprendizaje, lo cuál no es sencillo apreciar en el análisis estadístico.

Las validaciones se hicieron de forma cruzada, es decir, se hizo el entrenamiento en los tres pozos disponibles y después se validó la red de un pozo en los dos restantes repitiendo este proceso en los otros dos pozos, esta forma de validación permite al interprete valorar que red de que pozo le brinda mejores resultados.

Para facilitar la visualización de las predicciones se graficaron las curvas generadas por las redes, así como, los intervalos de calidad y los errores de las mismas. Las características de la gráfica se describen a continuación:

En los carriles 1 a 3 se colocaron las curvas de GR (que es un indicador de arcillosidad), profundidad, LLD y LLS (que miden resistividad somera y profunda), respectivamente, del pozo con el que se está haciendo la validación; por ejemplo, si se está validando el entrenamiento del pozo J-1 con el J-2, las curvas GR, LLD y LLS serán las correspondientes al pozo J-2. Los carriles 4 y 5 muestran las curvas sintéticas de saturación de agua generadas por la mejor red (BN) en azul y la traza media (MEANTRACE) en anaranjado, respectivamente, además, en ambos casos se muestra en negro la curva de estimación de SW original del pozo con el que se está validando. El carril 6 muestra las

curvas que correspondientes a la traza media más o menos tres desviaciones estándar, y el carril 7 el intervalo de calidad de la predicción en el punto. Por último los carriles 8 y 9 muestran las curvas que se generan al calcular el error de la predicción EP para la mejor red y para la traza media respectivamente.

### **5.7.1 Validaciones del pozo J-1**

Para validar el entrenamiento del pozo J-1 se utilizaron los pozos J-2 y J-3 en el intervalo que va de los 4,900 a los 5,300 metros y de 4,900 a 5,350 metros de profundidad, respectivamente, el análisis de la validación se hizo con la red 18, que fue la mejor red del entrenamiento y la traza media.

En la figura 5.19 se muestra la gráfica de validación que se hizo del entrenamiento del pozo J-1 con la curva de SW del pozo J-2, se observa que la predicción es más ruidosa en las calizas que en las dolomías, además las redes no reconstruyeron el evento de más alta saturación que está a los 4,962-4,981 metros (recuadro azul). El análisis estadístico indica que la predicción es mejor en las calizas y en la zona de transición, sin embargo en las curvas de error se puede notar que se alcanzan mejor los valores en las dolomías, especialmente cuando las saturaciones de agua son menores (recuadro púrpura), esto se debe a que en el pozo J-2 no tenemos una zona que sea únicamente de dolomías y que tenga valores de saturación tan bajos como el J-1. También es importante destacar que la traza media da una mejor predicción que la mejor red.

La figura 5.20 del pozo J-1 validado con el J-3. Al igual que con el pozo J-2, la predicción no representó los eventos de mayor saturación que se tienen en los primeros metros de la validación (recuadro azul), sin embargo, en la zona dolomítica la predicción mejora notablemente, aunque cuando se presentan eventos con aumento en las saturaciones la red sobreestima los valores (recuadro guinda), en las zonas de más baja saturación el error llega a ser casi cero. Nuevamente la traza media genera una mejor aproximación que la red 18.




Figura 5.19 Gráfica de validación del pozo J-1 con J-2 en la cual se muestran las predicciones hechas por la red 18 y la traza media.

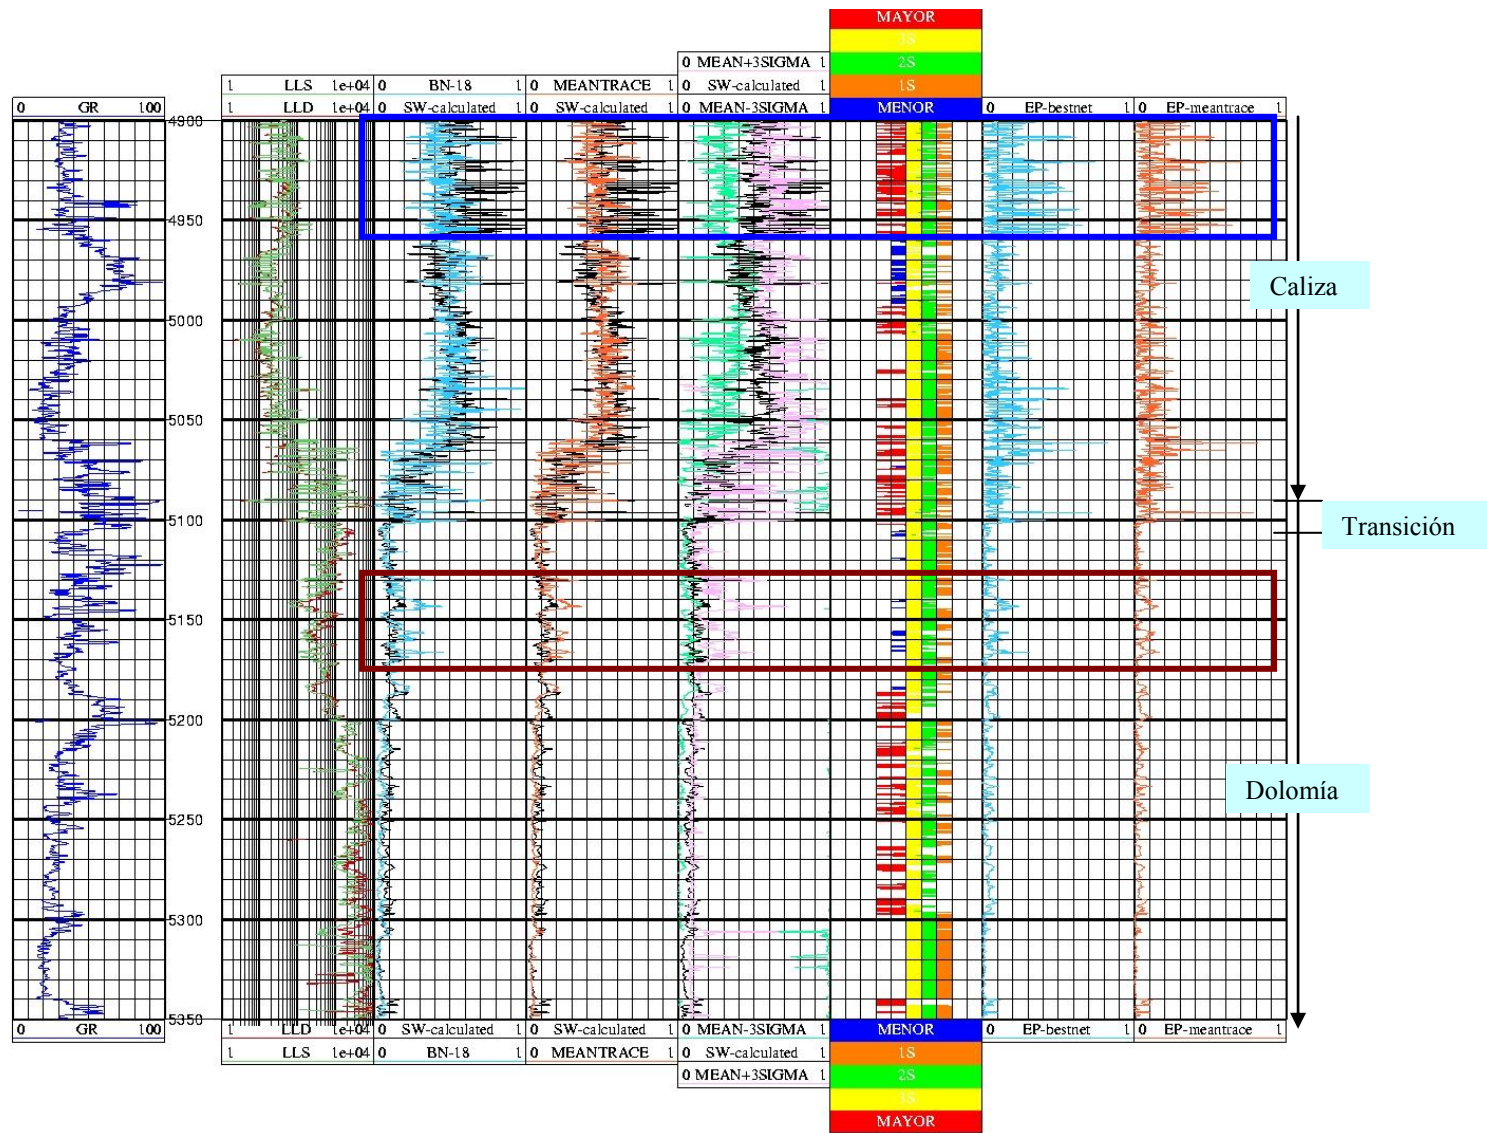


Figura 5.20 Gráfica de validación del pozo J-1 con el J-3 en la que se muestra la predicción hecha por la mejor red y la traza media.

### 5.7.2 Validaciones del pozo J-2

Para validar el entrenamiento del pozo J-2 se utilizaron los pozos J-1 y J-3 en el intervalo que va de los 4,850 a los 5,250 metros y de 4,900 a los 5,350 metros de profundidad, respectivamente; se hizo el análisis con la red 9, que fue la mejor red del entrenamiento y la traza media.

En la figura 5.21 se observa la validación del pozo J-2 con el J-1, la curva muestra que en las calizas la predicción es mejor que la del pozo J-1 y más cercana a los valores reales, en la parte de dolomías la predicción sobreestima los valores de saturación, aún así se distinguen bien los eventos, es decir, la correlación es buena. El análisis estadístico indica que la predicción no es confiable, sin embargo, el error real no es tan alto y es muy estable en la mayor parte del pozo. Hay que destacar que de los 5,038 a los 5,169 metros se tiene una sobreestimación de la saturación de agua prácticamente constante (recuadro rojo).

La figura 5.22 muestra la validación que se hizo con el pozo J-3. La curva generada es más ruidosa en la parte de calizas que en la de dolomías, en la que mejora notablemente, aunque presenta tramos en los que se tiene sobreestimado el valor en toda la capa (5,152-5,190 metros, recuadro rojo) y no ve el evento de baja saturación que se presenta de los 5,308 a los 5,339 (recuadro verde). También se observa que la predicción es menos precisa que la que se hizo del pozo J-1.

En ambas validaciones la traza media tiene una mejor aproximación a las saturaciones reales que la mejor red.






Figura 5.21 Gráfica de validación del pozo J-2 con el J-1, en la cual se muestran las predicciones hechas por la red 9 y la traza media.




Figura 5.22 Gráfica de validación de J-2 con J-3 en la que se muestran las predicciones hechas por la red 9 y la traza media.

### 5.7.3 Validaciones del pozo J-3

La validación del entrenamiento del pozo J-3 se realizó con el pozo J-1 de los 4,850 a los 5,300 metros y en el J-2 de los 4,900 a los 5,300 metros, en este caso la mejor red fue la 1.

En la figura 5.23 se presenta la validación que se hizo con el pozo J-1, como en los casos anteriores la predicción fue mejor en las dolomías, llegando a ser casi cero en algunos puntos (como los que se enmarcan en el recuadro azul), sin embargo, se puede ver que en algunos intervalos (como el que va de los 5,037 a los 5,084 metros en el recuadro rojo) sobreestima las saturaciones. El análisis estadístico muestra que la mayor parte de la predicción es confiable y el cálculo del error da una idea muy clara de que tanto se acercó el modelo a la curva real, especialmente en los últimos 100 metros del intervalo, en el caso de la traza media, que como en los entrenamientos anteriores, dio mejores resultados que la mejor red.

La figura 5.24 es la que corresponde a la validación con el pozo J-2, el modelo es ruidoso y, aunque distingue los cambios de altas y bajas saturaciones incluso en capas delgadas, los valores de esta curva se alejan de los reales conforme aumenta la saturación, y en el caso de las capas que están a los 5,200-5,230 metros, la mejor red sobreestima por mucho la saturación, mientras que la traza media la subestima (recuadro rosa), a pesar de ello es menos ruidosa y más precisa la predicción en esta zona (de transición) que en la zona de calizas tal como ha ocurrido en los pozos anteriores. Nuevamente la traza media provee un mejor modelo que la mejor red.






Figura 5.23 Gráfica de validación del pozo J-3 con J-1 en la que se muestran las predicciones hechas por la red 1 y la traza media.

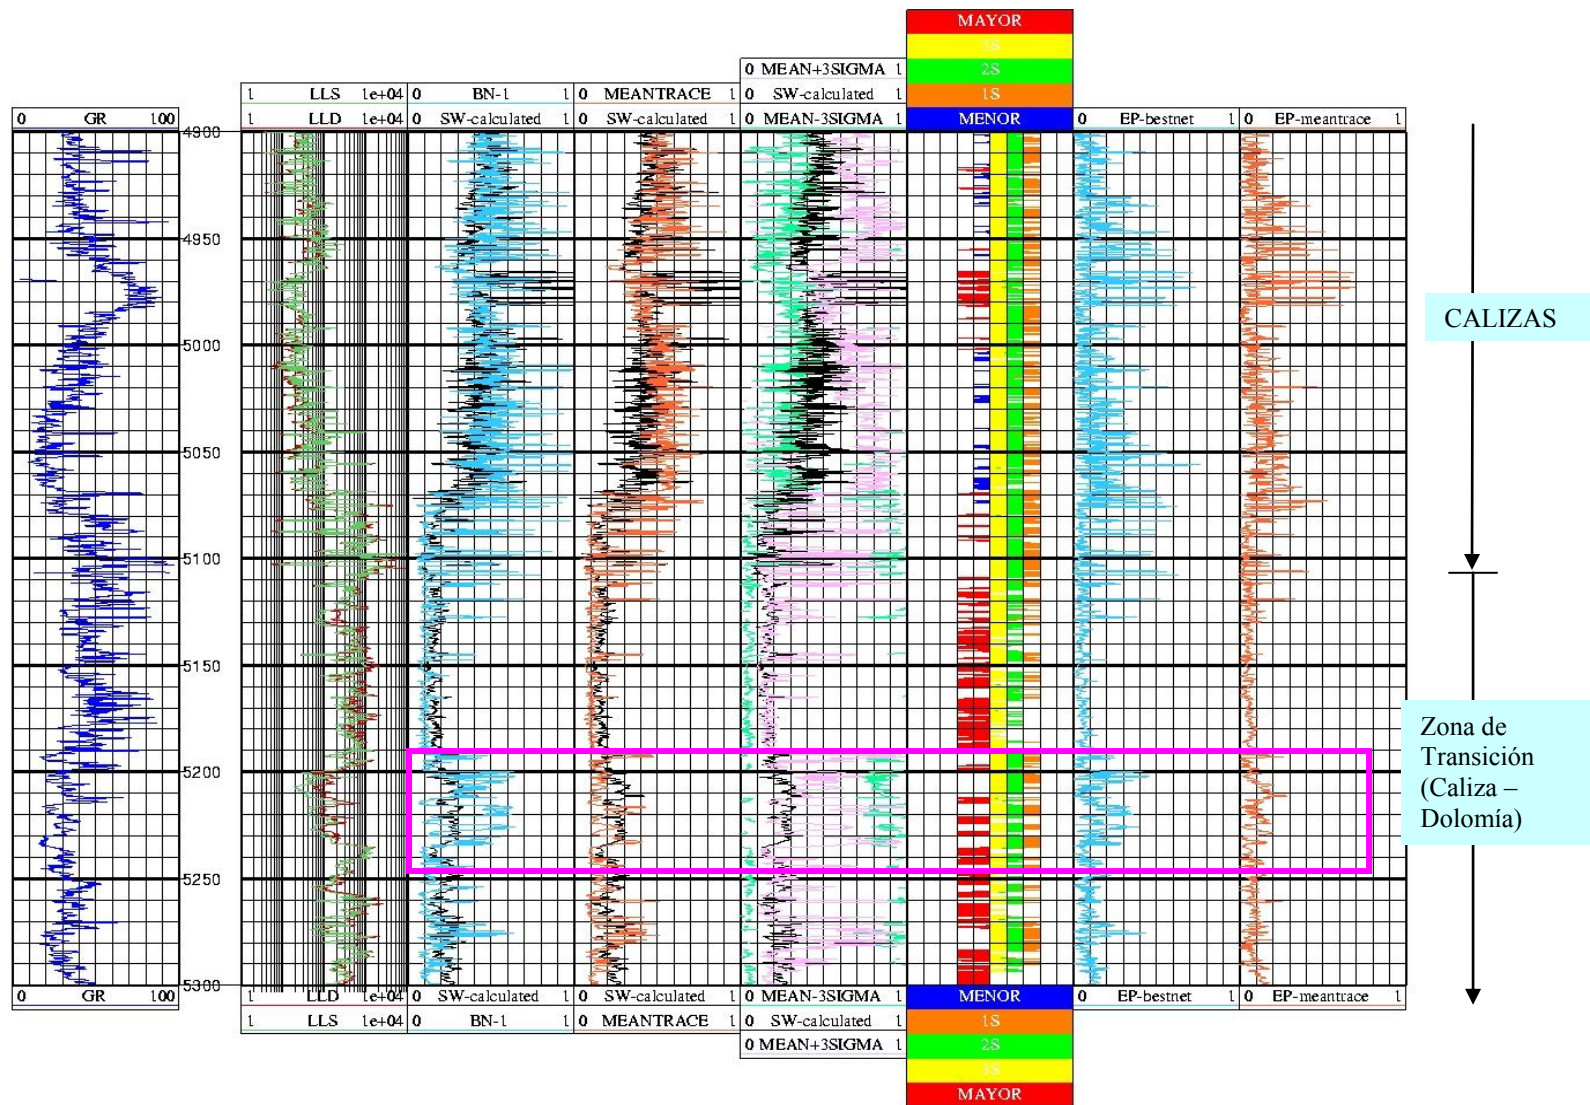


Figura 5.24 Gráfica de validación del pozo J-3 con J-2 en la que se muestran las predicciones hechas por la red 1 y la traza media.

## **5.8 Predicción**

En este ejemplo de aplicación no se realizó ninguna predicción a pozos que no contuvieran curva de saturación de agua debido a que el objetivo fue analizar la respuesta de las redes neuronales cuando se aplican a la predicción de curvas de Saturación de Agua; en cualquier caso, la calibración de las predicciones se podrá hacer, como se mencionó anteriormente, con datos de núcleo o cualquier información proveniente de muestras directas.

Cuando se requiere que se realice una o varias predicciones, el intérprete designará que red aplicará para su predicción dependiendo de que evento desee reproducir y cuál considera que le da mejores resultados, estas se calibrarán con los datos reales disponibles ya que no será posible hacerlo con curvas calculadas.

## CAPÍTULO 6.

### CONCLUSIONES Y RECOMENDACIONES

A partir de este ejemplo de aplicación se derivaron algunas conclusiones y recomendaciones que se consideraron pertinentes.

#### *Particulares:*

- Para el caso de los pozos analizados sería importante tomar en cuenta las características del pozo en el que se quiere predecir la curva, pues ya vimos que fue difícil reproducir la curva del pozo J-2 que es un pozo desviado, en el que no se presenta la zona puramente dolomítica y es no productor; sin embargo, las curvas generadas con este mismo pozo, a pesar de sobreestimar la mayoría de los valores de saturación, fue el que mejor reprodujo la forma general de las curvas originales además de ser la menos ruidosa.
- El caso de los pozos J-1 y J.3, es diferente, ambos son pozos productores y sus curvas de saturación son similares, especialmente en la zona dolomítica lo cual permite que la predicción sea más precisa, sin embargo, la predicción que hicieron las redes de ambos pozos de la curva en el pozo J-2 fue muy ruidosa, aunque la del J-1 fue mejor que la del J-3. En cuanto a la validación que se hizo entre ellos fue mejor la del pozo J-3 con el J-1 que la inversa, pues los valores de la curva generada por las redes fueron más cercanos a los reales, especialmente en las dolomías. Lo que si es claro para los tres pozos es que la traza media o (promedio de todas las trazas) brinda mejores aproximaciones que la mejor red.
- En mi caso particular, si tuviera que hacer la predicción de una curva y el objetivo fuera encontrar el cambio de las altas a bajas saturaciones escogería la traza media del pozo J-2 porque es la que refleja mejor la forma de las curvas, en cambio si el objetivo fuera encontrar la curva de saturación en dolomías para ubicar un posible intervalo productor escogería la traza media del J-3 que es la que mejor alcanzó los valores de SW en dicha zona.

#### *Generales:*

- Debido a que las redes neuronales están inspiradas en el funcionamiento del cerebro humano, las características de la red y la información de entrada deben enfatizar los eventos que queremos observar de lo contrario no se tendrán los resultados esperados.
- Las RNA's se pueden aplicar tanto a la predicción de registros faltantes o dañados como de curvas calculadas obteniendo resultados confiables.
- Cuando se está trabajando con curvas calculadas es necesario contar con información que valide que las consideraciones que se hicieron durante la

interpretación fueron las pertinentes, de lo contrario las predicciones, aunque tengan buena correlación en las validaciones, no se podrán considerar confiables.

- A pesar de que las redes neuronales en carbonatos no suelen ser muy confiables, dado que las propiedades petrofísicas pueden variar considerablemente de un pozo a otro, en este campo mostraron tener buenos resultados, gracias a que las características de los pozos no cambiaron abruptamente.
- Las redes neuronales son confiables entre pozos que no tengan variaciones geológicas importantes entre ellos (fallas, intrusiones, etc.). La cantidad de pozos en los que se pueda realizar una predicción dependerá de la homogeneidad de las características geológicas y de la proximidad entre los pozos en algunos casos.
- Es importante que la información que se le ingrese a la RNA sea confiable y que haya pasado por controles de calidad previos ya que este tipo de información es la que aprenderá y de su calidad dependerá la calidad de la predicción.
- Las validaciones cruzadas permiten tener un mayor panorama acerca de las características de las predicciones lo cual permite hacer una mejor elección para la predicción.
- La predicción se puede realizar a partir de una sola curva de entrada pero, entre mayor información de calidad se le proporcione a la red mejor será la predicción.
- Debido al tiempo relativamente corto que lleva el entrenamiento de una red, el costo y la calidad de los resultados las RNA's son una metodología que puede servir como apoyo en la ubicación de intervalos de interés e incluso en la toma de decisiones.
- A pesar de que las redes neuronales son una metodología confiable en la predicción de registros, los resultados que éstas nos dan no dejan de ser modelos computacionales, hay que tener en cuenta sus limitaciones y evitar el uso indiscriminado de ellas ya que no suplantán a las curvas obtenidas con fórmulas matemáticas a partir de datos reales.
- Es recomendable tener datos de núcleos que validen la calidad de la predicción cuando ya no se tiene una curva de comparación.
- La aplicación de redes neuronales artificiales a los registros geofísicos de pozo es cada vez más común y, conforme pasa el tiempo, se les encuentran cada vez más aplicaciones, sin embargo, hay que tomar en cuenta que existen más metodologías que pueden ayudar a la obtención de resultados así como las ventajas y desventajas de cada una.



## BIBLIOGRAFÍA

Arroyo Carrasco, F. A., *Bases Teóricas de la Interpretación de Registros Geofísicos de Pozos*, México, Facultad de Ingeniería, UNAM, 1985.

Bassiouni, Z. *Theory, Measurement and Interpretation of Well Logs*, Tulsa, OK, SPE Textbook Series 4, 1994.

Bollilla, Ana, *Redes Neuronales Artificiales*, [www.monografias.com](http://www.monografias.com)

Estrada Galicia, Jorge R., *Cálculo de Permeabilidad de las Rocas Aplicando Redes Neuronales Artificiales con Base en Información de Registros Geofísicos de Pozos*, Tesis, UNAM, México, 2003.

Gutiérrez Guevara, Marytere, *Redes Neuronales Aplicadas a la Reconstrucción de Registros Geofísicos de Pozo. Una Herramienta para la Evaluación de Formaciones*, Tesis, IPN, México, 2005.

Las Reservas de Hidrocarburos de México. Volumen II. Los Principales Campos de Petróleo y Gas de México, Primera Edición, PEMEX Exploración y Producción, México, D.F., 1999.

Manual de instrucción, Interpretación de Registros a Agujero Descubierta, Viro Consultoría Ltda., Quinta edición, México, 1997.

Mario Gómez Martínez, *Teoría y Simulación de Redes Neuronales Artificiales*, Barcelona, 1999.

Mera Barrera Oscar, Método de Interpretación de Registros con Exponentes  $M_A$  Variables en Rocas Carbonatadas, Instituto Mexicano del Petróleo, México, 2005.

Mirko Van Der Baan, Christian Jutten, *Neural Networks in Geophysical Applications*, Geophysics, Vol. 65, No.4, Julio-Agosto, 2000, P1032-1047.

Rolon, L. F., Chevron, et. al., *Developing Synthetic Well Logs for the Upper Devonian Units in Southern Pennsylvania*, Society of Petroleum Engineers, Eastern Regional Meeting Held in Morgantown, W.V., 14–16 Septiembre, 2005.

Rosillo, Jorge, et. al., *Geological Characterization of the Jujo - Tecominoacan Field, Tabasco, Mexico*, AAPG, Junio, 2001.

SCHLUMBERGER, *Log Interpretation Charts*, 2000.

Y. Zhang, H.A. Salisch, and J.G. McPherson, *Applications of Neural Networks to Identify Lithofacies From Well Logs*, Exploration Geophysics, 1999, pp 45-49.

Páginas web:

Aldabas-Rubira, Emiliano, *Introducción al Reconocimiento de Patrones Mediante Redes Neuronales*, <http://www.jcee.upc.es/JCEE2002/Aldabas.pdf>.

López, María V., et. al., *Software de Predicción de la Producción Forrajera*, UNNE - Comunicaciones Científicas y Tecnológicas, 2001. <http://www.unne.edu.ar/cyt/2001/8-Exactas/E-002.pdf>.

Red neuronal artificial, Wikipedia enciclopedia libre, 2004.  
[http://es.wikipedia.org/wiki/Red\\_neuronal\\_artificial](http://es.wikipedia.org/wiki/Red_neuronal_artificial)

Schlumberger Oilfield Glossary <http://www.glossary.oilfield.slb.com/>