



UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO

FACULTAD DE INGENIERÍA

APLICACIÓN DE REDES
NEURONALES EN LA
INGENIERÍA PETROLERA

TESIS

Que para obtener el título de
Ingeniero Petrolero

P R E S E N T A

Israel Oliver Hernández Ambrosio

DIRECTOR DE TESIS

Dr. Víctor Hugo Arana Ortiz



Ciudad Universitaria, Cd. Mx., 2017



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.



UNIVERSIDAD NACIONAL
AUTÓNOMA DE
MÉXICO

FACULTAD DE INGENIERÍA
DIVISIÓN DE INGENIERÍA EN CIENCIAS DE LA
TIERRA

Aceptación de Trabajo Escrito

DR. CARLOS AGUSTÍN ESCALANTE SANDOVAL
DIRECTOR DE LA FACULTAD DE INGENIERÍA
DE LA U.N.A.M.
Presente.

En relación con el Examen Profesional de **HERNANDEZ AMBROSIO ISRAEL OLIVER**, registrado con número de cuenta **412050488** en la carrera de **INGENIERÍA PETROLERA**, del cual hemos sido designados sinodales, nos permitimos manifestarle la aceptación del trabajo escrito desarrollado por el citado alumno.


Atentamente.




DR. JORGE ALBERTO AREVALO VILLAGRAN
FECHA DE ACEPTACIÓN: ABR. 25, 2017.



DR. VICTOR HUGO ARANA ORTIZ
FECHA DE ACEPTACIÓN: ABR 27, 2017.



DR. TEODORO IVAN GUERRERO SARABIA
FECHA DE ACEPTACIÓN: 16-Mayo-2017



ING. HECTOR ERICK GALLARDO FERRERA
FECHA DE ACEPTACIÓN: Mayo 16/17.



ING. EDGAR ANTONIO MEZA PEREZ
FECHA DE ACEPTACIÓN: Mayo 8, 2017.

FECHA DE EMISIÓN: 02 de Febrero de 2017

Este trabajo está dedicado a mi querida madre, Manuela. Los valores que me has inculcado es invaluable, gracias por todo el amor y apoyo que me has brindado.

A mi hermano Plácido, quien más estimo. Gracias por creer en mí, por apoyarme en todo momento y por los consejos que me has brindado, te lo debo todo, eres el mejor hermano y un ejemplo a seguir. Con todo mi corazón te lo dedico a tí y a mamá.

A mi hermana Amelia, José Luis, Gabriela y María, ustedes siempre creyeron e hicieron posible mis sueños. Gracias por apoyarme, en las buenas y en las malas.

A mi tío Juan (+), has sido la persona más alegre que he conocido, siempre te gustó impulsar la educación para la familia. Gracias.

A mis primos: Leobardo, Hugo y José. Gracias por sus apoyos, por todo lo que hemos compartido en las buenas y en las malas.

A mi alma mater y con orgullo, **Universidad Nacional Autónoma de México**, a tí te debo mi formación y desarrollo.

Al Programa Universitario de Estudios de la Diversidad Cultural y la Interculturalidad (PUIC), gracias por todo el apoyo económico, académico y moral.

A mi tutora del PUIC, Esther Carrillo. Tu dedicación y entusiasmo hacia los becarios es de gran admiración y gracias por toda la atención que me brindastes.

A mi amiga Laura, Julia y Othoniel, ustedes nunca dejaron de creer en mí, gracias por todas las motivaciones que me dieron. Gracias por todo los consejos, momentos y experiencias que hemos compartido.

A mi amiga Pamela y a mi amigo Emilio, gracias por compartir sus valiosas experiencias y consejos que me han brindado. No cambien...

A mis amigos: Humberto, Omar, Carlos, Oswaldo, Óscar, Gustavo, Gabriela, Luis, Néstor, Itzel, Alejandra, Rene, Cantú y Padilla. Los momentos de convivencia con ustedes siempre será para mí una gran experiencia.

A mi director de tesis, Dr. Arana. Gracias por todas las enseñanzas que me has inculcado y por apoyarme en los proyectos de emprendimiento.

Al Mtro. Miguel, por creer siempre en mis proyectos e ideas. Gracias por todo el apoyo brindado para lograr concluir este trabajo.

A cada persona que creyó en mí, y que estuvo conmigo en este esfuerzo.

Resumen

Actualmente las herramientas computacionales han adoptado de forma simplificada las habilidades del cerebro humano. Normalmente pensamos que estas herramientas sólo pueden ser utilizadas en la industria de la tecnología, sin embargo, estos mismos desarrollos pueden ser escaladas para ser usadas en la industria petrolera. La Inteligencia Artificial (IA) es una de las ramas de la computación con mayor auge, porque pueden emplearse para procesar información de una manera más eficiente con respecto a los métodos convencionales. Las Redes Neuronales Artificiales (RNA) es un área específica de la IA y se han empleado para el control de brazos de robot, reconocimiento de imágenes, etc., o cualquier otro sistema que es capaz de adquirir conocimiento a través de la experiencia.

Debido a las pocas investigaciones publicadas respecto al uso de las RNA en la ingeniería petrolera, en este trabajo resultó pertinente realizar dos casos de estudios que utiliza las RNA para predecir las propiedades más importantes de los fluidos petroleros. El primer caso se enfocó a predecir propiedades puntuales de los fluidos petroleros. Los datos usados en este primer estudio fueron recolectados de diferentes partes del Medio Oriente.

El segundo caso es un estudio que utilizó datos de los campos de México, la cual, se considera de tipo disruptivo, ya que, existe poca documentación de como predecir el comportamiento completo de una propiedad PVT. Dos y cinco modelos de RNA son desarrollados para el primer y segundo caso de estudio, respectivamente. Ambos estudios utilizaron una nueva metodología de validación de resultados, para comprobar la confiabilidad y del seguimiento de las leyes físicas del yacimiento, demostrando también las debilidades de algunos métodos convencionales.

Las técnicas de minería de datos son mencionadas e implementadas implícitamente en la etapa de preprocesamiento de información. También se aclara que, en desarrollo posteriores, será posible aplicar esta metodología a otros tipos de aceites. Indiscutiblemente, ésta metodología puede ser extendida para integrar estudios geológicos y petrofísicos a la red neuronal, lo que en definitiva podrá aprovecharse para generar un potente software aplicado a las diversas áreas de la industria petrolera.

El desarrollo de un software para tratar, procesar y predecir los datos, junto con el establecimiento de una metodología de validación de resultados, son las partes medulares del presente trabajo.

Las exactitudes de los dos estudios realizados mostraron ser superior a los resultados de los métodos indirectos usados.

El objetivo del presente trabajo es desarrollar modelos de redes neuronales para determinar las propiedades de los fluidos petroleros de manera indirecta y con mayor exactitud, junto con una metodología de validación del cumplimiento de las leyes físicas del yacimiento de cada modelo de red desarrollado.

Índice general

Índice de figuras	IX
Índice de tablas	XI
1. Introducción	1
2. Fundamentos de las Redes Neuronales Artificiales	5
2.1. Introducción	5
2.2. Redes Neuronales Artificiales	6
2.2.1. Relación de RNA con la Biología	6
2.2.2. Proceso de transmisión de señales (naturaleza electroquímica)	8
2.2.3. Analogía	9
2.2.4. Definición de Redes Neuronales Artificiales	10
2.2.5. Breve historia de las RNA	10
2.3. Componentes de un sistema neuronal artificial	12
2.3.1. Sistemas paralelos, distribuidos y adaptativos	12
2.3.1.1. Procesamiento en paralelo	12
2.3.1.2. Memoria distribuida	12
2.3.1.3. Aprendizaje adaptativo	13
2.3.2. Elementos básicos de un sistema neuronal artificial	13
2.3.2.1. Función de propagación	14
2.3.2.2. Función de transferencia o activación	14
2.3.2.3. Función de salida	15
2.3.3. Ejemplo	16
2.4. Clasificación de las Redes Neuronales Artificiales	17
2.4.1. Por su arquitectura	17
2.4.1.1. Redes monocapa (1 capa)	19
2.4.1.2. Redes de múltiples capas	19
2.4.1.3. Recurrentes	20
2.4.2. Por los mecanismos de aprendizaje	20
2.4.2.1. Redes con aprendizaje supervisado	22
2.4.3. Redes con aprendizaje no supervisado	22
2.4.3.1. Aprendizaje Hebbiano	22

2.4.3.2.	Aprendizaje competitivo y cooperativo	23
2.4.3.3.	Aprendizaje híbrido	23
2.4.4.	Por sus aplicaciones	23
2.4.4.1.	Asociación y clasificación	23
2.4.4.2.	Predicción	24
2.4.4.3.	Optimización	24
2.5.	Modelo Backpropagation	24
2.5.1.	Principios para entrenar una red multicapa empleando el algoritmo de retropropagación.	26
2.5.1.1.	Descripción gráfica del algoritmo Backpropagation.	26
2.5.1.2.	Etapas de entrenamiento	30
3.	Ejemplos de Redes Neuronales	33
3.1.	Caso de estudio 1: Reconocimiento de caracteres	33
3.1.1.	Introducción	33
3.1.2.	Diseño de la red neuronal	33
3.1.3.	Resultados	35
3.1.4.	Discusiones y conclusiones	37
3.2.	Caso de estudio 2: Generación de registros sintéticos	37
3.2.1.	Introducción	37
3.2.2.	Metodología	38
3.2.3.	Preparación de datos	38
3.2.4.	Modelo de Red Neuronal	39
3.2.5.	Resultados	39
3.2.6.	Conclusiones	45
3.3.	Caso de estudio 3: Predicción de la Porosidad	45
3.3.1.	Introducción	45
3.3.2.	Desarrollo	45
3.3.3.	Conclusiones	55
3.4.	Caso de estudio 4: Introduciendo un Nuevo Método para Predecir las Propiedades PVT del Aceite Crudo Iraní mediante las Redes Neuronales Artificiales	56
3.4.1.	Introducción	56
3.4.2.	Desarrollo de Modelos PVT	57
3.4.2.1.	Conjunto de datos de entrenamiento	57
3.4.2.2.	Conjunto de datos de validación cruzada	60
3.4.3.	Conclusiones	61
4.	Desarrollo de una Red Neuronal Aplicado en la Ingeniería Petrolera	63
4.1.	Introducción	63
4.2.	Revisión de literatura de las correlaciones PVT y RNA	64
4.2.1.	Correlaciones PVT para aceite saturado	64
4.2.2.	Correlaciones PVT para aceite sobresaturado	65
4.2.3.	Modelos de Redes Neuronales para estimar las propiedades PVT	66

4.3. Metodología	69
4.3.1. Recopilación y clasificación de datos PVT	69
4.3.2. Preprocesamiento de información	70
4.3.3. Elección del algoritmo RNA	71
4.3.4. Arquitectura y etapas de procesamiento de la Red Neuronal Artificial	72
4.3.5. Resultados y análisis de tendencia	73
4.4. Primer caso de estudio: Predicción de la presión de burbuja y el factor de volumen del aceite en la presión de burbuja	73
4.4.1. Adquisición y análisis de datos	73
4.4.2. Arquitectura y etapas de procesamiento de la RNA	74
4.4.3. Resultados y discusiones	75
4.4.4. Análisis de tendencia	83
4.4.5. Conclusiones	85
4.5. Segundo caso de estudio: Generación completa del comportamiento de la curva B_o	87
4.5.1. Introducción	87
4.5.2. Adquisición y análisis de datos	88
4.5.3. Arquitectura y etapas de procesamiento de la RNA	88
4.5.4. Análisis y resultados	90
4.5.5. Análisis de tendencia	99
4.5.6. Conclusiones	100
5. Conclusiones	101
A. Interfaces Open Fluid	105
Bibliografía	111

Índice de figuras

2.1. Modelo de neurona biológico	7
2.2. Forma esquemática de la transferencia de señal entre dos neuronas	8
2.3. Analogía de neuronas biológicas con uno artificial	9
2.4. Elementos básicos de una neurona artificial	13
2.5. Ejemplo de una estructura neuronal.	16
2.6. Clasificación de modelos de redes neuronales ^{1,2}	17
2.7. Capas en una RNA.	18
2.8. Red monocapa.	19
2.9. Ejemplo de redes multicapas.	20
2.10. Ejemplo de redes recurrentes.	21
2.11. Esquematización del algoritmo backpropagation.	25
2.12. Esquematización del algoritmo backpropagation.	26
2.13. Propagación de señales hacia adelante, feedforward.	27
2.14. Propagación de señales hacia adelante, feedforward.	27
2.15. Propagación de señales hacia adelante, feedforward.	28
2.16. Propagación de señal de error hacia atrás.	28
2.17. Actualización de pesos en la entrada de cada neurona.	29
3.1. Diferentes combinaciones de entradas y salidas usadas para desarrollar los modelos de redes neuronales.	40
3.2. Resultados del registro sintético generado por regresión múltiple.	41
3.3. Registro sintético de resistividad generado durante la verificación mediante el ejercicio 1, con la combinación A de entradas y salidas. Pozos 157 y 169 de la zona superior e inferior del Sur de Pensilvania.	42
3.4. Registro sintético de resistividad generado durante la verificación mediante el ejercicio 2, con la combinación A de entradas y salidas. Pozos 168 y 169 de la zona superior e inferior del Sur de Pensilvania.	42
3.5. Valores de obtenidos de R^2 en la zona superior del conjunto de datos del Sur de Pensilvania, mediante el ejercicio 1.	43
3.6. Valores de obtenidos de R^2 en la zona inferior del conjunto de datos del Sur de Pensilvania, mediante el ejercicio 1.	43
3.7. Valores de obtenidos de R^2 en la zona superior del conjunto de datos del Sur de Pensilvania, mediante el ejercicio 2.	44

ÍNDICE DE FIGURAS

3.8. Valores de obtenidos de R^2 en la zona inferior del conjunto de datos del Sur de Pensilvania, mediante el ejercicio 2.	44
3.9. Comparación de porosidad del núcleo y la porosidad estimada por la red neuronal en el pozo 31/4-3.	46
3.10. Prueba de sensibilidad de la porosidad-densidad transformada para los diferentes fluidos del poro: a) 30/9-1, b)30/9-B-40, c) 30/9-B-2	48
3.11. Comparación de la porosidad de la red neuronal y la porosidad-densidad transformada contra la porosidad del núcleo para el pozo: a) 30/9-1, b)30/9-B-40, c) 30/9-B-2	49
3.12. Gráfica de la porosidad del núcleo contra la porosidad de la red neuronal y porosidad del núcleo contra la porosidad-densidad transformada del pozo: a) 30/9-1, b)30/9-B-40, c) 30/9-B-2	50
3.13. Diagrama de bloque de un CM para la predicción de porosidad.	51
3.14. a) Comparación de bias y varianza de las redes con un ensamblaje promedio y OLC b) Correlación de porosidad de la red neuronal con la porosidad del núcleo.	52
3.15. a) Comparación de la porosidad del núcleo y la porosidad de la red neuronal por OLC del pozo 30/9-B-2, b) Gráfica de la porosidad del núcleo contra la porosidad de la RNA, c) Distribución de error	53
3.16. a) Comparación de la porosidad del núcleo y la porosidad de la red neuronal por OLC del pozo 30/9-B-24, b) Gráfica de la porosidad del núcleo contra la porosidad de la RNA, c) Distribución de error	54
3.17. Predicción de la presión de burbuja mediante: a) Standing y Standing modificado para Medio Oriente, b) Vazquez y Beggs y Vazquez y Beggs modificado para Medio Oriente, c) Al-Marhoun y Al-Marhoun modificado para el Medio Oriente, d) Modelo RNA	58
3.18. Predicción del factor de volumen del aceite en el punto de burbuja mediante: a) Standing y Standing modificado para Medio Oriente, b) Vazquez y Beggs y Vazquez y Beggs modificado para Medio Oriente, c) Al-Marhoun y Al-Marhoun modificado para el Medio Oriente, d) Modelo RNA	59
4.1. Arquitectura RNA: a) Presión de burbuja, p_b y b) Factor de volumen del aceite, B_{ob}	75
4.2. Curvas de errores: (a) Presión de burbuja, p_b y (b) Factor de volumen del aceite, B_{ob}	76
4.3. Gráficas de regresiones para el entrenamiento, validación y prueba del modelo de red de lap_b	77
4.4. Comparación de modelos de predicción para p_b	79
4.5. Comparación de modelos de predicción para p_b	80
4.6. Gráficas de regresión (B_{ob}): entrenamiento, validación y prueba.	81
4.7. Gráficas de regresiones para cuatro modelos.	82
4.8. Gráficas de número de muestras contra modelo empleado.	83

4.9. Comparación de modelos, variando R_g : (a) Modelos para p_b y (b) Modelos para B_{ob}	84
4.10. Comparación de modelos, variando T_y : (a) Modelos para p_b y (b) Modelos para B_{ob}	85
4.11. Comparación de modelos, variando $^{\circ}API$: (a) Modelo para p_b y (b) Modelo para B_{ob}	86
4.12. Comparación de modelos, variando γ_g : (a) Modelo para p_b y (b) Modelo para B_{ob}	87
4.13. Comportamiento baja, media y alta volatilidad, mediante B_{oD}	91
4.14. Comportamiento adimensional de los datos B_o de cada PVT.	92
4.15. Coeficientes de correlación para el modelo saturado	93
4.16. Coeficientes de correlación para el modelo bajosaturado.	94
4.17. Curva B_o generada por la red neuronal.	95
4.18. Comparación de valores reales contra valores estimados por la RNA. . .	96
4.19. Comparación de modelos para generar la curva completa de B_o	98
4.20. Tres curvas de B_o , mediante RNA.	99
A.1. Ventana de inicio RNA PVT.	106
A.2. Ventana de inicio para propiedades volumétricas.	107
A.3. Ventana del botón Importar datos.	108
A.4. Ventana del botón Normalización.	108
A.5. Ventana del botón Arquitectura RNA.	109
A.6. Ventana del botón Entradas y Salidas.	109
A.7. Ventana del botón Gráficas(Regresión lineal EVP).	110
A.8. Ventana Simular RNA.	110

Índice de tablas

3.1. Rango de los conjuntos de datos PVT.	57
3.2. Parámetros estadísticos obtenidos de los diferentes modelos de predicción para la P_b en el conjunto de datos de entrenamiento.	58
3.3. Parámetros estadísticos obtenidos de los diferentes modelos de predicción para la B_{ob} en el conjunto de datos de entrenamiento.	59
3.4. Parámetros estadísticos obtenidos de los diferentes modelos de predicción para la P_b en el conjunto de datos de validación cruzada.	60
3.5. Parámetros estadísticos obtenidos de los diferentes modelos de predicción para la B_{ob} en el conjunto de datos de validación cruzada.	60
4.1. Principales criterios propuestos para la clasificación de tipos de fluidos de los yacimientos.	70
4.2. Rangos de las propiedades usadas (aceite negro).	73
4.3. Parámetros estadísticos de las tres fases (p_b): entrenamiento, validación y prueba.	78
4.4. Resultados estadísticos de cada modelo de predicción de p_b	78
4.5. Parámetros estadísticos de las tres fases de RNA para B_{ob}	79
4.6. Rango de datos usados para las tres etapas de la RNA (B_{ob}).	81
4.7. Resultados estadísticos de cada modelo de predicción para B_{ob}	82
4.8. Rango de datos usados para el modelo saturado y bajosaturado.	89
4.9. Rango de datos usados para el modelo B_{ob}	93
4.10. Rango de datos usados para el modelo p_{ob}	94
4.11. Rango de datos usados para el modelo B_{oa}	95
4.12. Valores estimados de B_o por la red neuronal y del reporte PVT.	97
4.13. Rango de datos usados para el modelo saturado y bajosaturado.	98

Capítulo 1

Introducción

En la actualidad, las herramientas computacionales son desarrolladas desde diferentes perspectivas para poder proporcionar técnicas que permitan resolver problemas complejos; una de ellas es la inteligencia artificial (IA), una ciencia que está tomando gran auge y considerada como de las ramas más importantes de la ciencia de la computación.

La inteligencia artificial^{*} es una ciencia relativamente joven que surge en la década de los 50's, cuando los científicos e investigadores empezaron a considerar la posibilidad de poder implantar las habilidades y labores de los seres humanos en una máquina. La IA^{**} es un término que no ha sido totalmente definido, pero su objetivo es crear máquinas que permitan realizar actividades que requerirían de la inteligencia si lo realizara un humano³.

La IA ha sido usado en un amplio rango de campos, incluyendo en los diagnósticos médicos, bolsa de valores, control de robot, transporte, aviación, industrias pesadas, juguetes y juegos. La búsqueda, reconocimiento de voz, visión por computador y análisis de afinidad (como lo hace las páginas de Amazon y Netflix para sugerir productos que nos puedan gustar) son algunos campos de la IA con mayor éxito⁴. Hoy en día, si se dejara de usar repentinamente la IA en todas las industrias, no podríamos conseguir un préstamo en los bancos, los coches no se moverían, la electricidad no trabajaría, los trenes pararían, etc^{***}.

^{*}El término “Inteligencia Artificial” fue creado en 1956 por un profesor del Instituto Tecnológico de Massachusetts, John McCarthy.

^{**}En algunos libros y autores han escrito acerca de la IA y han definido como sistemas que combinan de manera sofisticada el hardware y software con elaborados bases de datos y modelos de procesamiento, basados en el conocimiento para demostrar las características de la toma de decisiones humana efectiva.

^{***}Durante los últimos treinta años, la IA ha sido implantado en la mayoría de las industrias.

Existen varias ramas o técnicas que pertenecen a la inteligencia artificial, las más populares^{5,6} son: la lógica difusa, redes neuronales y algoritmos genéticos. La lógica difusa* permite a la computadora analizar información del mundo real en una escala entre lo falso y lo verdadero. En los sistemas difusos, los valores de pertenencia o verdaderos se indican entre $[0.0,1]$, donde el 0.0 representa la falsedad total y el 1 la verdad absoluta. La probabilidad y los sistemas difusos operan sobre el mismo rango numérico, pero los conceptos son distintos. La probabilidad mide si algo va a ocurrir o no (o que pertenezca a un conjunto o no). En cambio, los sistemas difusos miden el grado en el cual algo ocurre o alguna condición existe. Las redes neuronales por su parte, se basan en aplicar el conocimiento ganado a través de la experiencia ante nuevos problemas o situaciones. El conocimiento la obtiene mediante la extracción de los datos experimentales (ejemplos o problemas que ya han sido resueltos), que fueron obtenidos por los seres humanos. Las redes neuronales se aplican en aquellos problemas que demandan de una solución computacional precisa o que requieren algoritmos muy extensos y complejos. Por otra parte, la idea de los algoritmos genéticos** es derivar estrategias de optimización, ya que muchos problemas tiene funciones objetivo complejas y la optimización tiende a finalizar en máximos y mínimos locales. Los algoritmos genéticos buscan optimizar (hallar el máximo o mínimo) una función objetivo utilizando los principios de la evolución biológica.

En el presente trabajo, nuestro interés es aplicar redes neuronales artificiales, por varias razones:

- 1) En la lógica difusa se requieren establecer reglas de inferencia, que sirve como guía para que el sistema se comporte adecuadamente o de manera deseada, de acuerdo al problema que se está analizando. Dichas reglas de inferencia (establece el grado de pertenencia) deben ser determinadas por un experto, por lo que resulta ser más difícil y laborioso. Por otra parte, los algoritmos genéticos están más enfocadas hacia la optimización de ciertas funciones.
- 2) El sistema de una red neuronal no requiere de un algoritmo específico para resolver un problema, solo se establecen relaciones entre las entradas y salidas. Tampoco requiere de mucho conocimiento respecto el tema a resolver.
- 3) Existen datos experimentales que pueden ser usados para “enseñar” a la red neuronal, y poder comparar el resultado real con la calculada.

*El estudio moderno de la lógica difusa y de las contribuciones tiene sus orígenes en el siglo XX, de las más sobresaliente es, cuando en 1965 Lofti A. Zadeh, publicó Fuzzy sets, donde describe las matemáticas de los conjuntos difusos, la cual propone funciones de pertenencia en el rango de $[0.0,1]$.

**La idea surgió en la tesis de J.D. Bagley : “El funcionamiento de los sistemas adaptables empleando algoritmos genéticos y correlativos”, en 1967⁵.

Actualmente los investigadores han implementado las Redes Neuronales Artificiales (RNA) para predecir algunas propiedades de la formación, principalmente enfocados a los registros geofísicos. Por otro lado, también se ha desarrollado en menor dimensión respecto a las propiedades de los fluidos, de tal manera que varios autores a la fecha del presente trabajo mencionan que las RNA han mostrado gran potencial en distintos ámbitos como es en la industria petrolera; tal herramienta ha resultado ser superior a otros métodos indirectos. Algunas de las publicaciones realizadas son las siguientes:

- Generando Registros Sintéticos de Pozos mediante Redes Neuronales Artificiales (RNA) Usando el Modelo MISO-ARMAX en el Campo Capiagua⁷
- Modelos para Predecir las Propiedades PVT de las salmueras de los Campos Petroleros⁸
- Aplicación de Simuladores de Redes Neuronales para Problemas de Interpretación de Registros de Pozos⁹
- Modelo de Red Neuronal para la Estimación de las Propiedades del Aceite del Medio Oriente¹⁰
- Aplicaciones de la Inteligencia-Virtual en la Ingeniería Petrolera: Red Neuronal Artificial¹¹

Conocer las propiedades de los fluidos es de suma importancia para los cálculos en ingeniería de yacimientos (balance de materia, recuperación mejorada, simulación numérica de yacimientos, etc.) y del diseño de instalaciones superficiales, sin embargo, estos estudios o mediciones de tales propiedades a menudo no están disponibles, algunas de las siguientes razones pueden ser:

- Las muestras no se han tomado para ahorrar costos
- Algunas veces las muestras obtenidas no son confiables
- El análisis PVT no están disponibles cuando es necesario
- Falta de personal especializada
- Para no generar una producción diferida de petróleo

Debido a las problemáticas mencionadas anteriormente, durante los últimos 60 años, los ingenieros han realizado importantes desarrollos para obtener de manera indirecta estas propiedades¹², mediante correlaciones empíricas. Cada correlación * fue desarrollado para un cierto rango de datos, de acuerdo a las características del yacimiento y

* las correlaciones empíricas técnicamente no se rigen por las leyes físicas del yacimiento¹³, porque cuando se desarrolla una correlación empírica en el modelo matemático solo se agregan parámetros constantes que hacen que se ajusten a los datos reales con las que se están trabajando.

1. INTRODUCCIÓN

del área geográfica con composiciones similares y grados API.

El objetivo del presente trabajo es desarrollar modelos de redes neuronales para determinar las propiedades de los fluidos petroleros de manera indirecta y con mayor exactitud, junto con una metodología de validación del cumplimiento de las leyes físicas del yacimiento de cada modelo de red desarrollado.

Por otro lado, el trabajo estará dividido en cinco capítulos, en el primer capítulo se presenta una breve introducción respecto a la inteligencia artificial, sus ramas, las principales áreas de aplicación y algunas publicaciones realizadas de las RNA en la ingeniería petrolera. En el segundo capítulo, se fundamenta su origen, historia, avances, la manera en que se clasifican y el algoritmo de aprendizaje que implementaremos en el presente estudio . Se documentarán varios ejemplos de aplicación en el capítulo tres, tratando de abarcar en varias disciplinas o enfoques. El capítulo cuatro es la parte medular del presente trabajo, ya que se desarrollará un modelo de RNA aplicado a la industria petrolera, específicamente en la predicción de las propiedades de los fluidos, a su vez se documentará brevemente el desarrollo de cada literatura revisada, esto con el fin de poder visualizar el estado de arte del desarrollo mencionado anteriormente. Por último, el capítulo cinco se establecerán las principales observaciones identificadas durante el desarrollo de la tesis, así también del cumplimiento de los objetivos establecidos, alcances e importancia.

Capítulo 2

Fundamentos de las Redes Neuronales Artificiales

2.1. Introducción

En los últimos años, los seres humanos han demandado distintos recursos para satisfacer tanto sus necesidades esenciales como sus deseos. Sin lugar a duda, la actividad tecnológica ha incrementado en las últimas décadas y en nuestros días resulta ser muy asombroso.

Se entiende por tecnología al conjunto de conocimientos técnicos y científicos que están ordenados, la cual, permiten construir y diseñar objetos y/o servicios que puedan satisfacer a las necesidades humanas. Con la tecnología, nacen aparatos y dispositivos, pero también surgen distintos términos en esta área, el de nuestro interés es: la red. La red, se entiende como un conjunto de entidades conectadas entre sí. Una red permite que circulen elementos materiales e inmateriales entre sus puntos de conexión.

En su búsqueda de mejora, el hombre ha mostrado interés en conocer el funcionamiento de su principal órgano, el cerebro, la cual, a través de las herramientas tecnológicas han pretendido acercarse o “igualarse” al funcionamiento del órgano cerebral.

El cerebro es un procesador de información con características muy particulares y complejas. Su principal función es procesar inmediatamente grandes cantidades de información que provienen de los sentidos, para combinarla y compararla con la información almacenada y dar respuestas adecuadas en nuevas situaciones.

Aunque todavía falta mucho por descubrir sobre la forma en que el cerebro aprende

a procesar la información, se han desarrollado modelos que tratan de imitar sus habilidades biológicas, a este tipo de modelos se le conoce como Redes Neuronales Artificiales.

Las computadoras convencionales son buenas y rápidas para resolver algoritmos aritméticos, pero no son buenas interactuando con datos deteriorados o de entornos, es decir, paralelismo masivo, tolerante a fallas y adaptabilidad¹⁴. El sistema de una red neuronal ayuda donde no podemos formular un algoritmo de solución o donde podemos conseguir resolver problemas mediante el uso de datos reales.

2.2. Redes Neuronales Artificiales

2.2.1. Relación de RNA con la Biología

Antes de abordar el estudio de las RNA es importante introducir conceptos básicos del sistema neuronales biológicos, con el fin de establecer el paralelismo de funcionamiento entre ambos.

La teoría neuronal comienza a desarrollarse con el científico Santiago Ramón y Cajal¹⁵, un gran neuroanatomista español descubridor de la estructura neuronal del sistema nervioso. Investigaciones preexistentes a la de Santiago Ramón y Cajal sostenían que el sistema nervioso estaba formado por una red continua de fibras nerviosas y la comunicación entre las neuronas era como tal. Sin embargo, en 1888, sobre las bases de sus investigaciones, Ramón y Cajal, demostró que el sistema nervioso en realidad estaba compuesto por una red de células individuales (las neuronas) ampliamente interconectadas entre sí. Además, observó en el microscopio los pequeños espacios vacíos que separaban unas neuronas de otras y estableció que la información fluye de una neurona a otra desde las dendritas hasta el axón, atravesando al cuerpo celular (soma), siendo lo anterior un gran descubrimiento para el campo de la neurociencia en el siglo XIX.

Existen neuronas de diferentes formas, tamaños y longitudes, por lo que, de acuerdo a sus atributos importantes determinarán las funcionalidades y utilidades de éstas.

Se estima que éste órgano fundamental, cuyo tamaño y desarrollo distingue a los seres humanos de otras especies, tiene 86 mil millones de neuronas y cada una de ellas se conecta con otras cinco mil¹⁶. Así que en nuestra cabeza hay 430 billones de sinapsis o conexiones de comunicación neuronal. El cerebro es cada vez más estudiado por la ciencia desde nuevos enfoques, se menciona que en la actualidad se observan las funcionalidades del cerebro en vivo y en tercera dimensión con equipos tecnológicos avanzados, porque el sistema nervioso humano aún guarda múltiples secretos sin develar.

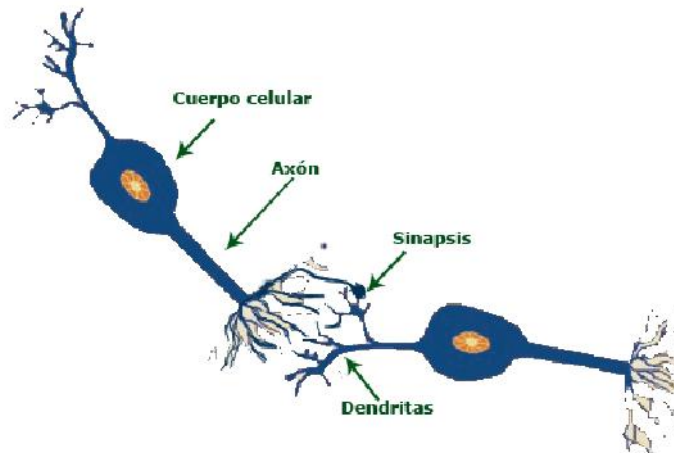


Figura 2.1: Modelo de neurona biológico

Una neurona es una célula (Fig. 2.1) viva y contienen los mismos elementos que forman parte de todas las células biológicas. La mayoría de los autores no consideran como un elemento la sinapsis dentro de una neurona, sin embargo, todos ellos los explican^{17,18,1,14}. En este trabajo se dividirá la estructura de una neurona en cuatro partes principales:

- **Sinapsis.** Las señales de entradas de otras neuronas o células son transferidas a una neurona mediante una conexión especial, la sinapsis. Cada conexión puede encontrarse usualmente en las dendritas de una neurona, algunas veces directamente en el soma.
- **Dendritas.** A través de éstas ramificaciones se reciben señales eléctricas que provienen de fuentes diferentes (otras células), lo cual, son transferidos al núcleo del cuerpo celular. Si existen varias ramificaciones de dendritas se le denomina árbol de dendritas.
- **Cuerpo celular o soma.** Se encarga de las actividades metabólicas de la neurona y recibe información de otras neuronas a través de conexiones o sinapsis.
- **Axón.** Esta rama tiene la funcionalidad de transferir impulsos o señales a otras células nerviosas. El axón es un cuerpo largo y extenso del soma, por otro lado, con frecuencia se ramifica extensamente cerca de su extremo.

Las neuronas presentan características peculiares y se diferencia de otras células vivas por su capacidad de comunicación. En términos generales, las dendritas y el soma reciben señales de entrada; después de que el soma ha recibido una gran cantidad de estimulante e inhibidor por las señales de la sinapsis o dendritas, el soma acumula las

señales. Tan pronto como la señal acumulada excede de un cierto valor (llamado valor umbral), el núcleo de la célula activa un pulso eléctrico que viaja a través del axón transmitiendo información a otras neuronas conectadas.

2.2.2. Proceso de transmisión de señales (naturaleza electroquímica)

En el punto de conexión de una neurona con otras, las transmisiones de señales se presentan de dos formas: eléctrica y química¹. La señal es generada en el núcleo de la neurona, ésta señal es de tipo eléctrico y viaja a lo largo del cuerpo del axón, cuando llega a los terminales axónicos de una neurona se transmite una señal de origen químico sobre las dendritas de las neuronas siguientes, las sustancias liberadas sobre las dendritas son moléculas transmisoras (neurotransmisores) que fluyen a través de unos contactos especiales, llamados sinapsis que tiene como función de receptor y se presenta en el punto de conexión entre los terminales axónicos y el extremo de las dendritas de una neurona (ver Fig. 2.2) . En general, podemos decir que la sinapsis es donde se unen las neuronas.

La información que fluye a través de la sinapsis son direccionales, en un único sentido. En las sinapsis más comunes no se presenta un contacto físico entre las neuronas, sino que éstas están separadas por un pequeño vacío de unas 0.2 micras¹. Debido a que se presenta el flujo de señal en una sola dirección se habla de dos tipos de neuronas: las **neuronas presinápticas** que son las que envían las señales y las **neuronas postsinápticas** que son las que reciben las señales (ver Fig. 2.2).




Figura 2.2: Forma esquemática de la transferencia de señal entre dos neuronas

La generación de señales son procesos complejos, sin embargo, se puede explicar

del siguiente modo: la neurona recibe impulsos procedentes de otras neuronas mediante las dendritas (entradas), así mismo, están conectadas con las terminales de las otras neuronas (salidas), la sinapsis. De acuerdo a la cantidad de sustancia química que se libera en la sinapsis se verá la efectividad (para que logre estimular a otra neurona debe superar el valor umbral) con la que la señal es transmitida a través de un parámetro, **peso**. El aprendizaje resulta de la modificación de estos pesos, junto con el procesamiento de información que realiza la neurona determinará el mecanismo básico de la memoria.

2.2.3. Analogía

La analogía que podemos establecer entre una neurona biológica y una neurona artificial es que las conexiones entre los nodos ($I_1 \dots I_i$) representan las dendritas y los axones (entradas), sin embargo, el axón puede funcionar como una salida (y), si se hace referencia como una neurona anterior a la que se está analizando. La conexión de los pesos ($W_1 \dots W_i$) representan la sinapsis y la aproximación umbral (elementos de la sumatoria del círculo, ver Fig. 2.3) representa la actividad realizada por el núcleo de la célula (soma).




Figura 2.3: Analogía de neuronas biológicas con uno artificial

2.2.4. Definición de Redes Neuronales Artificiales

Las redes neuronales artificiales o simplemente red neuronal se han definido de distintas formas, de las cuales podemos destacar las siguientes:

- *Una red neuronal es una representación artificial del cerebro humano que intenta simular sus procesos de aprendizaje.*
- *Una red neuronal artificial es una interconectividad grupal de neuronas artificiales que usan modelos matemáticos o modelos computacionales para procesar información basado en un enfoque conexionista para realizar cálculos.*
- *Un sistema de computación hecho por un gran número de elementos simples, elementos de proceso muy interconectados, los cuales procesan información por medio de un estado dinámico como respuesta a entradas externas.*
- *Una nueva forma de computación, inspiradas en modelos biológicos.*

Una definición más integrada, las redes neuronales artificiales es un modelo artificial que imita el funcionamiento del cerebro humano en su versión más simplificada, es decir, asimila el proceso de aprendizaje a través de la experiencia con el tratamiento de información y ejemplos, junto con las herramientas computacionales, la cual, está inspirada en un elemento de procesamiento que es la célula fundamental del sistema nervioso humano, la neurona.

2.2.5. Breve historia de las RNA

Es de gran relevancia iniciar con las principales contribuciones que se realizaron respecto al mundo de la computación. Hace más de cien años, cuando no existían las calculadoras digitales menos aún las computadoras, el 23 de julio de 1912 para ser precisos, nació en Inglaterra un destacado matemático y filósofo creador de la computación moderna: Alan Turing. En 1936, el científico Alan Turing* fue el primero en estudiar el cerebro como una forma de ver el mundo de la computación. Por otro lado, el matemático de origen Húngaro John Von Neumann, en los años 40 concibe una computadora basada en la lógica digital que opera ejecutando en serie las instrucciones que componen un algoritmo que se codifica en forma de programa, el cual se encuentra almacenado en memoria. Lo anterior se le conoce como la arquitectura de Von Neumann y es la base sobre la que se asientan la mayor parte de las computadoras digitales actuales¹. Ambos matemáticos ya habían concebido de que se podía incorporar la capacidad de pensar racionalmente en una de sus máquinas.

Los primeros teóricos que concibieron los fundamentos de la computación neuronal fueron Warren McCulloch, un neurofisiólogo y Walter Pitts, un matemático, y sus ideas

* Además de ser el inventor de la "Máquina Universal", fue el primero en diseñar una computadora que permitía jugar al ajedrez.

estaban basadas en que las neuronas operan mediante impulsos binarios. Ellos modelaron una red neuronal simple mediante circuitos eléctricos.

En 1949, Donald Hebb fue el primer desarrollador de la regla de aprendizaje. Su idea fue que el aprendizaje ocurría cuando se activaba ciertos cambios en una neurona. Se considera que los trabajos de Hebb son las bases de la teoría de RNA.

Frank Rosenblatt (1957) junto con otros colaboradores desarrollaron el neurocomputador, Mark I* Perceptrón. Esta es la red neuronal de reconocimiento de patrones más antigua que fue capaz de reconocer valores numéricos simples por medio de un sensor de imagen de 20 x 20 pixeles¹⁹.

Minsky y Papert (1969) demostraron matemáticamente que el Perceptrón no era capaz de aprender una función no lineal. Esto demostró que el modelo era muy débil, ya que las funciones no lineales son ampliamente utilizadas en la computación.

La investigación de las redes neuronales declina al inicio de 1970 y a mitad de la década de los 80's, sin embargo, algunos investigadores continuaron con su trabajo.

Entre 1985 y 1986, las redes neuronales retoman su importancia. Los investigadores, Paul Webors y David Rumelhart desarrollaron un algoritmo de aprendizaje para **redes de múltiples capas**, lo cual, lo nombraron como back propagation (retro-propagación). Con la red de retro-propagación, los investigadores refutaron la idea de que las redes son débiles y demostraron que éste modelo es capaz de aprender funciones no lineales.

Los modelos de redes neuronales son variados, al menos 50 tipos han sido explorados en investigación o han sido desarrollados para aplicaciones².

En la actualidad, las redes neuronales son aplicadas en muchas industrias, algunas de ellas son: la medicina, robótica, finanzas, automóviles, electrónica e industria petrolera. Por otro lado, Google ha sido líder de la Inteligencia Artificial y la ha usado para desarrollar muchos de sus servicios. En 2010, Sundai Pichai²⁰, CEO de la compañía Google, escribió sobre cómo la empresa usa sus gigantescas bases de datos, su prodigioso poder de cómputo y sus algoritmos de Inteligencia Artificial** para construir Google Translate. De acuerdo a la publicación realizada en Forbes, Pichai mostró estar decidido en mantener a Google en vanguardia, algunas de las investigaciones que es de gran interés para la compañía es el sistema AlphaGo (un sistema que venció al campeón mundial de Go), mejoramiento de reconocimiento de voz para Android y para ahorrar electricidad.

*Frank Rosenblant desarrolló diferentes versiones del Perceptrón, el primero Mark I.

**La IA es un término que generalmente se usa para hacer referencia a las redes neuronales, sin embargo, se dividen en tres modelos principales: RNA, Lógica difusa y algoritmos genéticos.

2.3. Componentes de un sistema neuronal artificial

2.3.1. Sistemas paralelos, distribuidos y adaptativos

Las RNA pretenden simular tres procesos principales que el sistema nervioso humano realiza, éstos son: procesamiento en paralelo, memoria distribuida y el aprendizaje adaptativo.

2.3.1.1. Procesamiento en paralelo

Este proceso es esencial si se quiere imitar el funcionamiento del sistema nervioso, ya que el cerebro humano es capaz de procesar varios datos al mismo tiempo, en consecuencia, le permite entender las cosas de forma mucho más rápida que si tuviera que ir interpretando lo que sucede en su entorno mediante un algoritmo definido o específico, un paso a la vez. Por ejemplo, cuando observamos una imagen, las neuronas de la visión se “reparten“ entre ellas las porciones de la imagen* que el ojo alcanza ver para poder procesarlo simultáneamente con miles de millones de neuronas a la misma vez. De manera similar, una red neuronal artificial reparte distintas porciones del problema entre todas sus neuronas o procesadores elementales, con lo que logra procesar los datos y encontrar una solución más rápida.

2.3.1.2. Memoria distribuida

Mientras que un procesador de información ocupa espacios de memorias bien definidas (se le asigna un espacio en el disco duro o en la memoria temporal), las RNA distribuyen su información por la sinapsis de la red, de modo que si una sinapsis de la red se daña, solo perdería una parte muy pequeña de la información. Además, los sistemas neuronales biológicos son redundantes, por consiguiente muchas neuronas y sinapsis pueden realizar un papel similar, por lo que el sistema resulta ser tolerante a fallos.

Las redes neuronales son los primeros modelos computacionales que tienen la capacidad de tolerar fallos. Respecto a la tolerancia a fallos se puede ver desde dos perspectivas: primero, las redes pueden trabajar o reconocer patrones con informaciones ruidosos, distorsionados o incompletos. Segundo, pueden seguir realizando su función aunque se destruya parte de la red.

*Se dice que el cerebro tarda aproximadamente $20ms$ en preprocesar una imagen compuesta por millones de píxeles, extraer sus características, analizarla e interpretarla.

2.3.1.3. Aprendizaje adaptativo

Esta característica es primordial y es la que hace más atractivas a las RNA. El modelo aprende a llevar ciertas tareas mediante un proceso de entrenamiento con ejemplos reales o ilustrativos. No requiere realizar un algoritmo, ni especificar funciones de distribución de probabilidad. Al decir que no requiere un algoritmo para resolver un problema, es porque ella puede generar su propia distribución de los pesos de los enlaces, que se van ajustando conforme se entrena la red, proceso de aprendizaje.

2.3.2. Elementos básicos de un sistema neuronal artificial

La mayoría de los modelos neuronales tienen elementos en común y comprenden principalmente de los siguientes componentes: función de propagación, función de activación y la función de salida (ver Fig. 2.4):

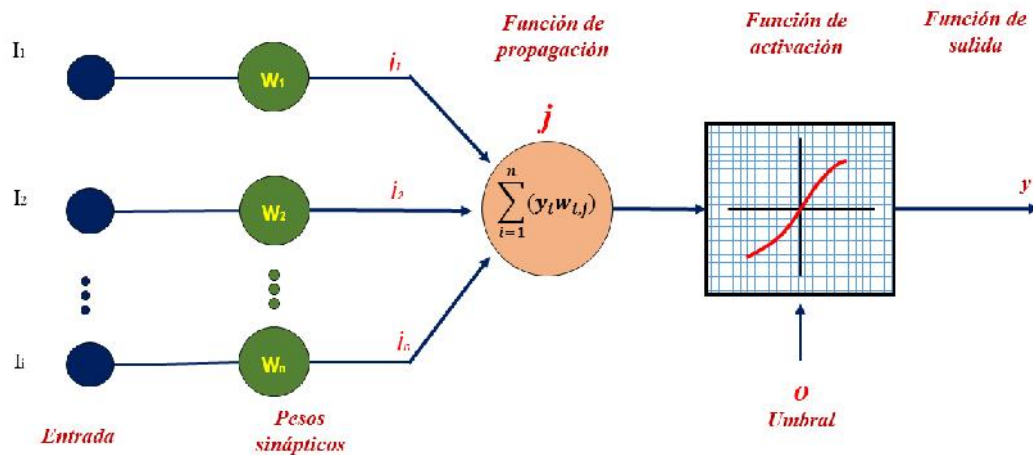


Figura 2.4: Elementos básicos de una neurona artificial

Normalmente un término más es agregado en el modelo de neurona artificial, la bias, que es insertado como una neurona¹⁹, y se usa para representar las conexiones de pesos, $w_{bias,j}$, con las neuronas, j , realmente el valor umbral, θ es quien representa el peso de cada bias. Podemos argumentar que la bias* es lo mismo que el valor umbral y el peso.

Las bias tienen el efecto de incrementar o disminuir la entrada neta de la función de activación, dependiendo si es positivo o negativo respectivamente²¹.

*La bias toma en cuenta dos cosas: 1) agrega una nueva entrada +1, y 2) agrega un peso sináptico que es igual a la bias.

2.3.2.1. Función de propagación

Para una neurona j la función de propagación recibe las salidas $y_{i_1}, y_{i_2}, y_{i_3}, \dots, y_{i_n}$ de otras neuronas $i_1, i_2, i_3, \dots, i_n$ (la cual son conectadas a j) y las transforma en una entrada neta, net_j , considerando las conexiones de los pesos w_{ij} . Por lo tanto, la entrada de una red es el resultado de la función propagación.

La multiplicación de la salida de cada neurona i por $w_{i,j}$, y la suma de todas ellas resulta:

$$net_j = \sum_{i=1}^n (y_i, w_{i,j}) \quad (2.1)$$

2.3.2.2. Función de transferencia o activación

La activación es el “estado de encendido” de una neurona. Cuando se habla de una neurona excitada o inhibida, significa que toma un valor positivo la neurona excitada y negativo cuando queda inhibida. Estos valores son determinados mediante alguna función de activación y lo que realiza es filtrar el valor obtenido con la regla de propagación para compararse con algún valor umbral y así determinar la salida.


Sobre los años, los investigadores han propuesto varias funciones para convertir entradas y salidas. Las funciones que son comúnmente usadas se describen en los siguientes párrafos.

E/P eje horizontal muestra la suma de las entradas

S/P eje vertical muestra el resultado de la función activación.

La mayoría de las funciones están diseñadas para valores entre 0 y 1.

Función umbral



La función de activación más simple es la función umbral binaria, lo que significa que sólo puede tomar dos valores. Si la entrada está por encima de un cierto umbral, la función cambia de un valor a otro.

1 si la suma de la entrada neta es positivo.


0 si la suma de la entrada neta es negativo.

$$y = f_{act}(net_j) = \begin{cases} 1 & \text{si } net_j \geq 0 \\ 0 & \text{si } net_j < 0 \end{cases}$$

Función lineal

La función lineal corresponde a la función $f(x) = x$, que produce:

- 1 si la suma de la entrada neta es negativo (<-1).
 - 1 si la suma de la entrada neta es positivo (>1).
- Si el valor de la suma de los pesos por las entradas se encuentra entre +1 y -1, corresponde a la función lineal.



$$y = f_{act}(net_j) = \begin{cases} -1 & \text{si } net_j < -c \\ net_j & \text{si } -c \leq net_j < c \\ 1 & \text{si } net_j > c \end{cases}$$

Función continua (sigmoidal).


La función sigmoidal es una función de activación que comúnmente es usada para construir una red neuronal. Es una expresión diferenciable y estrictamente incremental.

Una función de activación sigmoidal puede escribirse en la siguiente forma:

$$y = f_{act}(net_j) = \frac{1}{1 + e^{-\alpha * net_j}}$$

Esta función produce:

- ≈ 0 para valores de entradas negativos grandes.
 - 1 para valores de entradas positivos grandes.
- α es un parametro que cambia la pendiente de la función sigmoidal.



2.3.2.3. Función de salida

La función de salida de una neurona j calcula los valores que se transfieren a las otras neuronas conectadas a j .

Definición (Función de salida). Si j es una neurona. La función de salida:

$$f_{salida}(a_j) = y_j \tag{2.2}$$

calcula el valor de salida y_j de la neurona j del estado de activación a_j .

Generalmente la función de salida es simplemente la función identidad, de modo que el estado de activación de la neurona se considera la propia salida.

$$f_{salida}(a_j) = y_j, \text{ o } y_j = a_j \quad (2.3)$$

2.3.3. Ejemplo

La neurona que se muestra en la Fig.2.5 consiste de cuatro entradas con los pesos.

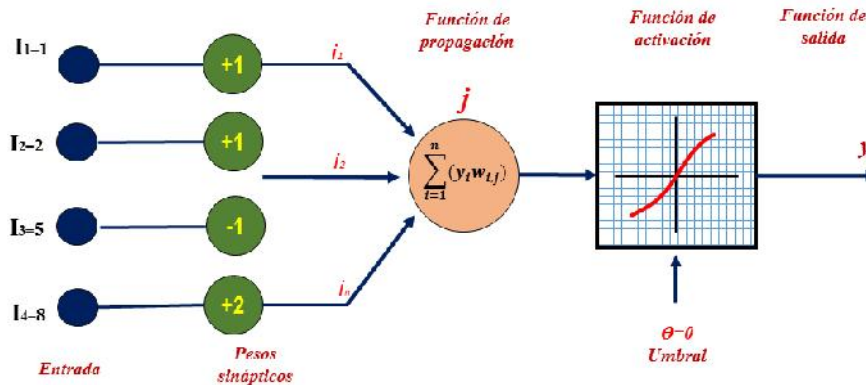


Figura 2.5: Ejemplo de una estructura neuronal.

La entrada de la red, net_j , antes de la etapa de la función de activación, es:

$$net_j = I_{in} w_{i,j} [1 \ 2 \ 5 \ 8] \begin{bmatrix} +1 \\ +1 \\ -1 \\ +2 \end{bmatrix} = 14$$

$$= (1 * 1) + (2 * 1) + (5 * -1) + (8 * 2) = 14$$

Con una función de activación binaria la salida de la neurona es:

$$y(umbral) = 1;$$

2.4. Clasificación de las Redes Neuronales Artificiales

Actualmente existen una gran variedad de modelos de redes neuronales; en la literatura podremos encontrar que se pueden realizar clasificaciones o taxonomías*, de acuerdo a su arquitectura, en función del tipo de aprendizaje y de acuerdo a sus aplicaciones (Fig.2.6).

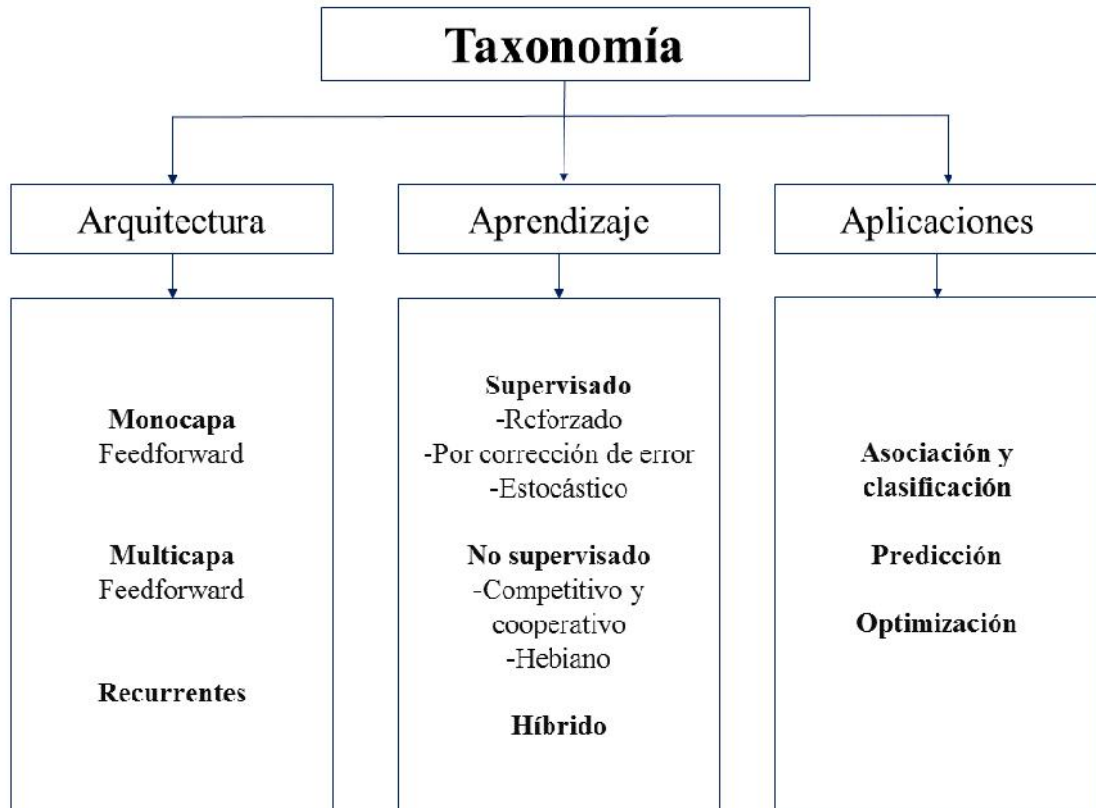


Figura 2.6: Clasificación de modelos de redes neuronales^{1,2}.

2.4.1. Por su arquitectura

Cuando los modelos de las RNA se clasifican por su topología o arquitectura, ésta consistirá en su organización y disposición de las neuronas en la red, la cual, formarán capas o agrupaciones de neuronas que están entre la entrada y salida de la red. Por lo

*En este contexto hace referencia a la ordenación de un grupo de cosas que tienen características comunes.

2. FUNDAMENTOS DE LAS REDES NEURONALES ARTIFICIALES

anterior, los parámetros fundamentales que encontraremos en esta arquitectura de red son: los números de capas, números de neuronas por capa, el grado de conectividad y el tipo de conexiones entre las neuronas (unidireccionales o recurrentes).

Los modelos de las RNAs pueden formar varias agrupaciones y se podrán distinguir tres tipos de capas (ver Fig.2.7):

- 1.- **De entrada.** Son conjuntos de neuronas que reciben información proveniente de fuentes externas de la red. Esta capa no procesa información, simplemente distribuye a las demás capas.
- 2.- **Ocultas.** Son capas internas de la red y no tiene contacto directo con el exterior. Ésta capa estará entre la capa de entrada y la capa de salida, sin embargo, el número de niveles ocultos puede ser entre cero y un número elevado.
- 3.- **De salida.** Es la última capa que puede existir en una red y su función es transferir información al exterior.

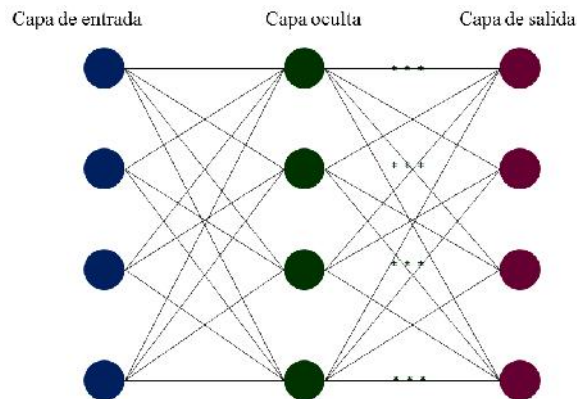


Figura 2.7: Capas en una RNA.

Los conjuntos de neuronas de una RNA forman conexiones entre ellas; esta conectividad está relacionada con la forma en que las salidas de las neuronas están canalizadas para convertirse en entradas de otras neuronas.

Las neuronas de las capas ocultas pueden estar interconectadas de diferentes maneras. El número de capas que tendrá una red definirá una clasificación interna de la arquitectura de la red. Esta clasificación suele distinguir entre redes de una sola capa y las redes de múltiples capas.

2.4.1.1. Redes monocapa (1 capa)

Una red de una sola capa consiste de una sola capa de pesos, donde las entradas son directamente conectadas a las salidas, es la vía de una serie de pesos. Los enlaces sinápticos son pesos que están conectados en cada entrada para cada salida. La suma de los productos de los pesos y las entradas es calculada en cada nodo (neurona), en la Fig.2.8 se puede observar un esquema de este tipo de red. En las redes monocapa, se establecen conexiones laterales entre las neuronas que pertenecen a la única capa que constituye la red, también pueden existir conexiones autorrecurrentes, es decir, salida de una neurona conectada a su propia entrada^{2, 1, 19}.

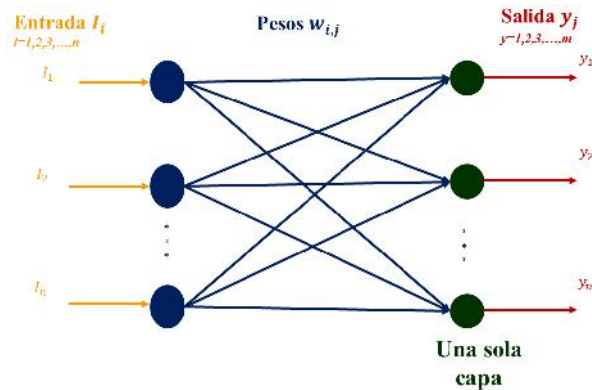


Figura 2.8: Red monocapa.

Este tipo de red se utiliza típicamente en tareas relacionadas con lo que se conoce como autoasociación, por ejemplo, para generar informaciones en una red incompleta o para depurar informaciones distorsionadas.

2.4.1.2. Redes de múltiples capas

Se denominan redes multicapas cuando disponen de conjuntos de neuronas agrupados en varios niveles de capas. La arquitectura de esta clase de red, además de que tiene una capa de entrada y una capa de salida, también tiene uno o más capas intermedias llamadas capas ocultas (ver Fig. 2.9). Las unidades de cálculo de la capa oculta son conocidos como neuronas ocultas¹⁴.

Generalmente, todas las neuronas de una capa reciben señales de entrada de otra capa anterior y la capa receptora envía las señales de salida a una capa posterior, cuando se realiza este tipo de conexión se le denomina como conexiones hacia adelante (feedforward). En este tipo de red no existen las conexiones hacia atrás y normalmente tampoco son autorecurrentes ni laterales.

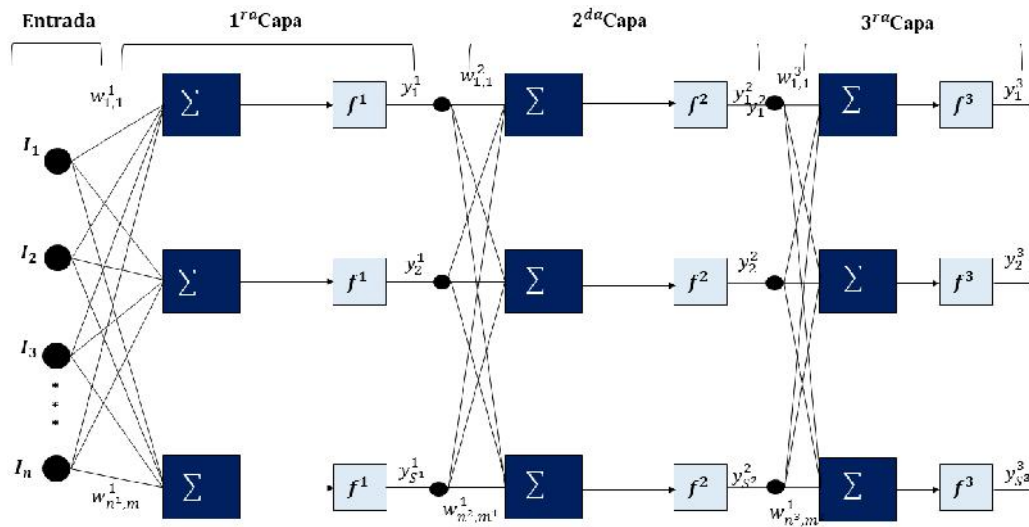


Figura 2.9: Ejemplo de redes multicapas.

Sin embargo, existe la posibilidad de conectar las salidas de las neuronas de las capas posteriores a las entradas de las capas anteriores, éste tipo de conexión se le conoce como conexiones hacia atrás (feedback). También puede existir combinación de conexiones. En general, las redes feedforward/feedback suelen ser bicapa, existiendo por tanto dos conjuntos de pesos: los correspondientes a las conexiones feedforward de la primera capa que va hacia la segunda y los de las conexiones feedback de la segunda a la primera.

2.4.1.3. Recurrentes

Las redes recurrentes son diferentes a las arquitecturas de las redes feedforward. Éstas contienen una retroalimentación hacia atrás o simplemente retroalimentación, i.e., algunas capas de sus salidas son conectadas a sus entradas y debe tener al menos un ciclo de retroalimentación (Fig. 2.10).

2.4.2. Por los mecanismos de aprendizaje

Existen muchas definiciones del término aprendizaje y es necesario tener nociones desde una perspectiva psicológica, para nuestro fin, podemos enfocarnos en la siguiente definición: “El aprendizaje es un cambio relativamente permanente en el comportamiento que refleja una adquisición de conocimientos y habilidades a través de la experiencia y que puede incluir el estudio, la instrucción, la observación o la práctica. Los cambios en

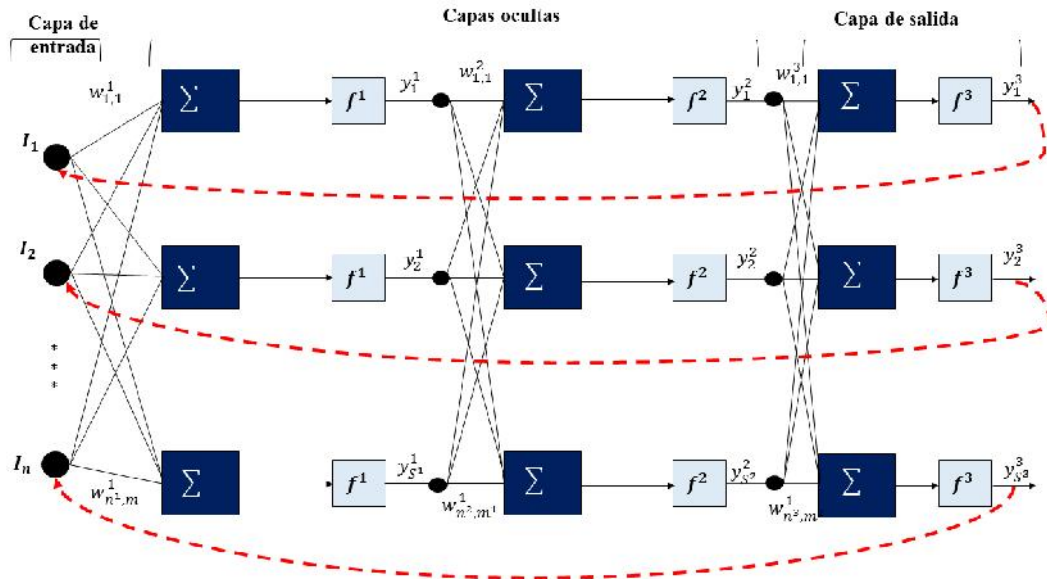


Figura 2.10: Ejemplo de redes recurrentes.

el comportamiento son razonablemente objetivos y por lo tanto, pueden ser medidos”^{*}. La analogía que podemos realizar con la definición anterior es que los conocimientos y habilidades de una RNA estarán dadas por sus pesos sinápticos y la experiencia la obtiene con la información suministrada a la red neuronal (datos de entrada), los estudios, la instrucción y observación determinarán sus unidades de procesamiento, las neuronas, y con base a esos estudios podrá determinar fenómenos de interés, podrán ser medidos. De acuerdo a lo anterior, desde un contexto de las RNA, el aprendizaje es el proceso por el cual una red modifica sus pesos en respuesta a la información de entrada.

Para construir una RNA, se debe partir de un cierto modelo de neurona y de una determinada arquitectura de red, estableciéndose pesos sinápticos iniciales como nulos o aleatorios². Para que la red pueda operar es necesario entrenarla y someterlo a pruebas con cierta regla de aprendizaje.

En general, se suelen considerar dos tipos de reglas de aprendizaje, la que se conoce como supervisada y no supervisada. El aprendizaje supervisado se diferencia de la otra por la existencia de un agente externo, la cual controla el proceso de aprendizaje de la red.

^{*}Papalia, D. E. Psicología, 1990, pág. 164.

2.4.2.1. Redes con aprendizaje supervisado

Este tipo de aprendizaje se caracteriza porque se someten a una etapa conocida como entrenamiento y para poder ejecutar este proceso se requiere de un agente externo (supervisor o maestro) que determina la respuesta que debería generar la red a partir de una entrada determinada.

Este tipo de aprendizaje consiste en construir un modelo neuronal que permita estimar relaciones entre las entradas y las salidas. Generalmente los datos de salida no coincidirán con los datos reales, por lo que generará un margen de error en el modelo.

El aprendizaje supervisado puede llevarse a cabo en tres formas:

- 1.- **Aprendizaje por corrección de error.** Se lleva a cabo ajustando los pesos de las conexiones de la red en función de la diferencia entre los valores deseados y los obtenidos en la salida, de acuerdo al margen de error cometido.
- 2.- **Aprendizaje por refuerzo.** Este tipo de aprendizaje es más lento que el anterior ya que la salida de la red no puede compararse al valor deseado para poder obtener el error cometido. El funcionamiento de esta red es muy similar a los métodos numéricos. La función del supervisor en este caso es indicar mediante una señal de refuerzo si la salida de la red se ajusta a la deseada (éxito=+1 o fracaso=-1) y en función de ello se ajustan los pesos basándose en un mecanismo de probabilidades, realmente puedes tener el valor real, pero no le enseñas a la red.
- 3.- **Aprendizaje estocástico.** Básicamente consiste en realizar cambios aleatorios en los pesos y evaluar su efecto a partir del objetivo deseado y de distribuciones de probabilidades.

2.4.3. Redes con aprendizaje no supervisado

También son conocidos como redes con aprendizaje autosupervisado o autoorganizado; este tipo de red no requiere de un agente externo para realizar el ajuste de sus pesos sinápticos. La red no recibe ninguna información que le pueda indicar si la salida es correcta o no, por ello, se dice que estos tipos de redes son capaces de autoorganizarse.

En cuanto a los procesos de aprendizaje de las redes no supervisadas se pueden clasificar en dos tipos: aprendizaje Hebbiano y aprendizaje competitivo y cooperativo.

2.4.3.1. Aprendizaje Hebbiano

El aprendizaje Hebbiano fue postulado por Donald O. Hebb (1949), y consiste en el ajuste de pesos de las conexiones de acuerdo con la correlación (multiplicación en

caso de los valores binarios +1 y -1) de los valores de activación (salidas) de las dos neuronas conectadas:

$$\delta w_{i,j} = x_i y_j \quad (2.4)$$

En esta regla, el patrón de entrada y salida son los pares x_i, y_j la cual está asociada al peso sináptico. Así, si las dos unidades son activas (positivas), se produce un reforzamiento de la conexión, caso contrario, se produce un debilitamiento de la conexión.

2.4.3.2. Aprendizaje competitivo y cooperativo

Está claro que en todas las redes inicialmente deben ser suministradas por informaciones y en el proceso se ajustan los pesos. En las redes de este tipo, cuando se le presenta una información de entrada, sólo una de las neuronas de salida a la red o un cierto grupo de neuronas pueden llegar activarse. Por lo tanto, el aprendizaje competitivo se refiere a que las neuronas deben alcanzar un estímulo para que puedan activarse y solo algunas lo logran (las que alcanza el valor de respuesta máximo). Las conexiones de las neuronas se dan en todas las capas de la red, existiendo en estas neuronas conexiones recurrentes de autoexcitación y conexiones de inhibición por parte de las neuronas vecinas, si se logran activar alguna de ellas por alguna neurona vecina se dice que es cooperativo.

2.4.3.3. Aprendizaje híbrido

En algunas redes pueden llegar a combinarse el aprendizaje, el supervisado y no supervisado, y pueden presentarse en distintas capas de neuronas.

2.4.4. Por sus aplicaciones

Se han realizado muchas aplicaciones con las RNA y han sido muy exitosas, principalmente para el procesado de señales e imágenes, reconocimiento de voz y caracteres, control de robots, inspección industrial, etc.

Las aplicaciones de las RNA pueden clasificarse de la siguiente forma: Asociación (memoria asociativa) y clasificación, predicción y optimización.

2.4.4.1. Asociación y clasificación

Idealmente un clasificador debería ser entrenado para que cuando se le presente una versión distorsionada ligeramente del patrón, pueda ser reconocida correctamente sin problemas. De manera similar, la red debe ser capaz de poder omitir el ruido y recuperar una señal limpia. El objetivo de una red de asociación es recuperar un patrón enteramente o un conjunto de patrones, dado el conjunto total.

2.4.4.2. Predicción

Se puede entender a un problema de extrapolación o interpolación. El sistema es entrenado con un gran conjunto de datos, muestras de entrenamiento, basados en un procedimiento de aprendizaje supervisado.

Una red se considera que está entrenada con éxito si logra aproximar los valores de la muestra de entrenamiento. El objetivo de este entrenamiento es dar una respuesta correcta o aproximada a la salida de la red para un estímulo de entrada con la que nunca fue entrenada la red.

2.4.4.3. Optimización

Las RNA son una herramienta interesante para la optimización de aplicaciones, que normalmente implica la búsqueda mínima absoluta de una función energía. Una vez definida la función energía se determinan los pesos sinápticos. El mayor inconveniente asociado al problema de optimización es la alta posibilidad de converger hacia un mínimo local, en vez de hacia un mínimo absoluto.

2.5. Modelo Backpropagation

Minsky y Papert (1969) demostraron que una red de una sola capa feed-forward puede tener muchas restricciones, pero ellos no presentaron una solución. Las limitaciones que se presentaron en tal red fue un factor significativo para que declinara el interés para seguir desarrollando los modelos de las redes neuronales en los años 70. El descubrimiento (por muchos investigadores independientes) de un método general efectivo de entrenamiento de una red neuronal multicapas, backpropagation, fue propuesto en 1986 por Rumelhart, Hinton y Williams. La idea central de esta solución es que los errores de las unidades de las capas ocultas son determinadas por retropropagación de errores de las unidades de la capa de salida.

La naturaleza general del método de retropropagación (multicapa, red feedforward entrenado por backpropagation) es que puede ser usado para resolver problemas en muchas áreas²². El entrenamiento de una red de retropropagación (Fig. 2.11) se puede dividir en las siguientes tres etapas:

- **Entrenamiento Feedforward con señales de entrada.**

Cada nodo de entrada recibe una señal, la cual es enviado a todas las unidades ocultas.

Cada unidad oculta determinan una activación para enviar señales a los otros nodos ocultos hasta llegar a todos los nodos de la capa de salida.

- Retropropagación de errores.

Cada nodo de salida compara su valor de activación o calculado con el valor de salida deseada.

Basado en estas diferencias, el error es propagado hacia los nodos anteriores,

Regla Delta.

- Ajustes de pesos

Todos los pesos se calculan simultáneamente basado en los errores que fueron propagados en la red.

Backpropagation puede ser considerado como la generalización de la regla delta para la función de activación en redes de múltiples capas. La regla delta solo trabaja para la capa de salida, backpropagation o generalización de la regla delta, es un camino para crear valores deseados en las capas ocultas.

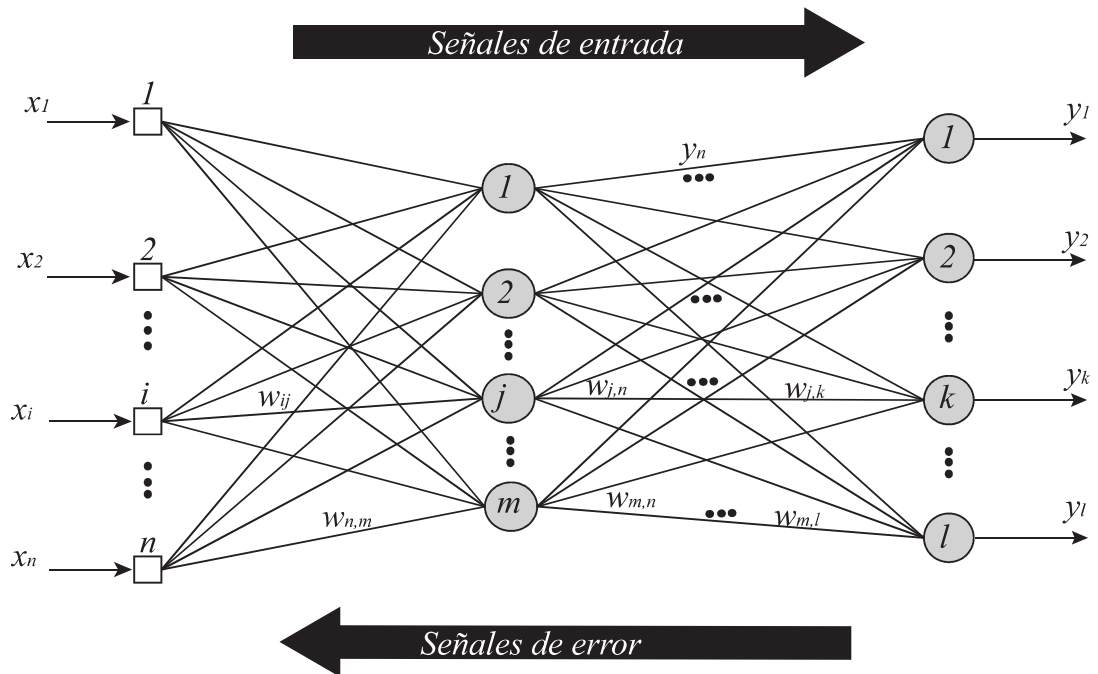


Figura 2.11: Esquematización del algoritmo backpropagation.

2.5.1. Principios para entrenar una red multicapa empleando el algoritmo de retropropagación.

Existen variaciones del backpropagation que proporciona métodos para acelerar la convergencia de manera más práctica. Sin embargo, el método de retropropagación nació con la implementación del algoritmo del gradiente descendente. Para fines explicativos, se utiliza el algoritmo mencionado anteriormente para describir el principio básico de funcionamiento, ya que todas presentan la misma estructura.

2.5.1.1. Descripción gráfica del algoritmo Backpropagation.

Para que una red neuronal lleve a cabo su aprendizaje, debemos entrenarlo con un conjunto de datos. El conjunto de datos de entrenamiento consiste de señales de entradas (x_1, x_2, \dots, x_n) asignado con su correspondiente objetivo (salida deseada) denominados z , Fig. 2.12.




Figura 2.12: Esquemización del algoritmo backpropagation.

El entrenamiento de la red es un proceso iterativo. En cada iteración los coeficientes de los pesos son modificados usando un nuevo dato para el conjunto de entrenamiento. Nosotros podemos determinar los valores de las señales de salidas para cada neurona en cada capa de la red.

Los símbolos y_n representan la salida de la neurona n y cuando tenemos $w_{m,n}$ representan los pesos de las conexiones entre la salida de la neurona m y la entrada de la neurona n en la siguiente capa, esto es la propagación de señales en la capa oculta (ver Fig. 2.11).

En las Figuras 2.13, 2.14 y 2.15 se ilustran la propagación de señales a través de la red, $(w_{(x_n),m})$ representa los pesos de las conexiones entre la red de entrada x_n y la neurona m en la capa siguiente.




Figura 2.13: Propagación de señales hacia adelante, feedforward.

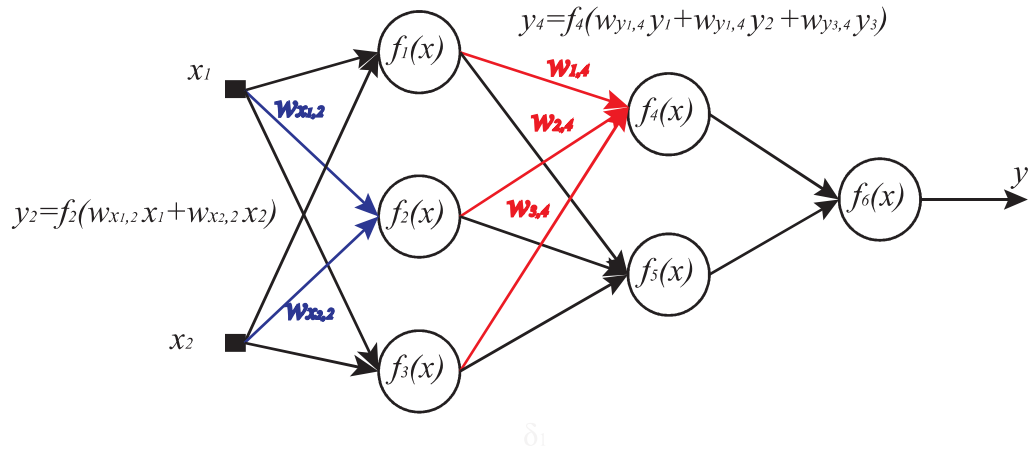


Figura 2.14: Propagación de señales hacia adelante, feedforward.

2. FUNDAMENTOS DE LAS REDES NEURONALES ARTIFICIALES




Figura 2.15: Propagación de señales hacia adelante, feedforward.

La última propagación de señal en la red, la salida y , es comparado con el valor deseado, que se encuentra reportado en el conjunto de datos de entrenamiento, la diferencia de $z - y$ se denomina error, δ . Es imposible conocer directamente el error en las neuronas de las capas internas, porque los valores de salida de éstas neuronas son desconocidas. La idea de este algoritmo es propagar la señal de error hacia atrás a todas las neuronas, esto es, las señales de salidas fueron las entradas de las últimas neuronas (ver Fig.2.16).




Figura 2.16: Propagación de señal de error hacia atrás.

Cuando la señal de error es calculada en cada neurona, los pesos de entrada pueden modificarse, $w'_{m,n}$, en la Figura 2.17 se ejemplifica en algunas neuronas la actualización

de los pesos. La fórmula $\frac{df(e)}{de}$ representa la derivada de la función de activación, donde e es la entrada neta, net . El coeficiente η afecta la velocidad de aprendizaje y pueden seleccionarse por distintos métodos. Uno de ellos implica que al inicio del proceso de entrenamiento se elige un valor grande, el cual va descendiendo gradualmente conforme avanza el proceso. El segundo método comienza con parámetros pequeños que aumentan a medida que el proceso avanza y nuevamente disminuye en la etapa final⁵.




Figura 2.17: Actualización de pesos en la entrada de cada neurona.

2.5.1.2. Etapas de entrenamiento

El objetivo de esta sección es realizar un resumen de las principales ecuaciones que serán necesarios de implementar en el algoritmo para poder resolver algún problema, la derivación. Las principales etapas y pasos que se deben ejecutar en el algoritmo de retropropagación del error, son las siguientes

Etapas 0. Inicializar los pesos (Conjunto de valores aleatorios pequeños).

Etapas 1. Mientras la condición “parar” sea falsa, realizar los pasos 2-9.

Etapas 2. Para cada par de entrenamiento, ejecutar las etapas 3-8.

Feedforward

Etapas 3. Para cada unidad de entrada ($X_i, i = 1, 2, 3, \dots, n$) recibe una señal x_i y se envía esta señal a todas las unidades en la capa siguiente (unidades ocultas).

Etapas 4. Cada unidad oculta ($a_{inj}, j = 1, 2, 3, \dots, m$) suma los pesos de las señales de entrada.

$$a_{inj} = net_{inj} = \sum_{i=1}^n x_i w_{i,j} \quad (2.5)$$

aplicamos la función de activación para calcular la señal de salida,

$$a_j = f(net_{inj}) \quad (2.6)$$

y se envía la señal a todas las unidades de la capa siguiente.

Etapas 5. Sumas cada unidad de salida ($Y_k, k = 1, 2, 3, \dots, l$) con los pesos en la señal de entrada,

$$y_{ink} = net_k = \sum_{j=1}^m a_j w_{j,k} \quad (2.7)$$

aplicando la función de activación obtenemos la señal de salida,

$$y_k = f(y_{ink}) \quad (2.8)$$

Retropropagación del error

Etapas 6. Cada unidad de salida ($Y_k, k = 1, 2, 3, \dots, l$) recibe el valor deseado correspondiente al patrón de entrenamiento, calcula el error,

$$\delta_k = (z_k - a_k) f'(y_{ink}), \quad (2.9)$$

con este valor se puede calcular el término de corrección de peso (usado para actualizar el peso $w_{j,k}$ más adelante).

Etapa 7. Cada unidad oculta ($a_j, j = 1, 2, 3, \dots, m$) suma esta entrada delta,

$$\delta_{inj} = \sum_{k=1}^l \delta_k w_{j,k}, \quad (2.10)$$

multiplicamos por la derivada de la función de activación para calcular el error, esto es para j-ésima unidades ocultas,

$$\delta_j = \delta_{inj} f'(a_{inj}), \quad (2.11)$$

Actualización de pesos

Etapa 8. Cada unidad de salida ($Y_k, k = 1, 2, 3, \dots, l$) se deberá actualizar su peso. La regla de cambio de pesos para la capa de salida,

$$\begin{aligned} \Delta w_{j,k} &= \eta \delta_k a_j \\ w_{j,k}(\text{Nuevo}) &= w_{j,k}(\text{Anterior}) + \Delta w_{j,k} \end{aligned} \quad (2.12)$$

ahora, para realizar la actualización de los pesos en la unidad de entrada a una unidad oculta, se calcula de la siguiente manera:

$$\begin{aligned} \Delta w_{i,j} &= \eta \delta_j a_j \\ w_{j,k}(\text{Nuevo}) &= w_{j,k}(\text{Anterior}) + \Delta w_{i,j} \end{aligned} \quad (2.13)$$

- Etapa 9. Establecer una condición “detener”, cuando se cumpla lo establecido.

Capítulo 3

Ejemplos de Redes Neuronales

3.1. Caso de estudio 1: Reconocimiento de caracteres

3.1.1. Introducción

Las redes neuronales empezaron a ganar popularidad con la solución del problema de reconocimiento de caracteres(o patrones). Por lo tanto, aunque no está directamente relacionado con la ingeniería petrolera, se considera que es de gran importancia incluirlo en el presente capítulo.

En este caso de estudio²³ se ejemplificará el problema de reconocimiento de caracteres^{*} usando el procedimiento de aprendizaje de backpropagation. Nuestra tarea es enseñar a la red neuronal a reconocer 3 caracteres, es decir, cada plano tendrá sus respectivos pares [0,1],[1,0] y [1,1] para formar cada letra. También se producirá una señal de error, [0,0], en respuesta a otros caracteres.

3.1.2. Diseño de la red neuronal

(a) Estructura: La red neuronal consiste de tres capas, cada capa con 2 neuronas, una capa de salida y dos capas ocultas. Existen 36 entradas a la red. En este caso particular se implementa la función sigmoideal:

$$y = \frac{1}{1 + \exp(-z)} \quad (3.1)$$

es elegida como una función de activación no lineal. Los términos umbrales (igual a 1) y pesos son incluidos en la estructura de la red.

^{*}Calculado por Maxim Kolesnikov, ECE Dept., Universidad de Illinois, Chicago, 2005.

3. EJEMPLOS DE REDES NEURONALES

(B) Diseño de base de datos: Se “enseñará” a la red a reconocer los caracteres ‘A’, ‘B’ y ‘C’. Para entrenar a la red y producir una señal de error, usaremos otros 6 caracteres ‘D’, ‘E’, ‘F’, ‘G’, ‘H’ e ‘I’. Para comprobar si el aprendizaje de la red logra reconocer los errores, se usa otros 3 caracteres ‘X’, ‘Y’ y ‘Z’. Podemos notar que el objetivo es comprobar la respuesta de la red a errores para los caracteres que no fueron mostrados a la red durante el proceso de entrenamiento.

Los caracteres que serán reconocidos están dados en una matriz de 6x6. De los 36 elementos (píxeles) es un conjunto de 0 y 1. Las representaciones de los caracteres están dadas en las siguientes matrices de 6x6:

A:	<table border="1"><tr><td>0</td><td>0</td><td>1</td><td>1</td><td>0</td><td>0</td></tr><tr><td>0</td><td>1</td><td>0</td><td>0</td><td>1</td><td>0</td></tr><tr><td>1</td><td>0</td><td>0</td><td>0</td><td>0</td><td>1</td></tr><tr><td>1</td><td>1</td><td>1</td><td>1</td><td>1</td><td>1</td></tr><tr><td>1</td><td>0</td><td>0</td><td>0</td><td>0</td><td>1</td></tr><tr><td>1</td><td>0</td><td>0</td><td>0</td><td>0</td><td>1</td></tr></table>	0	0	1	1	0	0	0	1	0	0	1	0	1	0	0	0	0	1	1	1	1	1	1	1	1	0	0	0	0	1	1	0	0	0	0	1	B:	<table border="1"><tr><td>1</td><td>1</td><td>1</td><td>1</td><td>1</td><td>0</td></tr><tr><td>1</td><td>0</td><td>0</td><td>0</td><td>0</td><td>1</td></tr><tr><td>1</td><td>1</td><td>1</td><td>1</td><td>1</td><td>0</td></tr><tr><td>1</td><td>0</td><td>0</td><td>0</td><td>0</td><td>1</td></tr><tr><td>1</td><td>0</td><td>0</td><td>0</td><td>0</td><td>1</td></tr><tr><td>1</td><td>1</td><td>1</td><td>1</td><td>1</td><td>0</td></tr></table>	1	1	1	1	1	0	1	0	0	0	0	1	1	1	1	1	1	0	1	0	0	0	0	1	1	0	0	0	0	1	1	1	1	1	1	0	C:	<table border="1"><tr><td>0</td><td>1</td><td>1</td><td>1</td><td>1</td><td>1</td></tr><tr><td>1</td><td>0</td><td>0</td><td>0</td><td>0</td><td>0</td></tr><tr><td>1</td><td>0</td><td>0</td><td>0</td><td>0</td><td>0</td></tr><tr><td>1</td><td>0</td><td>0</td><td>0</td><td>0</td><td>0</td></tr><tr><td>1</td><td>0</td><td>0</td><td>0</td><td>0</td><td>0</td></tr><tr><td>0</td><td>1</td><td>1</td><td>1</td><td>1</td><td>1</td></tr></table>	0	1	1	1	1	1	1	0	0	0	0	0	1	0	0	0	0	0	1	0	0	0	0	0	1	0	0	0	0	0	0	1	1	1	1	1
0	0	1	1	0	0																																																																																																												
0	1	0	0	1	0																																																																																																												
1	0	0	0	0	1																																																																																																												
1	1	1	1	1	1																																																																																																												
1	0	0	0	0	1																																																																																																												
1	0	0	0	0	1																																																																																																												
1	1	1	1	1	0																																																																																																												
1	0	0	0	0	1																																																																																																												
1	1	1	1	1	0																																																																																																												
1	0	0	0	0	1																																																																																																												
1	0	0	0	0	1																																																																																																												
1	1	1	1	1	0																																																																																																												
0	1	1	1	1	1																																																																																																												
1	0	0	0	0	0																																																																																																												
1	0	0	0	0	0																																																																																																												
1	0	0	0	0	0																																																																																																												
1	0	0	0	0	0																																																																																																												
0	1	1	1	1	1																																																																																																												
D:	<table border="1"><tr><td>1</td><td>1</td><td>1</td><td>1</td><td>1</td><td>0</td></tr><tr><td>1</td><td>0</td><td>0</td><td>0</td><td>0</td><td>1</td></tr><tr><td>1</td><td>0</td><td>0</td><td>0</td><td>0</td><td>1</td></tr><tr><td>1</td><td>0</td><td>0</td><td>0</td><td>0</td><td>1</td></tr><tr><td>1</td><td>0</td><td>0</td><td>0</td><td>0</td><td>1</td></tr><tr><td>1</td><td>1</td><td>1</td><td>1</td><td>1</td><td>0</td></tr></table>	1	1	1	1	1	0	1	0	0	0	0	1	1	0	0	0	0	1	1	0	0	0	0	1	1	0	0	0	0	1	1	1	1	1	1	0	E:	<table border="1"><tr><td>1</td><td>1</td><td>1</td><td>1</td><td>1</td><td>1</td></tr><tr><td>1</td><td>0</td><td>0</td><td>0</td><td>0</td><td>0</td></tr><tr><td>1</td><td>1</td><td>1</td><td>1</td><td>1</td><td>1</td></tr><tr><td>1</td><td>0</td><td>0</td><td>0</td><td>0</td><td>0</td></tr><tr><td>1</td><td>0</td><td>0</td><td>0</td><td>0</td><td>0</td></tr><tr><td>1</td><td>1</td><td>1</td><td>1</td><td>1</td><td>1</td></tr></table>	1	1	1	1	1	1	1	0	0	0	0	0	1	1	1	1	1	1	1	0	0	0	0	0	1	0	0	0	0	0	1	1	1	1	1	1	F:	<table border="1"><tr><td>1</td><td>1</td><td>1</td><td>1</td><td>1</td><td>1</td></tr><tr><td>1</td><td>0</td><td>0</td><td>0</td><td>0</td><td>0</td></tr><tr><td>1</td><td>1</td><td>1</td><td>1</td><td>1</td><td>1</td></tr><tr><td>1</td><td>0</td><td>0</td><td>0</td><td>0</td><td>0</td></tr><tr><td>1</td><td>0</td><td>0</td><td>0</td><td>0</td><td>0</td></tr><tr><td>1</td><td>0</td><td>0</td><td>0</td><td>0</td><td>0</td></tr></table>	1	1	1	1	1	1	1	0	0	0	0	0	1	1	1	1	1	1	1	0	0	0	0	0	1	0	0	0	0	0	1	0	0	0	0	0
1	1	1	1	1	0																																																																																																												
1	0	0	0	0	1																																																																																																												
1	0	0	0	0	1																																																																																																												
1	0	0	0	0	1																																																																																																												
1	0	0	0	0	1																																																																																																												
1	1	1	1	1	0																																																																																																												
1	1	1	1	1	1																																																																																																												
1	0	0	0	0	0																																																																																																												
1	1	1	1	1	1																																																																																																												
1	0	0	0	0	0																																																																																																												
1	0	0	0	0	0																																																																																																												
1	1	1	1	1	1																																																																																																												
1	1	1	1	1	1																																																																																																												
1	0	0	0	0	0																																																																																																												
1	1	1	1	1	1																																																																																																												
1	0	0	0	0	0																																																																																																												
1	0	0	0	0	0																																																																																																												
1	0	0	0	0	0																																																																																																												
G:	<table border="1"><tr><td>0</td><td>1</td><td>1</td><td>1</td><td>1</td><td>1</td></tr><tr><td>1</td><td>0</td><td>0</td><td>0</td><td>0</td><td>0</td></tr><tr><td>1</td><td>0</td><td>0</td><td>0</td><td>0</td><td>0</td></tr><tr><td>1</td><td>0</td><td>1</td><td>1</td><td>1</td><td>1</td></tr><tr><td>1</td><td>0</td><td>0</td><td>0</td><td>0</td><td>1</td></tr><tr><td>0</td><td>1</td><td>1</td><td>1</td><td>1</td><td>1</td></tr></table>	0	1	1	1	1	1	1	0	0	0	0	0	1	0	0	0	0	0	1	0	1	1	1	1	1	0	0	0	0	1	0	1	1	1	1	1	H:	<table border="1"><tr><td>1</td><td>0</td><td>0</td><td>0</td><td>0</td><td>1</td></tr><tr><td>1</td><td>0</td><td>0</td><td>0</td><td>0</td><td>1</td></tr><tr><td>1</td><td>1</td><td>1</td><td>1</td><td>1</td><td>1</td></tr><tr><td>1</td><td>0</td><td>0</td><td>0</td><td>0</td><td>1</td></tr><tr><td>1</td><td>0</td><td>0</td><td>0</td><td>0</td><td>1</td></tr><tr><td>1</td><td>0</td><td>0</td><td>0</td><td>0</td><td>1</td></tr></table>	1	0	0	0	0	1	1	0	0	0	0	1	1	1	1	1	1	1	1	0	0	0	0	1	1	0	0	0	0	1	1	0	0	0	0	1	I:	<table border="1"><tr><td>0</td><td>0</td><td>1</td><td>1</td><td>1</td><td>0</td></tr><tr><td>0</td><td>0</td><td>0</td><td>1</td><td>0</td><td>0</td></tr><tr><td>0</td><td>0</td><td>0</td><td>1</td><td>0</td><td>0</td></tr><tr><td>0</td><td>0</td><td>0</td><td>1</td><td>0</td><td>0</td></tr><tr><td>0</td><td>0</td><td>0</td><td>1</td><td>0</td><td>0</td></tr><tr><td>0</td><td>0</td><td>1</td><td>1</td><td>1</td><td>0</td></tr></table>	0	0	1	1	1	0	0	0	0	1	0	0	0	0	0	1	0	0	0	0	0	1	0	0	0	0	0	1	0	0	0	0	1	1	1	0
0	1	1	1	1	1																																																																																																												
1	0	0	0	0	0																																																																																																												
1	0	0	0	0	0																																																																																																												
1	0	1	1	1	1																																																																																																												
1	0	0	0	0	1																																																																																																												
0	1	1	1	1	1																																																																																																												
1	0	0	0	0	1																																																																																																												
1	0	0	0	0	1																																																																																																												
1	1	1	1	1	1																																																																																																												
1	0	0	0	0	1																																																																																																												
1	0	0	0	0	1																																																																																																												
1	0	0	0	0	1																																																																																																												
0	0	1	1	1	0																																																																																																												
0	0	0	1	0	0																																																																																																												
0	0	0	1	0	0																																																																																																												
0	0	0	1	0	0																																																																																																												
0	0	0	1	0	0																																																																																																												
0	0	1	1	1	0																																																																																																												

$$\begin{array}{c}
 \boxed{\begin{array}{c} 1\ 0\ 0\ 0\ 0\ 1 \\ 0\ 1\ 0\ 0\ 1\ 0 \\ 0\ 0\ 1\ 1\ 0\ 0 \\ 0\ 0\ 1\ 1\ 0\ 0 \\ 0\ 1\ 0\ 0\ 1\ 0 \\ 1\ 0\ 0\ 0\ 0\ 1 \end{array}} \\
 \text{X:}
 \end{array}
 \quad
 \begin{array}{c}
 \boxed{\begin{array}{c} 0\ 1\ 0\ 0\ 0\ 1 \\ 0\ 0\ 1\ 0\ 1\ 0 \\ 0\ 0\ 0\ 1\ 0\ 0 \\ 0\ 0\ 0\ 1\ 0\ 0 \\ 0\ 0\ 0\ 1\ 0\ 0 \\ 0\ 0\ 0\ 1\ 0\ 0 \end{array}} \\
 \text{Y:}
 \end{array}
 \quad
 \begin{array}{c}
 \boxed{\begin{array}{c} 1\ 1\ 1\ 1\ 1\ 1 \\ 0\ 0\ 0\ 0\ 1\ 0 \\ 0\ 0\ 0\ 1\ 0\ 0 \\ 0\ 0\ 1\ 0\ 0\ 0 \\ 0\ 1\ 0\ 0\ 0\ 0 \\ 1\ 1\ 1\ 1\ 1\ 1 \end{array}} \\
 \text{Z:}
 \end{array}$$

(c) Preparando la red: El algoritmo de aprendizaje backpropagation fue usado para resolver este problema. En este método el conjunto de entrenamiento de vectores de entrada es aplicado vector por vector en la entrada de la red y propagado hacia adelante. Los pesos son ajustados por el algoritmo BP. Subsecuentemente, nosotros repetimos estos pasos para todos los conjuntos de entrenamiento. Todo el proceso luego es repetido para la siguiente iteración. El proceso se detiene cuando se alcanza la condición de convergencia.

3.1.3. Resultados

(a) Entrenamiento de la red: Para reconocer los caracteres mostrados arriba, aplicamos el correspondiente matriz de 6x6 en la forma de 1x36 vectores para la entrada de la red. El carácter fue considerado reconocido si ambas salidas de la red no fueron más de 0.1 de diferencia de su respectivo valor deseado. La relación de aprendizaje inicial η fue un conjunto experimental de 1.5 y fue decreciendo por un factor de 2 después de cada 100 iteraciones. Este enfoque, sin embargo, resultó que el proceso de aprendizaje convergió hacia varios mínimos locales. Por lo tanto, el algoritmo de aprendizaje fue ejecutado nuevamente para 1000 iteraciones y eso hizo que el parámetro de función energía convergiera para algunos valores, pero el reconocimiento falló para todos los caracteres.

VECTOR ENTRENAMIENTO 0: [0.42169 0.798603] — NO RECONOCIDO —
 VECTOR ENTRENAMIENTO 1: [0.158372 0.0697667] — NO RECONOCIDO —
 VECTOR ENTRENAMIENTO 2: [0.441823 0.833824] — NO RECONOCIDO —
 VECTOR ENTRENAMIENTO 3: [0.161472 0.0741904] — NO RECONOCIDO —
 VECTOR ENTRENAMIENTO 4: [0.163374 0.0769596] — NO RECONOCIDO —
 VECTOR ENTRENAMIENTO 5: [0.161593 0.074359] — NO RECONOCIDO —
 VECTOR ENTRENAMIENTO 6: [0.172719 0.0918946] — NO RECONOCIDO —
 VECTOR ENTRENAMIENTO 7: [0.15857 0.0700591] — NO RECONOCIDO —
 VECTOR ENTRENAMIENTO 8: [0.159657 0.0719576] — NO RECONOCIDO —

3. EJEMPLOS DE REDES NEURONALES

Los vectores de entrenamiento 0,1,...,8 son entradas que corresponden a los caracteres 'A','B',..., 'I'.

Para evitar las problemáticas mencionadas anteriormente, una modificación más fue hecha. Después de cada 400 iteraciones se restableció la relación de aprendizaje a su valor inicial. Cuando aproximamos a 2000 iteraciones, la red es capaz de converger a 0 errores y reconoce correctamente todos los caracteres:

VECTOR ENTRENAMIENTO 0: [0.0551348 0.966846] — RECONOCIDO —
VECTOR ENTRENAMIENTO 1: [0.929722 0.0401743] — RECONOCIDO —
VECTOR ENTRENAMIENTO 2: [0.972215 0.994715] — RECONOCIDO —
VECTOR ENTRENAMIENTO 3: [0.0172118 0.00638034] — RECONOCIDO —
VECTOR ENTRENAMIENTO 4: [0.0193525 0.00616272] — RECONOCIDO —
VECTOR ENTRENAMIENTO 5: [0.00878156 0.00799531] — RECONOCIDO —
VECTOR ENTRENAMIENTO 6: [0.0173236 0.00651032] — RECONOCIDO —
VECTOR ENTRENAMIENTO 7: [0.00861903 0.00801831] — RECONOCIDO —
VECTOR ENTRENAMIENTO 8: [0.0132965 0.00701945] — RECONOCIDO —

(b) Resultados del reconocimiento: Con el fin de determinar si la detección de error es desarrollado correctamente, se tuvo que guardar los pesos obtenidos en un archivo de datos, modificando los conjuntos de datos en el programa, reemplazamos los caracteres 'G','H' y 'I' (vector 6,7 y 8) por los caracteres 'X', 'Y' y 'Z'. Luego se ejecutó el programa, cargando previamente los pesos guardados en el archivo de datos. Los resultados mostraron que no se desarrolló un sobre-entrenamiento. Los siguientes resultados son:

VECTOR ENTRENAMIENTO 6: [0.00790376 0.00843078] — RECONOCIDO—
VECTOR ENTRENAMIENTO 7: [0.0105325 0.00890258] — RECONOCIDO —
VECTOR ENTRENAMIENTO 8: [0.0126299 0.00761764] — RECONOCIDO —

Los tres caracteres fueron exitosamente identificados, por lo que lograron generar la señal de error [0,0].

(c) Robustecimiento de Red: En este estudio consistió en agregar un poco de ruido en la entrada. En el caso de distorsión de 1-bit (fuera de 36 bits) las relaciones de reconocimiento fueron:

VECTOR ENTRENAMIENTO 0: 25/36 reconocimientos (69.4444 %)
VECTOR ENTRENAMIENTO 1: 33/36 reconocimientos (91.6667 %)
VECTOR ENTRENAMIENTO 2: 32/36 reconocimientos (88.8889 %)
VECTOR ENTRENAMIENTO 3: 35/36 reconocimientos (97.2222 %)
VECTOR ENTRENAMIENTO 4: 34/36 reconocimientos (94.4444 %)
VECTOR ENTRENAMIENTO 5: 35/36 reconocimientos (97.2222 %)
VECTOR ENTRENAMIENTO 6: 36/36 reconocimientos (100 %)

VECTOR ENTRENAMIENTO 7: 35/36 reconocimientos (97.2222 %)
VECTOR ENTRENAMIENTO 8: 36/36 reconocimientos (100 %)

También se investigó para el caso de distorsión de 2 bits y fueron capaces de alcanzar las siguientes relaciones de reconocimiento:

VECTOR ENTRENAMIENTO 0: 668/1260 reconocimientos (53.0159 %)
VECTOR ENTRENAMIENTO 1: 788/1260 reconocimientos (62.5397 %)
VECTOR ENTRENAMIENTO 2: 906/1260 reconocimientos (71.9048 %)
VECTOR ENTRENAMIENTO 3: 1170/1260 reconocimientos (92.8571 %)
VECTOR ENTRENAMIENTO 4: 1158/1260 reconocimientos (91.9048 %)
VECTOR ENTRENAMIENTO 5: 1220/1260 reconocimientos (96.8254 %)
VECTOR ENTRENAMIENTO 6: 1260/1260 reconocimientos (100 %)
VECTOR ENTRENAMIENTO 7: 1170/1260 reconocimientos (92.8571 %)
VECTOR ENTRENAMIENTO 8: 1204/1260 reconocimientos (95.5556 %)

3.1.4. Discusiones y conclusiones

El reconocimiento de los tres caracteres fue exitosamente identificados por la red y al mismo tiempo fue capaz de clasificar otros caracteres como errores. Sin embargo, existe un precio que pagar para esta conveniencia. Parece que cuanto mayor es la relación de detección de error, la robustez de nuestra red es menor. Por ejemplo, cuando 2 bits del carácter 'A' son distorsionados, la red tiene solamente 53% de relación de reconocimiento. En términos generales, en la salida de cada caso, 1 y 2, la red 'piensa' que su entrada no es el símbolo 'A' y por lo tanto, puede ser clasificado como error. En general, la red de retropropagación del error prueba ser mucho más potente que Madilene. Es posible lograr una convergencia mucho más rápida y también es más fácil de programar. Existen casos, en que el algoritmo de aprendizaje de retropropagación del error consigue parar en algún mínimo local, pero ellos pueden ser exitosamente tratado mediante el ajuste de la relación de aprendizaje.

3.2. Caso de estudio 2: Generación de registros sintéticos

3.2.1. Introducción

Los registros geofísicos han sido utilizados desde hace un siglo, como herramienta principal para determinar el potencial de producción de hidrocarburos en los yacimientos. Los geofísicos interpretan datos de los registros, con el fin de determinar los parámetros petrofísicos de los pozos. Sin embargo, por razones económicas, las compañías no siempre poseen todos los registros que son necesarios para determinar las características del yacimiento. En este caso de estudio²⁴ presenta un enfoque del uso

3. EJEMPLOS DE REDES NEURONALES

de las redes neuronales artificiales como principal herramienta de estimación.

Las redes neuronales son usadas ampliamente en la caracterización del yacimiento porque tiene la habilidad de extraer relaciones no lineales de un conjunto de datos esparcidos. Los estudios respecto al tema usan los registros de medición por cable, y de los atributos sísmicos para predecir las propiedades del yacimiento, tal como: la porosidad efectiva, saturación de fluido, la permeabilidad de la roca, y para definir litofacies y predecir la respuesta de un registro geofísico. En todo caso las redes neuronales demuestran ser una herramienta con mucho potencial, alcanzando mejor coeficiente de correlación comparando con las técnicas de análisis tradicionales, como es la regresión lineal.

3.2.2. Metodología

La metodología aplicada en este trabajo está basada en otros estudios ya realizados^{25,26}, esta se divide en tres partes:

1. La robustez de la metodología general en la generación de registros sintéticos de pozos usando redes neuronales es proporcionada por la aplicación de esta nueva tecnología a un nuevo campo en el norte-este de Estados Unidos, donde prevalece nueva geología y ambiente de depósito cuando se comparan estudios previos que fueron aplicados en Texas.
2. Los resultados de la generación de los registros sintéticos usando redes neuronales son comparados con más métodos convencionales, tal como, la regresión-múltiple, y la superioridad de la tecnología de redes neuronales es demostrado.
- 3.- Una Red Neuronal de Regresión General es introducido como la red más apropiada para este estudio. En esta fase se busca la mejor arquitectura de la red, para generar el mejor coeficiente de correlación.

3.2.3. Preparación de datos

La primera etapa de preparación de los datos fue para identificar la profundidad de las unidades productivas en el área: la Murrysville, el 100 Foot, el Gordon, el Speechley y la segunda formación Bradford. Tomando en cuenta las características de los sedimentos de estas formaciones, el intervalo de estudio puede ser dividido en dos segmentos, con características diferentes de litologías y petrofísicas. Además, esta división permite una mejor visualización de los actuales registros y de los generados por la red neuronal. Los intervalos elegidos fueron de 1000 a 2000 pies y de 2500 a 3000 pies. Se construyó una matriz de datos en una hoja de cálculo, estas incluyeron: nombre del pozo, la longitud, latitud, y los valores de resistividad, densidad, rayos gama y registros de neutrón.

3.2.4. Modelo de Red Neuronal

La arquitectura de la red neuronal usada consistió de tres capas: la capa de entrada con 7 neuronas, capa de salida con 7000 neuronas y la capa de salida con una sola neurona.

Entrenamiento, calibración y verificación fueron llevados a cabo mediante dos ejercicios:

Ejercicio 1: Cuatro pozos combinados. En este ejercicio el conjunto de datos, consiste de 4 pozos, y fue usado para el entrenamiento, calibración y verificación de la red y luego cada uno de estos pozos fueron usados para verificar el entrenamiento de la red. Las combinaciones de diferentes pares de entradas y salidas fueron elegidas para entrenar la red, quedando como se muestra en la Figura 3.1. El porcentaje de datos usados para el entrenamiento, calibración y verificación fueron de 80 %,15 % y 5 % respectivamente.

Ejercicio 2: Tres pozos combinados, uno pozo excluido. Este ejercicio usa solamente tres pozos para el entrenamiento y desarrollo de la red, mientras que el cuarto pozo nunca es usado en el entrenamiento y calibración, por lo que fue seleccionado para generar el registro sintético fuera de los otros tres pozos (verificación). Por lo tanto, los pozos 157, 168 y 169 fueron combinados para generar registros en el pozo 174; pozos 157, 168 y 174 fueron combinados para generar registros en el pozo 169; pozos 157, 174 y 169 fueron combinados para generar registros del pozo 168; y los pozos 174, 169 y 168 fueron combinados para generar los registros del pozo 157. El porcentaje usado fueron distribuido de 85 % para el entrenamiento y 15 % para la calibración.

3.2.5. Resultados

Para demostrar la diferencia entre los resultados de la red neuronal y la metodología más convencional, regresión múltiple, para generar registros sintéticos, un ejercicio fue realizado usando las metodologías descritas en el ejercicio 1. Los resultados de los dos pozos se muestran en la Figura 3.2. Resultados similares alcanzaron las otras combinaciones de otros pozos. Estos resultados son comparados con la estimación realizada por la red neuronal, algunas de ellas son mostradas en las Figuras 3.3 y 3.4.

El conjunto de datos del ejercicio 1 proviene del Sur de Pensilvania. El coeficiente de correlación generada por la red neuronal se encuentra entre 0.79 0.96. para todos los registros: resistividad, densidad y neutrón. En la Figura 3.3 se muestran los resultados de los registros sintéticos de resistividad de los diferentes pozos para la combinación establecida en el ejercicio 1.

3. EJEMPLOS DE REDES NEURONALES

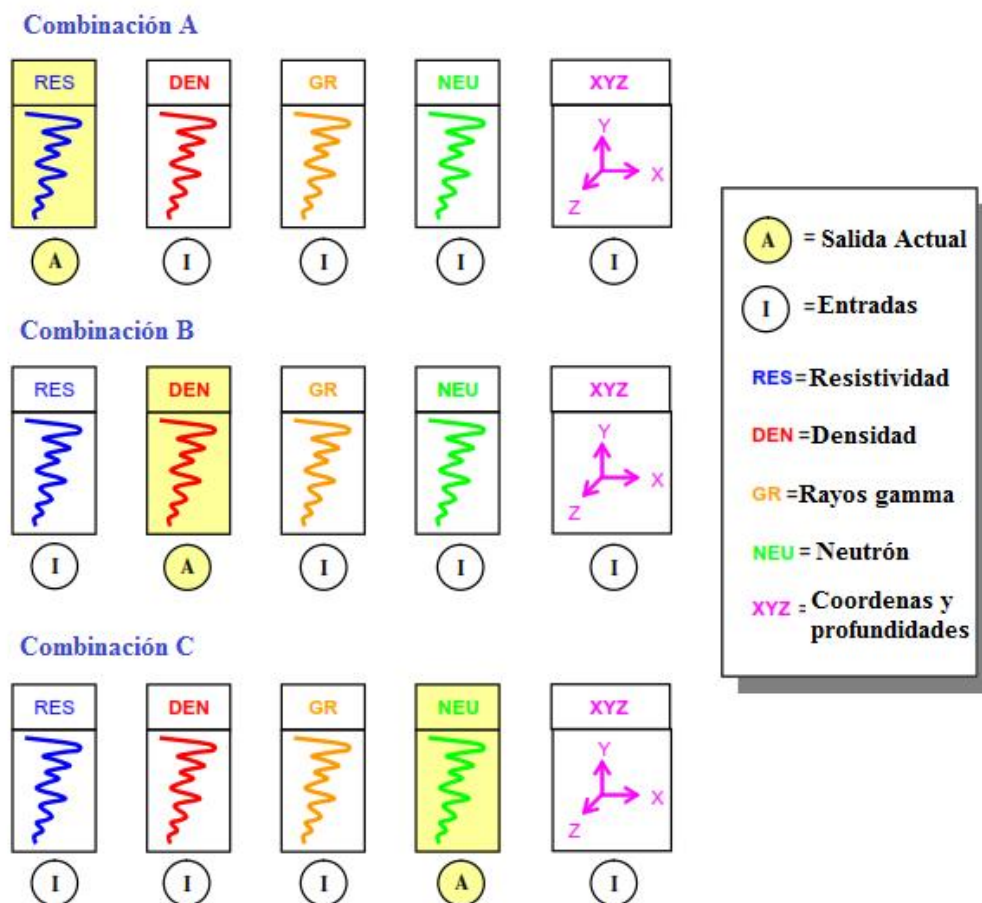


Figura 3.1: Diferentes combinaciones de entradas y salidas usadas para desarrollar los modelos de redes neuronales.

Los resultados obtenidos en el ejercicio 1 para la zona superior e inferior del área del Sur de Pensilvania, mejora substancialmente en comparación con los resultados obtenidos del conjunto de datos de Buffalo Valley. Sin embargo, mejoramientos más significativos fueron desarrollados en el ejercicio 2. Los coeficientes de correlaciones, R^2 , están por encima de 0.8. Aunque en algunos pozos muestran una R^2 entre 0.6 a 0.7, los registros sintéticos generados por la red neuronal, durante el proceso de verificación mostraron un alto grado de exactitud. Los registros sintéticos de resistividad generada por la red neuronal de los diferentes pozos se muestran en la Figura 3.4.

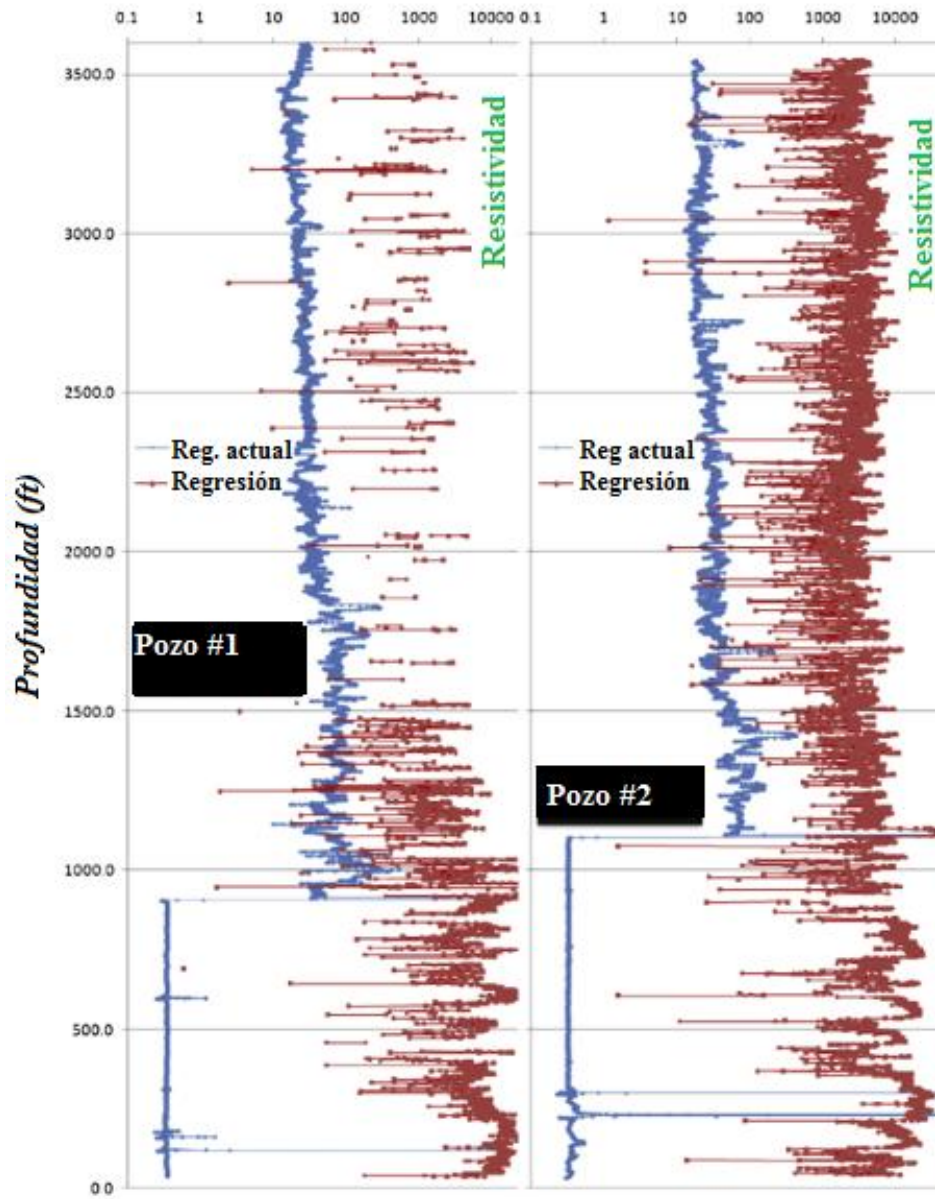


Figura 3.2: Resultados del registro sintético generado por regresión múltiple.

3. EJEMPLOS DE REDES NEURONALES

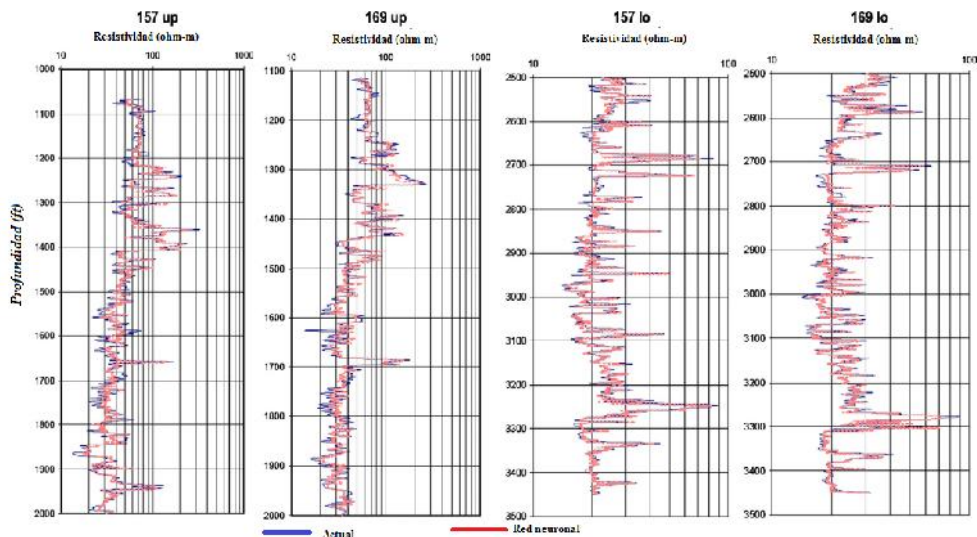


Figura 3.3: Registro sintético de resistividad generado durante la verificación mediante el ejercicio 1, con la combinación A de entradas y salidas. Pozos 157 y 169 de la zona superior e inferior del Sur de Pensilvania.

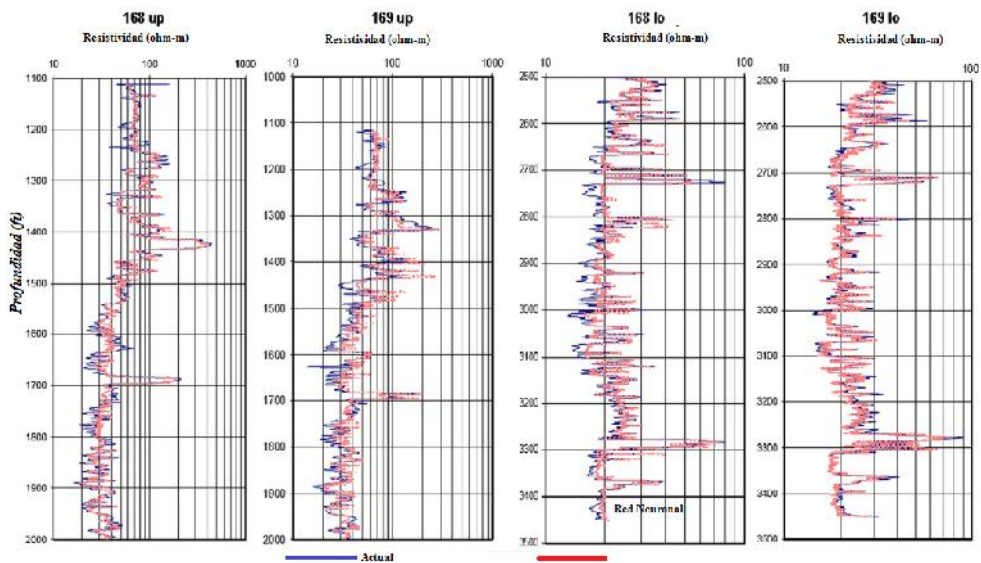


Figura 3.4: Registro sintético de resistividad generado durante la verificación mediante el ejercicio 2, con la combinación A de entradas y salidas. Pozos 168 y 169 de la zona superior e inferior del Sur de Pensilvania.

Los resultados mostrados en el ejercicio 1 y 2, indica que el mejor modelo de red neuronal lo determina la combinación A, como segundo lugar la combinación B y por último de la combinación C (ver Fig.3.5 y 3.6).




Figura 3.5: Valores de obtenidos de R^2 en la zona superior del conjunto de datos del Sur de Pensilvania, mediante el ejercicio 1.

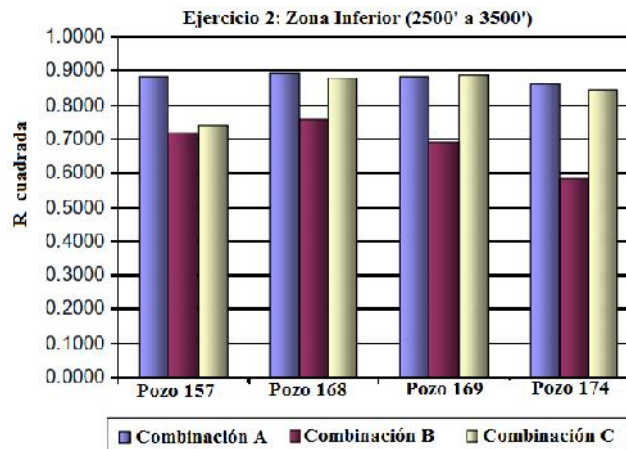


Figura 3.6: Valores de obtenidos de R^2 en la zona inferior del conjunto de datos del Sur de Pensilvania, mediante el ejercicio 1.

Para el ejercicio 2, los mejores resultados fueron obtenidos, de los pozos número

3. EJEMPLOS DE REDES NEURONALES

168 y 169. En las Figuras 3.7 y 3.8 se pueden observar los valores de R^2 obtenidos para cada combinación.

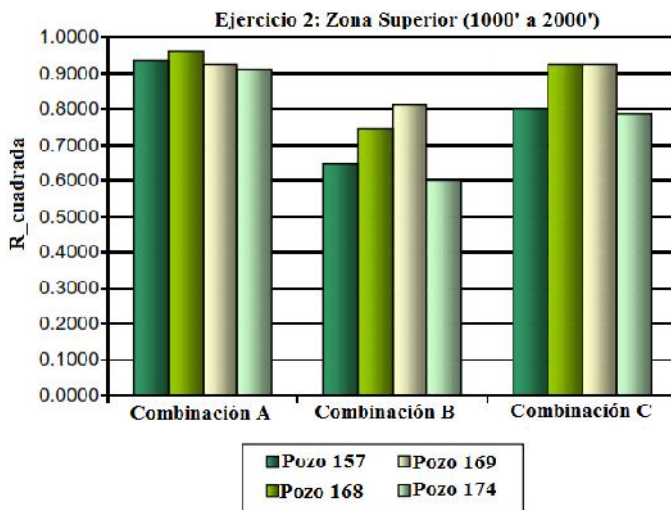


Figura 3.7: Valores de obtenidos de R^2 en la zona superior del conjunto de datos del Sur de Pensilvania, mediante el ejercicio 2.




Figura 3.8: Valores de obtenidos de R^2 en la zona inferior del conjunto de datos del Sur de Pensilvania, mediante el ejercicio 2.

3.2.6. Conclusiones

Este trabajo demuestra que la generación de registros sintéticos con un razonable grado de exactitud es posible realizar mediante el uso de redes neuronales. Además, es demostrado que el uso de redes neuronales para generar registros sintéticos es superior a los métodos convencionales.

Tres modelos de redes neuronales para predecir los registros de resistividad, densidad y neutrón fueron construidos mediante el ejercicio 1 y 2, estableciendo diferentes combinaciones.

Los resultados indica que el mejor desempeño se obtiene con la combinación A. Por otro lado, en el ejercicio 2, los registros sintéticos generados por la red neuronal mostraron un alto grado de exactitud porque la geología del área de estudio es simple, por lo que favoreció la interpolación de datos. Por lo tanto, los mejores resultados fueron obtenidos de los pozos localizados en la parte central de la sección estudiada. Esta condición puede cambiar en áreas donde se presenta una geología más compleja.

3.3. Caso de estudio 3: Predicción de la Porosidad

3.3.1. Introducción

Este ejemplo de predicción de porosidad²⁷ son determinadas mediante el uso de los registros de pozos, para lograr lo anterior fue necesario probar dos método, usando una sola red neuronal y un enfoque de máquina comité o CM (Committe Machine, por su siglas en inglés). La arquitectura de una sola red neuronal está constituida por tres capas. La capa de entrada tiene 3 neuronas que corresponden al registro de densidad, sónico y resistividad. La capa oculta tiene 7 neuronas y la capa de salida tiene una neurona. En el enfoque de máquina comité se entrenaron a 20 redes de los mismos conjuntos de datos. De las 20 redes se seleccionaron 9 de ellas. El principal objetivo de usar CM es para obtener una mejor predicción de la porosidad mediante una combinación de redes en lugar de encontrar una sola red mediante el enfoque de prueba y error.

3.3.2. Desarrollo

La mayoría de los estudios de redes neuronales reportados en ciencias de la tierra, proporcionan solo realizaciones individuales de las predicciones y la mejor red de entre un número de redes entrenadas de forma individual es seleccionada por prueba y error. Como resultado de las pruebas realizadas, la arquitectura de la red queda con una capa de entrada de 3 neuronas, 7 neuronas para la capa oculta y 1 neurona para la capa de salida.

3. EJEMPLOS DE REDES NEURONALES

La red fue entrenada por el algoritmo backpropagation Levenberg-Marquardt. Los datos de entrenamiento fueron dominados por el intervalo que se encuentra fuera del yacimiento, niveles del Jurásico y Terciario. La mayoría de los valores de porosidad están basados de las mediciones de laboratorio, la densidad del grano y de la densidad aparente de los datos de la línea de acero. La principal ventaja de usar la porosidad derivada de las mediciones de densidad es el hecho de que estas son las mejores estimaciones disponibles, ya que la compresibilidad del material de grano puro es probable que sea pequeño al igual que el de la matriz. Por lo tanto, la densidad del grano en el laboratorio no es muy diferente a los valores in situ, por lo que la porosidad estimada es menos propensa a una corrección por la presión. Este trabajo ha sido probado en varios pozos y en varios campos. En la Fig. 3.9 se muestra el resultado de la red de la sección del yacimiento del pozo 31/4-3. La comparación que se hace entre las predicciones y la porosidad del núcleo de helio revela sorprendentes similitudes que indican, después de todo, que los datos del pozo y del núcleo pueden ser bastante consistente.

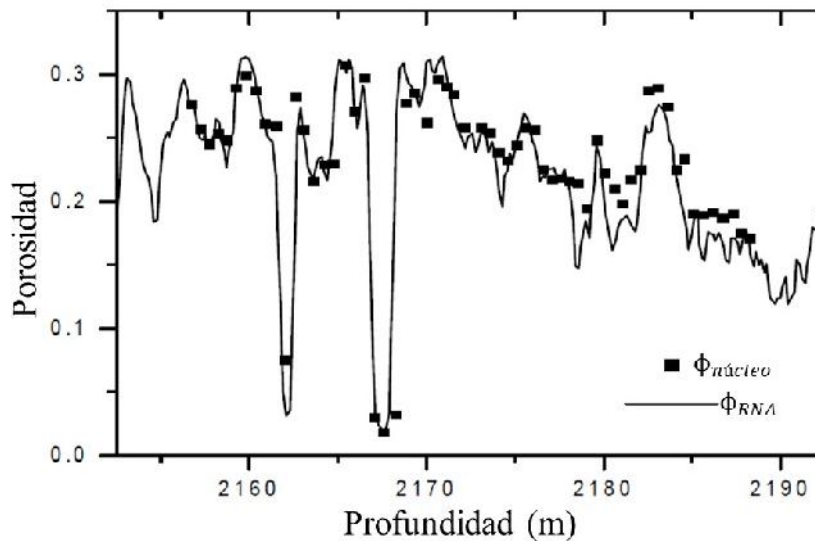


Figura 3.9: Comparación de porosidad del núcleo y la porosidad estimada por la red neuronal en el pozo 31/4-3.

Para calcular la porosidad por la densidad del grano, fue necesario asumir el valor de la densidad de la salmuera de 1.03 gr/cm^3 , ya que no fueron tomados muestras en la sección que contiene hidrocarburos. Los patrones de entrenamiento cubren el rango de porosidad de 0.02-0.55 de diferentes campos. De los 81 datos, solamente 14

son tomados como prueba principal del área, la cual es el campo Oseberg. La red es capaz de tomar en cuenta los diferentes fluidos, esto puede ser apreciado en la Fig. 3.11.

Ellos compararon la predicción de porosidad por la red neuronal con la que se calcula por la densidad-porosidad transformada usando una densidad de grano constante de $\rho_g = 2.64g/cm^3$ y con densidades de los fluidos alternativos, $\rho_f = 0.25, 0.75$ y $1.03g/cm^3$ para gas, aceite y salmuera respectivamente, en los tres pozos con agua saturada, aceite saturada y salmuera de formación saturada. Las correspondientes porosidades transformadas de ϕ_p revela fuerte sensibilidad del fluido del poro, con una diferencia de 0.05 a 0.1 unidades, asumiendo el resultado de la salmuera frente a la roca llena de gas. Existe una fuerte respuesta al fluido del poro en la transformada, como se muestra en la Fig. 3.10. Conociendo la densidad del fluido del poro, la porosidad puede ser calculada usando la transformada de densidad-porosidad.

Un término adicional de corrección para el contenido de arcillas y una variable ρ_g , normalmente son agregados para mejorar la exactitud de la transformada, implicando la necesidad de datos de núcleos adicionales y las entradas de la interpretación de registros para obtener la arcillosidad del registro de rayos gamma. La predicción de porosidad por la red neuronal en los tres pozos, revela una gran coincidencia con la porosidad del núcleo. La porosidad estimada con la red neuronal sigue a la porosidad calculada por la densidad transformada, pero la ventaja del enfoque de la red neuronal es que no necesita información acerca del fluido del poro y tampoco la corrección de arcillosidad, solamente datos de los registros es requerido.

En la Fig. 3.11a la porosidad de la red neuronal y la porosidad de la densidad transformada se correlacionan mejor que con la porosidad del núcleo. La razón es porque son diferentes las condiciones de mediciones para el registro y núcleo. Existe una sobre-predicción por la red neuronal, de 0.5-2 unidades de porosidad, esto significa que el conjunto de datos de entrenamiento no pudo ser completamente representativo para la red, por lo que requiere más información. En el caso de la porosidad de la densidad transformada, modificaron la densidad del fluido para que se ajuste a la porosidad del núcleo.

En la Fig. 3.11b la porosidad de la red neuronal está prediciendo cerca de 2 unidades mayor que la porosidad de la densidad transformada y de la porosidad del núcleo. La razón es que este también es una prueba de pozo y al comparar la densidad y valores sísmicos de este conjunto de datos de entrenamiento, este pozo está teniendo un bajo valor de densidad de alrededor de 0.75-1 gm/cc y un mayor tiempo de viaje sísmico de 5-7 $\mu sec/ft$. Debido a esto, existe una sobre-predicción de porosidad en este pozo. Esto puede remediarse mediante la construcción de más redes regionales (elección de pozos) para que los pozos de esa zona estén plenamente representados en el conjunto de datos de entrenamiento.

3. EJEMPLOS DE REDES NEURONALES

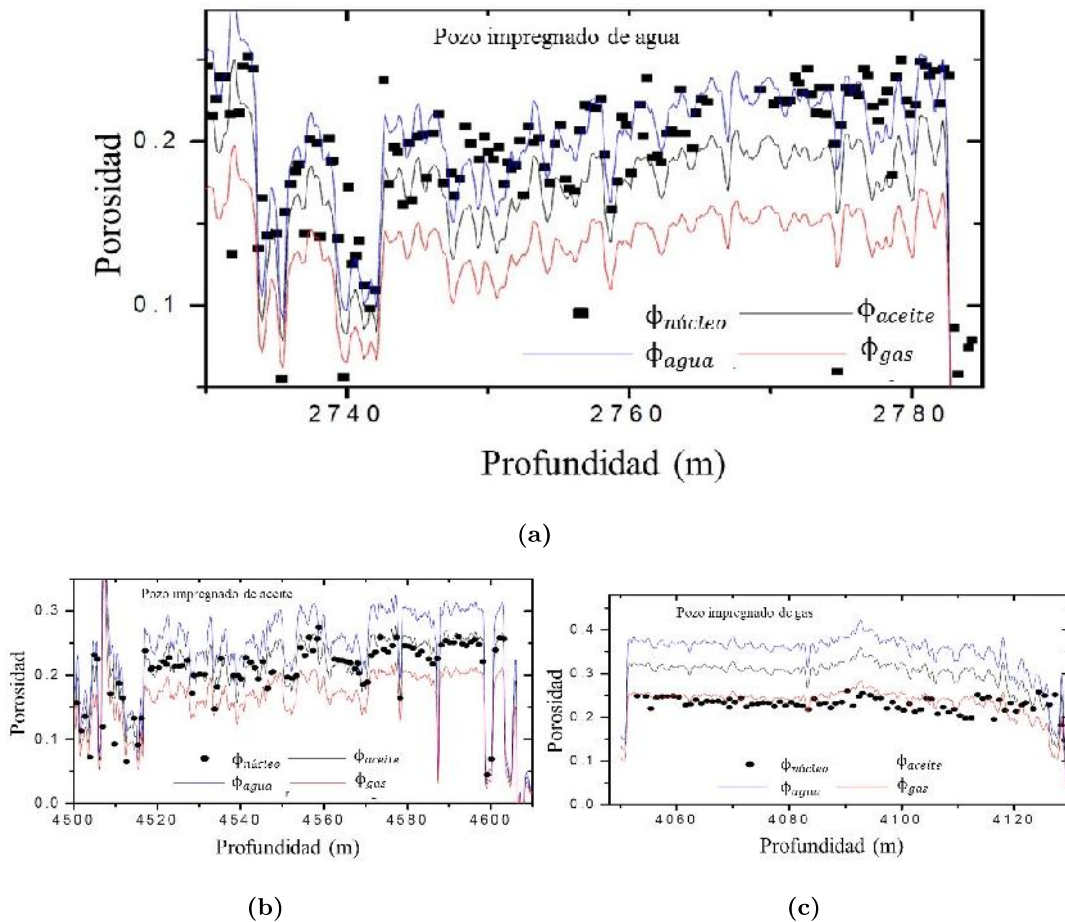


Figura 3.10: Prueba de sensibilidad de la porosidad-densidad transformada para los diferentes fluidos del poro: a) 30/9-1, b)30/9-B-40, c) 30/9-B-2

En la Fig. 3.11c existe una pequeña variación de escala en los datos del núcleo debido a las capas delgadas de la parte inferior de Oseberg. Estas capas también han sido observadas en muchos otros pozos del campo Oseberg. Existe una similitud en las tendencias de las tres porosidades que están por debajo de la profundidad de 4090m, todos incrementan ligeramente, pero debido a las capas delgadas la porosidad del núcleo tiene mayores variaciones.

La desviación entre la porosidad de la red neuronal y la porosidad de la densidad transformada, es debido la diferencia en la respuesta de densidad y del registro sísmico por debajo de la profundidad de 4118m, como la densidad comenzó incrementar la porosidad disminuyó en la densidad transformada, mientras que el registro sísmico tiene una tendencia creciente, por consiguiente, la porosidad de la red neuronal empieza incrementar. También existe una transición de pizarra-arena arriba del intervalo del

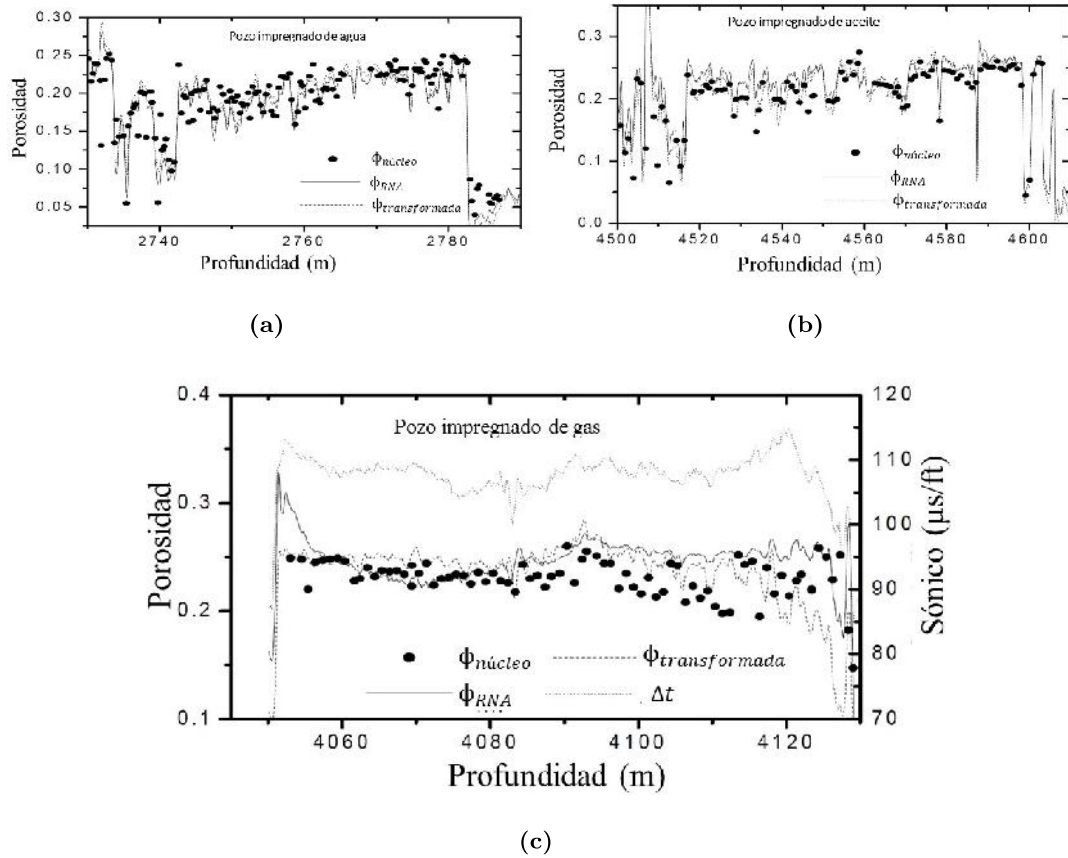


Figura 3.11: Comparación de la porosidad de la red neuronal y la porosidad-densidad transformada contra la porosidad del núcleo para el pozo: a) 30/9-1, b) 30/9-B-40, c) 30/9-B-2

yacimiento, existe un pico en la porosidad de la red neuronal, la cual, no está presente en el núcleo. Mientras que la densidad es virtualmente constante, el sónico revela dos picos distintos en la parte superior e inferior del yacimiento. Este pico se presenta en la red neuronal debido al incremento de tiempo de viaje del registro sónico. Esta característica ha sido observada en varios pozos del campo Oseberg, y es considerado como un evento de baja velocidad. La predicción de la red neuronal se basa en la entrada de tres registros que se compara favorablemente con la porosidad del núcleo de helio y no solo con la densidad.

En la Fig. 3.12 se muestran las gráficas para los pozos 30/9-1, 30/9-B-40 y 30/9-B-2 como una comparación entre el desempeño de la porosidad de la red neuronal y de la porosidad densidad junto con la porosidad del núcleo. Las gráficas revelan que las dos predicciones son muy similares.

3. EJEMPLOS DE REDES NEURONALES

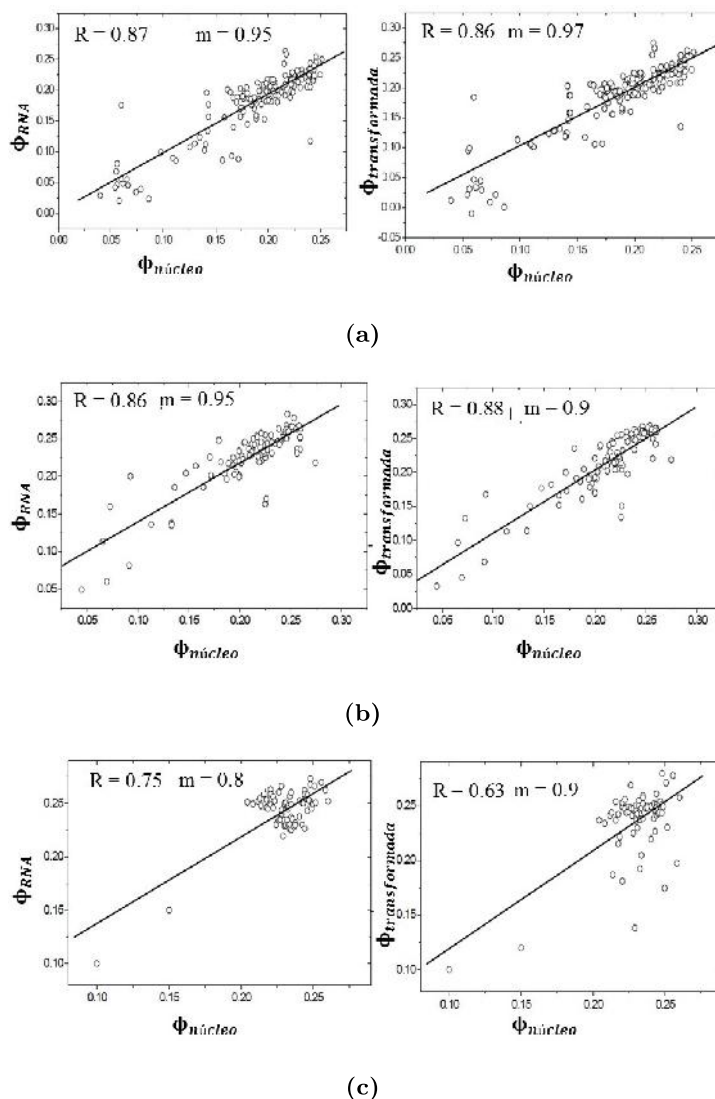


Figura 3.12: Gráfica de la porosidad del núcleo contra la porosidad de la red neuronal y porosidad del núcleo contra la porosidad-densidad transformada del pozo: a) 30/9-1, b)30/9-B-40, c) 30/9-B-2

Para la cuantificación del error, se determinó la diferencia entre la salida de la red neuronal y la porosidad del núcleo. Se generó un histograma para observar la distribución de error, en el histograma de error se aplicó un ajuste Gaussiano y se calculó la media y la desviación estándar de la función de distribución de probabilidad. Un ajuste Gaussiano para la distribución del error para los tres pozos proporciona la media de error de 0.01 en la porosidad y una desviación estándar de 0.015, por lo que es suficientemente bajo para todos los propósitos.

Siendo motivado por los beneficios de la arquitectura de MC, con la introducción promedio del conjunto y el enfoque de combinación lineal óptima u OLC (son las siglas en inglés de optima lineal combination) que mejora aún más los resultados, se desarrolla el segundo estudio mediante el uso de CM para predecir la porosidad. El argumento es que mientras una red reproduce el principal patrón, las otras pueden proporcionar detalles perdidos por la primera. Si todos los errores del miembro comité están perfectamente correlacionados, el uso de comité no mostrará un mejor desempeño. Sin embargo, cuando los patrones de error no están correlacionados, el desempeño de comité incrementa dramáticamente y se aproxima asintóticamente aun rendimiento perfecto. Por lo tanto, es beneficioso determinar los errores de las redes menos correlacionados que conforman a la máquina comité, con el fin de mejorar su desempeño. El método común para construir un comité es por el entrenamiento de un conjunto de redes independientemente, usando algún conjunto de datos de aprendizaje.

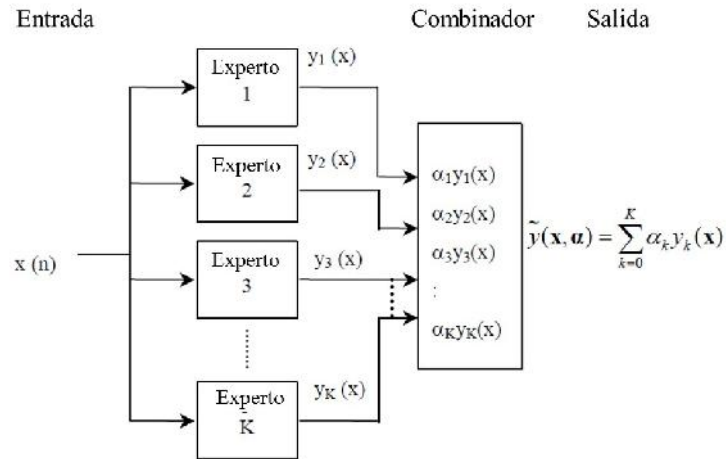


Figura 3.13: Diagrama de bloque de un CM para la predicción de porosidad.

La arquitectura de comité es mostrada en la Fig. 3.13, aquí cada experto es una sola red neuronal que tiene 3 neuronas en la entrada, 10 neuronas en la capa oculta y 1 neurona en la capa de salida. Se entrenaron 20 redes con los mismos datos de entradas, pero solo se seleccionaron 9 de ellas (redes con sesgos mínimos), inicializando pesos iniciales diferentes. La creación de un ensamble puede ser hecha por el enfoque de “prueba y selección”, que consiste en probar el desempeño de las redes individuales en un conjunto de datos y luego seleccionar el mejor de ellos. La salida de las redes seleccionadas se combina utilizando un promedio de ensamble. El promedio del ensamble proporciona un promedio del sesgo y la varianza de todas las redes, mientras que el

3. EJEMPLOS DE REDES NEURONALES

enfoque de OLC provee un ajuste adicional a los datos mediante la eliminación de bias y la reducción de la varianza, demostrando que es la mejor técnica para la predicción de la porosidad.

Para observar el desempeño de la máquina comité, más datos de entrenamiento de diferentes pozos de Oseberg fueron agregados al conjunto de de datos de entrenamiento del previo estudio. El número total de patrones de entrenamiento es de 168, para cada experto del comité.

La distribución de la varianza de los expertos del comité es sorprendentemente constante, como se muestra en la Fig. 3.14a, y refleja límites prácticos en la exactitud, por lo que logra coincidir con los datos del núcleo y de los registros por línea de acero, esto equivale a una desviación estándar de 0.02 de la porosidad. El promedio del conjunto y OLC implica solamente una reducción menor en la varianza mientras que la bias es prácticamente eliminada por OLC. La predicción de porosidad de la red neuronal se correlaciona muy bien con la porosidad del núcleo para el conjunto de datos de entrenamiento, como se muestra en la Fig. 3.14b.

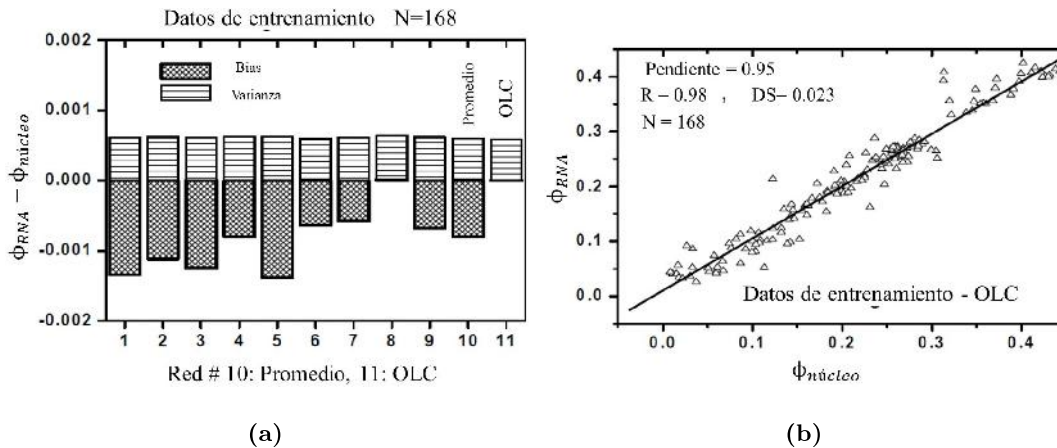


Figura 3.14: a) Comparación de bias y varianza de las redes con un ensamblaje promedio y OLC b) Correlación de porosidad de la red neuronal con la porosidad del núcleo.

Esta técnica ha sido probada en diferentes pozos del campo Oseberg y resultó ser exitoso. La Fig. 3.15a muestra los resultados respecto al gas y aceite del pozo 30/9-B-20, con un contacto gas-aceite en 3198m. En general, la correlación entre la predicción de las redes neuronales y la porosidad del núcleo es buena, como se muestra en la Fig. 3.15b.

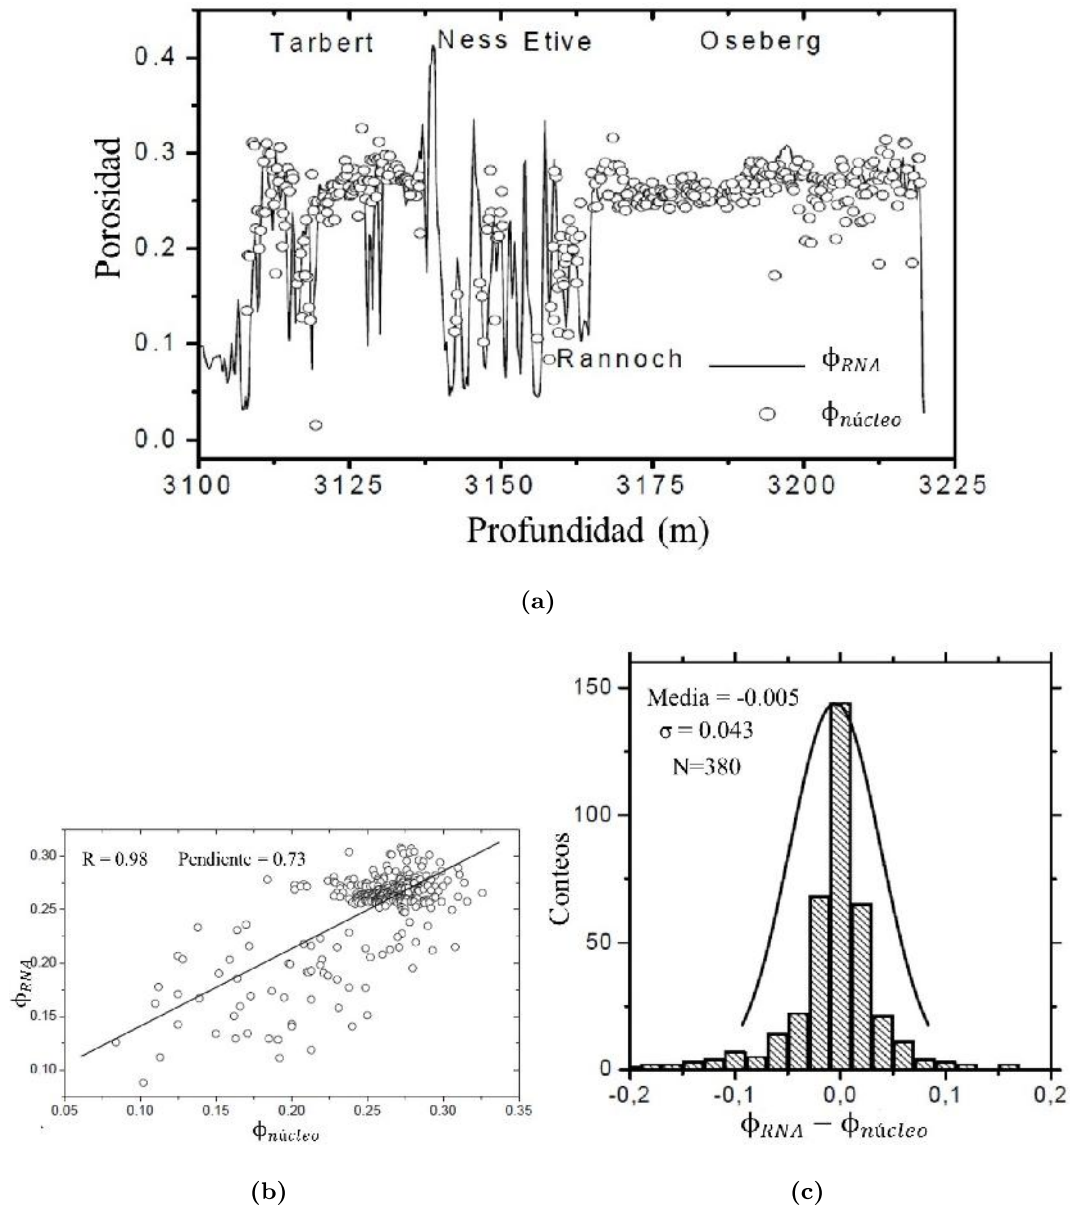


Figura 3.15: a) Comparación de la porosidad del núcleo y la porosidad de la red neuronal por OLC del pozo 30/9-B-2, b) Gráfica de la porosidad del núcleo contra la porosidad de la RNA, c) Distribución de error

La técnica Gaussiana se ajusta en la diferencia entre el núcleo y la predicción de porosidad por la red neuronal, esto muestra resultado de una media insignificante y una desviación estándar de 0.04, como se muestra en la Fig. 3.15c, que es principalmente debido a la dispersión en la porosidad del núcleo y la porosidad de la red neuronal.

3. EJEMPLOS DE REDES NEURONALES

La dispersión está principalmente en la formación Ness (3140-60) porque consiste de una delgada capa de arena, arcilla y carbón. Por debajo de la formación Ness se encuentra la formación Tarbet (3110 a 3135m), la cual es bastante homogénea dentro de cada litología de las secuencias de arenas y arcillas. En la Fig. 3.16a se muestra la comparación de la predicción de porosidad por la red neuronal y la porosidad del núcleo del pozo 30/9-B-24. El pozo tiene 161 datos de núcleo. La predicción de porosidad por la red neuronal coincide muy bien con la porosidad del núcleo, como se muestra en la Fig. 3.16b. El Gaussiano se ajusta en la diferencia entre el núcleo y la predicción de porosidad por la red neuronal, proporcionando una media insignificante y una desviación estándar de 0.01, como se muestra en la Fig. 3.16c. Los datos del núcleo están disponibles en Etive (3380-90m), Rannoch (3390-3393m) y la formación Oseberg (3393-3448m).

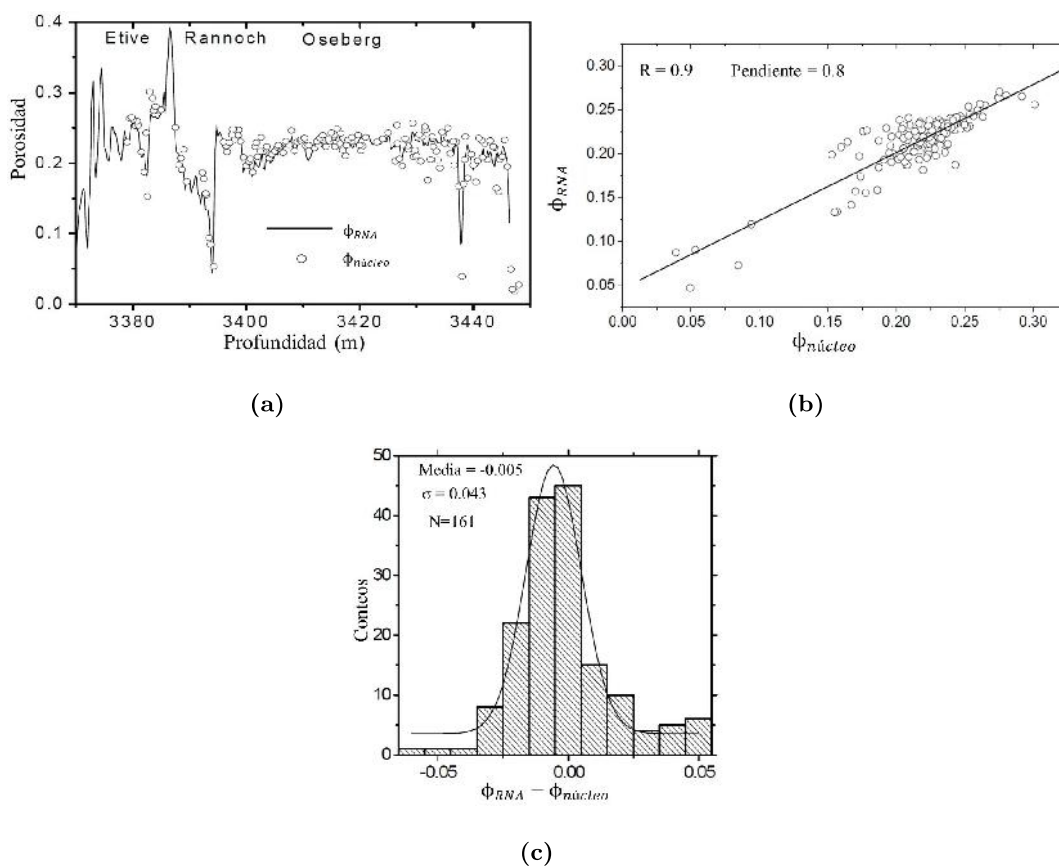


Figura 3.16: a) Comparación de la porosidad del núcleo y la porosidad de la red neuronal por OLC del pozo 30/9-B-24, b) Gráfica de la porosidad del núcleo contra la porosidad de la RNA, c) Distribución de error

3.3.3. Conclusiones

El enfoque de la red neuronal para predecir la porosidad tiene un número de ventajas sobre los métodos convencionales, incluyendo las fórmulas empíricas basados en modelos de regresión lineal o las fórmulas semi-empíricas comunes, como la de Wyllie y la ecuación de densidad. El método de red neuronal representa un enfoque pragmático para el problema de conversión de registro clásico que durante los años ha causado problemas a los geocientíficos e ingenieros petroleros. En lugar de buscar relaciones complicadas entre las propiedades geológicas/geofísicas, el enfoque de la red neuronal no requiere un modelo matemático y ni establecer la linealidad entre las variables.

El principal inconveniente del método es la cantidad de esfuerzo requerido para seleccionar una colección representativa como datos de entrenamiento, lo cual es común que todos los modelos se apoyen de datos reales. Por otro lado, una vez establecido la aplicación de la red neuronal requiere de un mínimo tiempo de cómputo. Para la red de porosidad nosotros encontramos que valores calculados de la porosidad de la densidad de grano y del dato de densidad aparente in-situ, proporciona resultados más consistentes que el uso de datos estándar de la porosidad del núcleo de helio. Los beneficios que tiene una sola red neuronal de la máquina comité, son en las predicciones, ya que la red neuronal comité son redundantes y evidentes(una sola red puede proporcionar la misma información).

Las 20 redes de porosidad son entrenadas por el mismo patrón, pero las condiciones iniciales fueron aleatorias, en este estudio se incluyó las 9 mejores redes en la máquina comité, basado en un criterio de mínimo error cuando es comparado con los datos reales.

Las predicciones de porosidad son suficientemente exactas para satisfacer las necesidades más prácticas y son comparables con la exactitud obtenida de la ecuación de densidad. El enfoque de la red neuronal, por otro lado, no requiere de un conocimiento previo del material de grano y fluido del poro, por lo tanto, puede aplicarse con gran confiabilidad durante la perforación de pozo sin previa evaluación petrofísica.

En este estudio, no se consideraron los efectos de los diferentes fluidos de perforación, por ejemplo, un lodo base aceite o agua. Sería muy interesante observar el comportamiento de la red con respecto a los fluidos de perforación en un futuro estudio.

3.4. Caso de estudio 4: Introduciendo un Nuevo Método para Predecir las Propiedades PVT del Aceite Crudo Iraní mediante las Redes Neuronales Artificiales

3.4.1. Introducción

Cuando los datos de los experimentos PVT del aceite crudo no están disponibles dos métodos son aplicados principalmente. El primer método es la aplicación de la ecuación de estado, la cual requiere información exacta acerca de los componentes de los fluidos del yacimiento. Obtener información exacta de los componentes es caro y demasiado tiempo, además de que requiere enormes cálculos numéricos. El segundo método es la aplicación de correlaciones PVT.

En décadas recientes, varias correlaciones matemáticas y técnicas gráficas han sido desarrollados para predecir las propiedades PVT del aceite crudo para determinar la presión de burbuja (P_b) y el factor de volumen del aceite (B_o). Estas correlaciones asumen que las propiedades están fuertemente en función de las mediciones de las propiedades PVT.

$$P_b = \mu(R_s, T, \rho_o, \rho_g) \quad B_o = \mu(R_s, T, \rho_o, \rho_g)$$

El objetivo de este caso estudio (Naseryan, Salahshoor y Kharrat²⁸) fue desarrollar una técnica más y precisa para predecir las propiedades PVT del aceite crudo, mediante las redes neuronales artificiales.

Para desarrollar el modelo de RNA, 218 muestras de aceite crudo fueron tomadas en diferentes ubicaciones del yacimiento iraní. Los datos se dividen en dos grupos: el primer grupo incluye 190 datos que son usados para entrenar el modelo de la red. El segundo grupo es un conjunto de validación cruzada que involucra 28 datos y es usado para evaluar la validez de la estabilidad de la RNA. Además, los resultados de la predicción de las propiedades PVT por los modelos de RNA es comparado con las correlaciones PVT, como Standing, Vazquez y Beggs, Al-Marhoun, y una correlación modificada para el aceite crudo del Medio Oriente que fue presentada por Al-Marhoun.

El arreglo de entrada del modelo de RNA para este estudio consiste de la relación de solubilidad (R_s), gravedad específica del aceite (γ_o), gravedad específica del gas (γ_g) y temperatura del yacimiento(T).

Durante el proceso de entrenamiento, la conexión óptima de los pesos entre las neuronas de la capa de la red neuronal fue determinado.

3.4.2. Desarrollo de Modelos PVT

Cada uno de los 218 conjuntos de datos aplicados en este estudio contienen la P_b , B_o , R_s , ρ_{API} , ρ_g y T . Los rangos de los conjuntos de datos PVT aplicados son mostrado en la Tabla 3.1. P_b y B_{ob} han sido considerados como salidas y R_s , ρ_{API} , ρ_g y T como entradas de la red neuronal.

Cuando el dominio de los elementos de entrada de la RNA es considerablemente diferente del uno al otro como se muestra en la Tabla 3.1, la red neuronal obtenida son inestables y no puede ser confiable. Por ejemplo, el rango de B_{ob} es [1.1-1.805] mientras que la P_b tiene un dominio de [348-5,155]. Con el fin de eliminar este problema los elementos de los conjuntos de datos de entradas tuvieron que pasar por una etapa de preprocesamiento, que consiste en clasificar los datos en un rango de [-1 1], a esto se le conoce como normalización.

Tabla 3.1: Rango de los conjuntos de datos PVT.

	P_b (psia)	T (°F)	R_s (scf/stb)	B_{ob} (rb/stb)	ρ_o	ρ_g
Rango	348-5,155	120-250	125-1,485	1.1-1.805	0.831-0.930	0.815-1.270

Después de examinar las diferentes estructuras de la red neuronal con diferentes números de capas ocultas por prueba y error, la estructura de la red neuronal con una capa y 12 neuronas muestra el mejor desempeño de predicción con $R^2 = 0.996$ para la estimación de la P_b . La red con 12 neuronas en la capa oculta determina un coeficiente de 0.997 para la predicción de B_{ob} .

3.4.2.1. Conjunto de datos de entrenamiento

Diagramas de dispersión (Fig. 3.17) han sido usados para comparar la presión de burbuja obtenida con los diferentes modelos y valores experimentales de la P_b . La predicción de la P_b se ilustra en la Fig. 3.17d y en la Tabla 3.2 se muestran los parámetros estadísticos obtenidos de los diferentes modelos PVT aplicados en los conjuntos de datos de entrenamiento.

3. EJEMPLOS DE REDES NEURONALES

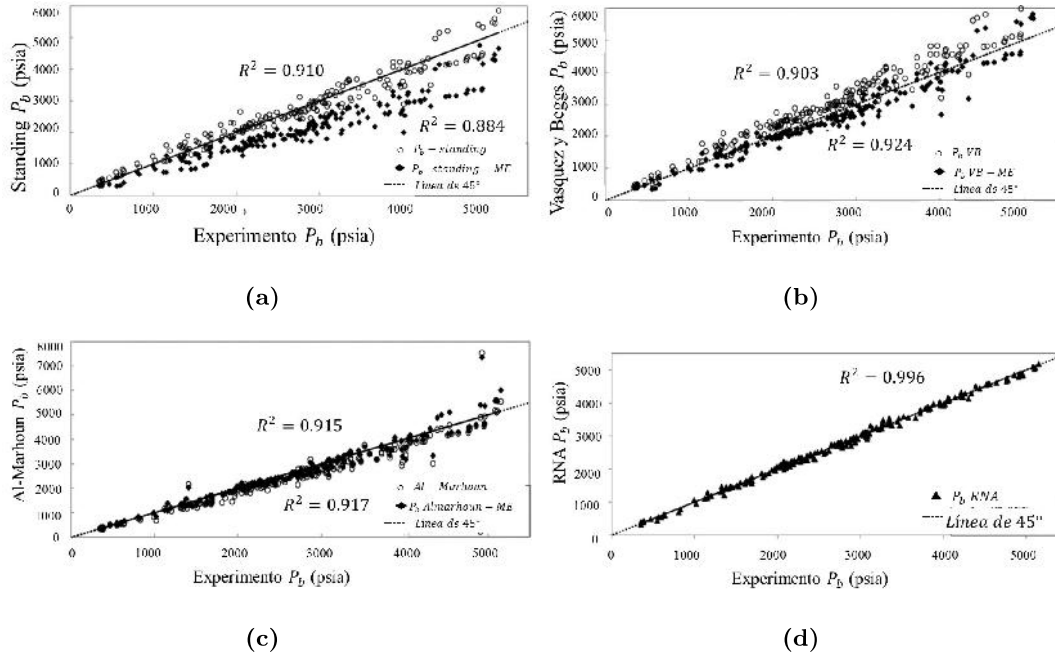


Figura 3.17: Predicción de la presión de burbuja mediante: a) Standing y Standing modificado para Medio Oriente, b) Vazquez y Beggs y Vazquez y Beggs modificado para Medio Oriente, c) Al-Marhoun y Al-Marhoun modificado para el Medio Oriente, d) Modelo RNA

Tabla 3.2: Parámetros estadísticos obtenidos de los diferentes modelos de predicción para la P_b en el conjunto de datos de entrenamiento.

	Standing	Standing (EM)	Vazquez Beggs	Vazquez Beggs (EM)	Al-Marhoun	Al-Marhoun (EM)	RNA
ERP (%)	-2.74	23.14	-14.10	2.69	6.76	2.27	-0.01
ERPA (%)	8.75	23.33	14.92	8.57	8.73	5.99	2.79
Min ERA (%)	0.00	1.21	0.19	0.01	0.00	0.02	0.01
Max ERA (%)	37.75	50.32	14.9	37.43	53.05	49.06	19.99
D. Estándar (%)	11.58	10.39	10.76	10.84	9.20	8.22	3.99
R^2	0.910	0.884	0.924	0.903	0.915	0.917	0.996

ERP: Error Relativo Promedio. ERPA: Error Relativo Promedio Absoluto. ERA: Error Relativo Absoluto.

R^2 : Coeficiente de Correlación. EM: Ecuación Modificada.

La gráfica de dispersión (Fig. 3.18) compara las diferentes predicciones del factor de volumen en el punto de burbuja, B_{ob} , con respecto a los valores experimentales de B_{ob} . El modelo de RNA tiene mejor desempeño en la predicción de B_{ob} como se muestra en

3.4 Caso de estudio 4: Introduciendo un Nuevo Método para Predecir las Propiedades PVT del Aceite Crudo Iraní mediante las Redes Neuronales Artificiales

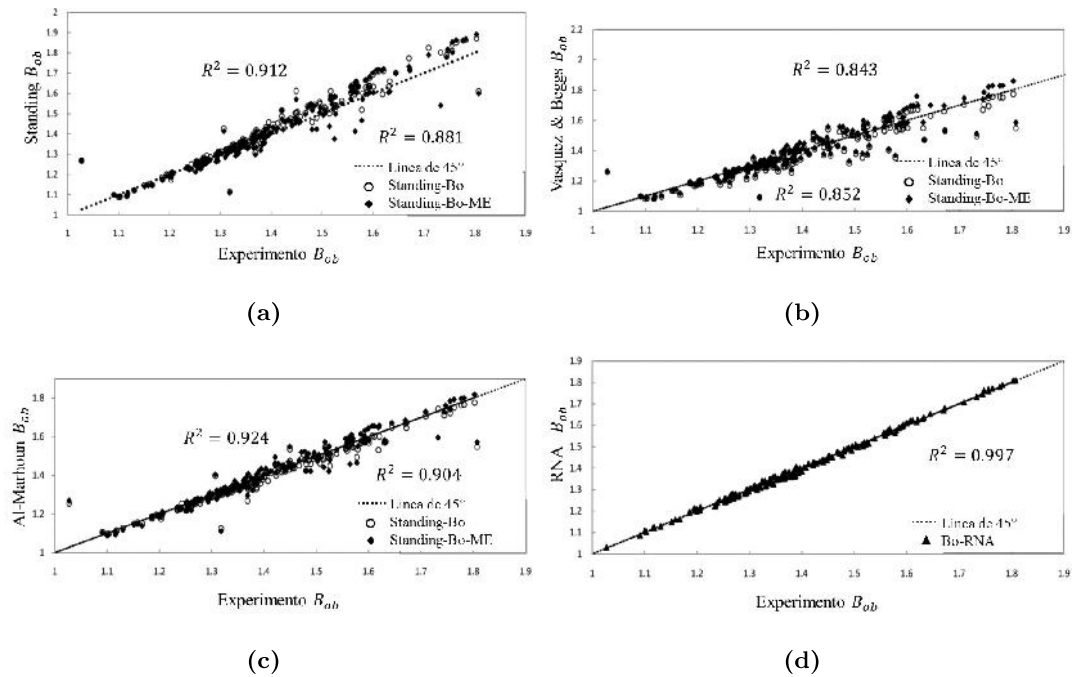


Figura 3.18: Predicción del factor de volumen del aceite en el punto de burbuja mediante: a) Standing y Standing modificado para Medio Oriente, b) Vazquez y Beggs y Vazquez y Beggs modificado para Medio Oriente, c) Al-Marhoun y Al-Marhoun modificado para el Medio Oriente, d) Modelo RNA

la Fig. 3.18d, en el que se ha logrado obtener una nube más estrecha y más cercano a los puntos de datos de la línea de 45°. Los resultados obtenidos de los análisis de errores estadísticos para el conjunto de datos de entrenamiento se presentan en la Tabla 3.3.

Tabla 3.3: Parámetros estadísticos obtenidos de los diferentes modelos de predicción para la B_{ob} en el conjunto de datos de entrenamiento.

	Standing	Standing (EM)	Vazquez Beggs	Vazquez Beggs (EM)	Al-Marhoun	Al-Marhoun (EM)	RNA
ERP (%)	-1.51	-0.47	1.47	0.39	0.99	0.17	-3E-05
ERPA (%)	2.27	2.33	2.89	2.83	1.52	1.68	0.53
Min ERA (%)	0.00	0.01	0.03	0.02	0.00	0.01	0.00
Max ERA (%)	23.35	23.18	22.58	23.10	21.96	23.42	1.78
D. Estándar (%)	3.17	3.65	4.05	4.21	2.59	3.05	0.65
R^2	0.912	0.881	0.843	0.852	0.92	0.904	0.997

3. EJEMPLOS DE REDES NEURONALES

3.4.2.2. Conjunto de datos de validación cruzada

Con el fin de asegurar acerca de la generalización de la RNA obtenida, la predicción de las propiedades PVT del aceite crudo de Irán fue probado con un conjunto de datos que no ha sido usado durante el proceso de entrenamiento, para comprobar el potencial de extensibilidad de la red producida. Para lograr este propósito 28 conjuntos de datos fueron introducidos en la estructura de la red neuronal y los resultados obtenidos fueron analizados.

Las Tablas 3.4 y 3.5 muestran los parámetros estadísticos obtenidos por los diferentes modelos de PVT en la predicción de P_b y B_{ob} para el conjunto de datos de validación cruzada.

Tabla 3.4: Parámetros estadísticos obtenidos de los diferentes modelos de predicción para la P_b en el conjunto de datos de validación cruzada.

	Standing	Standing (EM)	Vazquez Beggs	Vazquez Beggs (EM)	Al-Marhoun	Al-Marhoun (EM)	RNA
ERP (%)	-6.99	18.82	-18.17	-2.64	4.29	-1.19	0.21
ERPA (%)	10.60	18.99	18.55	8.33	11.71	6.66	1.38
Min ERA (%)	0.39	1.45	3.03	0.41	0.01	0.61	0.26
Max ERA (%)	34.55	40.77	45.76	33.15	90.06	64.23	4.57
D. Estándar (%)	12.81	10.54	10.91	11.01	19.68	13.75	1.87
R^2	0.90	0.88	0.90	0.89	0.73	0.825	0.973

Tabla 3.5: Parámetros estadísticos obtenidos de los diferentes modelos de predicción para la B_{ob} en el conjunto de datos de validación cruzada.

	Standing	Standing (EM)	Vazquez Beggs	Vazquez Beggs (EM)	Al-Marhoun	Al-Marhoun (EM)	RNA
ERP (%)	-0.66	0.06	2.28	0.78	1.61	0.91	-0.15
ERPA (%)	2.06	2.18	3.11	2.83	1.92	1.74	0.40
Min ERA (%)	0.07	0.02	0.00	1.43	0.32	0.00	0.00
Max ERA (%)	10.91	11.58	14.32	12.32	14.45	13.1	0.94
D. Estándar (%)	2.94	3.39	3.93	4.08	2.86	2.96	0.46
R^2	0.921	0.916	0.875	0.883	0.928	0.92	0.998

3.4.3. Conclusiones

En este estudio, la RNA se usa como una nueva herramienta de predicción en lugar de modelos de regresión convencional. La predicción de las propiedades PVT (P_b , B_{ob}) del aceite crudo iraní, se realizó usando propiedades de los experimentos PVT como entradas para la red.

Para obtener una RNA óptima con un bajo suma del error cuadrado en el desempeño de la predicción, varios RNA con diferentes números de neuronas en la capa oculta han sido analizado y para cada propiedad PVT, la mejor estructura de la red neuronal con sus correspondientes pesos y sesgos han sido obtenidos. También para asegurar la generalización de la estructura de la RNA, un conjunto de datos para la validación cruzada fue introducido y los resultados fueron presentados.

Los resultados obtenidos demuestran que la RNA se desempeña mejor en la predicción del B_{ob} y P_b , la cual, el mejoramiento del coeficiente de correlación respecto a las correlaciones tradicionales de PVT pasa ser de $R^2 = 0.83$ hasta $R^2 = 0.99$. También, las correlaciones modificadas de Al-Marhoun tiene un desempeño de predicción mejorado de las propiedades PVT del aceite crudo de Irán, especialmente en el caso de la presión de burbuja P_b . El conjunto de datos que fueron usados en este estudio representan casi a todos los yacimientos de aceite crudo de Irán y la red obtenida puede aplicarse exitosamente para la predicción de las propiedades PVT del aceite crudo iraní.

Capítulo 4

Desarrollo de una Red Neuronal Aplicado en la Ingeniería Petrolera

4.1. Introducción

Determinar las propiedades PVT del aceite es de gran importancia porque en los cálculos y análisis de ingeniería de yacimiento dependen de ellos, tales como: estimación de reserva, balance de materia, diseño de instalaciones superficiales, recuperación mejorada, simulación de yacimiento, etc. Idealmente estas propiedades deberían de ser determinadas mediante estudios de laboratorios, sin embargo, estas mediciones algunas veces no están disponibles o son muy costosos. Algunas de las razones por la que no se toman muestras de hidrocarburos para realizar los estudios de laboratorio son:

- Las muestras no se han tomado para ahorrar costos
- Algunas veces las muestras obtenidas no son confiables
- El análisis PVT no están disponibles cuando es necesario
- Falta de personal especializado
- Para no generar una producción diferida de petróleo

Los problemas mencionados anteriormente han obligado a los ingenieros a desarrollar métodos matemáticos que permitan determinar las propiedades de los hidrocarburos. En la actualidad, existen una gran cantidad de modelos matemáticos, conocidos

4. DESARROLLO DE UNA RED NEURONAL APLICADO EN LA INGENIERÍA PETROLERA

como correlaciones empíricas, estas correlaciones fueron desarrolladas usando regresión lineal, regresión múltiple no lineal o técnicas gráficas. Cada correlación fue desarrollada para un rango de datos de las características de los fluidos del yacimiento, es decir, de su composición y grados API. Las exactitudes de las correlaciones son críticas y no es a menudo conocer su mejoramiento⁸.

Recientemente, las técnicas de inteligencia artificial son usadas para resolver problemas de la ingeniería petrolera. En este trabajo se usará una de las ramas o técnicas de la inteligencia artificial, las redes neuronales artificiales. En los últimos años, varios artículos han sido publicados. Estos artículos pueden ser divididos en dos categorías. El primero, usa redes neuronales para analizar la información de litología de los registros de pozos, y segundo, usan redes neuronales para elegir un modelo de yacimiento para ser usado en un estudio convencional de prueba de interpretación de pozos^{29,30}. Las redes neuronales también han sido usadas para predecir las propiedades de los fluidos del yacimiento. En este capítulo desarrollaremos una red neuronal que será capaz de predecir las propiedades del aceite, demostrando que la exactitud de tal predicción será mejor que la de las correlaciones empíricas. La metodología se establecerá conforme se construye la red neuronal.

4.2. Revisión de literatura de las correlaciones PVT y RNA

En los últimos 60 años, los ingenieros realizaron un importante desarrollo y uso de las correlaciones empíricas para estimar las propiedades PVT. Las correlaciones desarrolladas durante los años, pueden ser divididos en dos tipos: yacimientos saturados y no saturados.

La lista de correlaciones PVT que existen para determinar las propiedades del aceite es enorme. Sin embargo, mencionaremos los más comunes en este trabajo.

4.2.1. Correlaciones PVT para aceite saturado

El principal parámetro que es medido durante el decremento de presión de una prueba de laboratorio es la presión de burbuja. La presión de burbuja es modelada como función de la relación de solubilidad, gravedad específica del gas, gravedad específica del aceite y la temperatura del yacimiento. Las correlaciones de la presión de burbuja han recibido mucha atención porque, primeramente, es la base para la derivación de otras propiedades PVT, y segundo, define el punto de transición de un comportamiento saturado o sobresaturado durante el decremento de presión.

Standing^{31,32} en 1947 y 1977 presentó correlaciones para la presión de burbuja y para el factor de volumen del aceite. Estos modelos empíricos se desarrollaron con 105 datos experimentales de 22 muestras aceites crudos de California, generando un error promedio de 4.8 %.

Lasater³³ presentó una correlación para la presión de burbuja basado en 158 datos experimentales medidos en 137 diferentes tipos de aceite crudo de Canadá, Occidente-Medio del continente Americano y sur de América.

Glaso³⁴ utilizó el enfoque de Standing para 45 muestras de mezclas de hidrocarburos del Mar del Norte. Él presentó una correlación para la presión de burbuja, p_b , y para el factor de volumen del aceite, B_o , con un error promedio de 1.28 % y 0.43 %, respectivamente.

Vazquez y Beggs³⁵ propusieron una correlación empírica para estimar la relación de solubilidad, R_s . Este modelo fue obtenido mediante el análisis de regresión usando más de 6000 mediciones de R_s , B_o y la viscosidad, μ_o en varias presiones. Las mediciones fueron realizadas con más de 600 análisis de laboratorio PVT de diferentes campos del mundo.

Al-Marhoun³⁶ publicó las correlaciones para estimar la presión de burbuja y el factor de volumen del aceite para aceites crudos del Medio Oriente. Usó 160 conjuntos de datos para 69 yacimientos de aceites del Medio Oriente. Los errores promedios de las correlaciones fueron del 3.66 % para la P_b y 0.88 % para el B_o .

Petrosky y Farshad³⁷, presentaron correlaciones para el aceite negro, basados en 81 análisis de laboratorios de aceite crudo del Golfo de México. Sus correlaciones presentaron errores de 3.28 % y 0.64 % para la P_b y B_o , respectivamente.

En 1959 Chew y Connally³⁸ propusieron la idea de realizar correlaciones para la viscosidad del aceite saturado, mediante el ajuste de la correlación del aceite muerto para una presión específica que está por debajo de la presión de burbuja. El modelo que formularon Chew y Connally incluyen parámetros que son modificados por diferentes autores. Los valores de los parámetros que fueron presentados por Beggs y Robinson³⁹ son considerados como el mejor para el ajuste de tal modelo. Por otra parte, Standing expresó la correlación gráfica original de Beal para la viscosidad del aceite muerto, mediante un modelo matemático. Beggs y Robinson también desarrollaron otra expresión para la correlación gráfica de Beal para aceite muerto usando 460 mediciones.

4.2.2. Correlaciones PVT para aceite sobresaturado

Se pueden determinar las propiedades PVT del aceite por arriba de la presión de burbuja, bajosaturado, mediante modelos empíricos propuestos por varios autores.

Es importante mencionar que la R_s en esta etapa se mantiene constante porque todo el gas se encuentra disuelto en el aceite. El factor de volumen del aceite es calculado en función de la compresibilidad del aceite a temperatura del yacimiento. Para evaluar la compresibilidad isotérmica, Vazquez y Beggs propusieron una correlación para un total de 4036 datos experimentales.

En 1993, Petrosky y Farshad³⁷ publicaron otra correlación para la compresibilidad del aceite, similar a la de Vasquez y Beggs, con la diferencia de un parámetro de ajuste para mejorar la exactitud de la correlación.

Algunas correlaciones de la viscosidad del aceite que se encuentran por arriba de la presión de burbuja, de las más populares fueron desarrolladas por Beal en 1946 y Vazquez y Beggs. Beal⁴⁰ presentó una correlación gráfica para la variación de la viscosidad del aceite bajosaturado con 52 mediciones de viscosidad. Basado en 3593 datos, Vazquez y Beggs desarrollaron una expresión para estimar la viscosidad del aceite sobresaturado, reportando un error promedio absoluto de 7.54 %.

4.2.3. Modelos de Redes Neuronales para estimar las propiedades PVT

En la actualidad existen una gran cantidad de trabajos respecto a las redes neuronales aplicados en la industria petrolera. Sin embargo, existen pocas publicaciones realizadas para la estimación de las propiedades PVT con RNA, porque estos PVT son particularmente difíciles de estudiar, por su composición y cambios de fases. Las principales publicaciones que se encuentran disponibles son resumidas en los siguientes párrafos.

Gharbi y Elsharkawy presentaron dos modelos de redes neuronales para estimar la presión de burbuja y el factor de volumen del aceite, para aceites crudos del Medio Oriente. La arquitectura del primer modelo de la red neuronal fue definida por dos capas ocultas (Gharbi y Elsharkawy⁴¹, 1997). El modelo de la presión de burbuja tuvo ocho neuronas en la primera capa y cuatro neuronas para la segunda capa. El factor de volumen del aceite quedó definido con 6 neuronas en ambas capas. Ambos modelos fueron entrenados usando 498 conjuntos de datos, reportados en la literatura y de fuentes no publicadas. El modelo se probó con 22 conjuntos de datos para el aceite crudo del Medio Oriente. Los resultados mostraron mejoramiento sobre los métodos convencionales. Gharbi y Elsharkawy⁴² (1997) presentaron otro modelo de red neuronal para estimar la P_b y B_{ob} de forma universal. Ellos usaron 5200 datos de análisis PVT, representando 350 tipos de aceites crudos de diferentes partes del mundo. La P_b y B_{ob} fueron considerados como variables de salidas, mientras que la T , API , γ_g y R_s fueron establecidas como variables de entrada. La arquitectura de la red neuronal más exitosa fue diseñada con una sola capa oculta con 5 neuronas, esto es para la P_b y B_{ob} .

Varotsis⁴³ et al. (1999) presentó un nuevo enfoque para determinar las propiedades del aceite y gas y condensado. El modelo (backpropagation) fue desarrollado usando 650 muestras de fluidos de diferentes yacimientos del mundo. La base de dato fue dividida aleatoriamente en 80 % para el entrenamiento, 10 % para la validación y 10 % para la prueba. El modelo desarrollado mostró errores promedios de predicción de 0.5-2.5 % para el aceite y gas y condensado, respectivamente.

Osman⁸ et al. (2001) desarrolló un nuevo modelo (backpropagation) para predecir B_{ob} , basado en las RNA usando datos experimentales de todo el mundo. Se utilizaron 803 conjuntos de datos publicados de los campos de Medio Oriente, Malasia y del Golfo de México. De los 803 conjuntos de datos, 402 fueron para el entrenamiento, 200 para la validación cruzada y 200 para la prueba del modelo. La arquitectura de la red consistió de tres capas, en el primero se introducen las variables de entrada R_s , T_{yac} , γ_g y γ_o , la segunda capa se estableció con 5 neuronas y la tercera con una neurona, representando la salida de B_{ob} . El porcentaje de error relativo generado en éste modelo fue de 1.7886 % con un coeficiente de correlación de 0.988.

Al-Mahourn⁴⁴ (2002) presentó un modelo para predecir la presión de burbuja y el factor de volumen del aceite en la presión de burbuja para el aceite crudo de Arabia Saudita. El modelo utilizó 283 conjuntos de datos. La predicción del factor de volumen del aceite en la presión de burbuja presentó un porcentaje de error absoluto de 0.5166 con un coeficiente de correlación de 0.9989.

Osman⁴⁵ et al. (2005) desarrolló dos modelos (función base radial y backpropagation) para predecir las propiedades de la salmuera. El primer modelo predice la densidad de la salmuera, factor de volumen de formación y la compresibilidad isotérmica, en función de la presión, temperatura y la salinidad. Su arquitectura se definió con tres capas (entradas, oculta y salidas), la primera capa consta de tres neuronas, la segunda capa con 38 neuronas y la tercera capa contiene 3 neuronas de salida. El segundo modelo fue desarrollado para predecir la viscosidad como una función de la temperatura y la salinidad. La topología del segundo modelo consta de dos neuronas de entradas (temperatura y salinidad), la capa oculta consta de 2 neuronas y la capa de salida una sola neurona (viscosidad). Un total de 1040 conjuntos de datos fueron utilizados, 520 para el entrenamiento, 260 para la validación cruzada y 260 para la prueba.

Omole⁴⁶ et al (2009) presentó otro estudio para la predicción de la viscosidad del aceite crudo en la presión de burbuja. Se usaron 32 conjuntos de datos, la cual, fueron coleccionados de la región Delta de Nigeria. De los 32 conjuntos de datos fueron divididos en tres partes, la primera consta de 17 datos para el entrenamiento de la red, 5 conjuntos de datos para la validación y 10 se utilizaron para probar que la red funciona con gran confiabilidad y exactitud. La topología de la red (backpropagation) se estableció con tres capas, la primera hace referencia a las entradas (P , T , γ_g , API , R_s), la capa

4. DESARROLLO DE UNA RED NEURONAL APLICADO EN LA INGENIERÍA PETROLERA

oculta se definió con 7 neuronas y la tercera capa con una neurona, que representa la viscosidad del aceite en la presión de burbuja. El modelo de RNA mostró ser superior a las correlaciones empíricas, generando un bajo error relativo absoluto de 0.06781 y un coeficiente de correlación de 0.9989.

Naseryan Moghadam²⁸ et al (2011) introdujo un nuevo modelo para predecir las propiedades del aceite crudo iraní, estas fueron la P_b y B_{ob} . Para desarrollar el modelo se utilizaron 218 conjuntos de datos obtenidos en diferentes yacimientos de Irán. Los datos se dividieron en 85 % para el entrenamiento (190 conjuntos de datos) y 15 % para la validación cruzada (28 conjuntos de datos). La arquitectura de la red consta de tres capas, la primera recibe el conjunto de datos de entrada ($R_s, \gamma_g, \gamma_{API}, T$), la segunda capa (oculta) se definió con 12 neuronas y la tercera capa son las salidas de la red con dos neuronas, que representa la P_b y B_{ob} . El máximo porcentaje de error relativo absoluto de ambas etapas (entrenamiento y validación) fue del 19.9 % con un coeficiente de correlación mínima de 0.996.

Makinde⁴⁷ et al. (2012) desarrolló un modelo (backpropagation) para determinar la viscosidad del aceite bajosaturado, por lo que utilizó 105 conjuntos de datos para construir la red. Los datos fueron coleccionados de la región delta de Nigeria. La topología de la red se definió con tres capas, en la primera se definen las entradas, el número óptimo de neuronas en la capa oculta fue de 10 y la capa de salida con una sola neurona (viscosidad sobresaturada). Los datos fueron divididos en tres conjuntos, 63 datos se utilizaron para el entrenamiento, 21 para la validación cruzada y 21 datos para la fase de prueba. El modelo alcanzó un error promedio relativo absoluto de 0.01998 y un coeficiente de correlación de 0.999.

Afoama⁴⁸ et al (2014) introdujo un nuevo estudio para predecir la p_b y B_{ob} , basado en 269 conjuntos de datos de diferentes yacimientos de Delta de Nigeria. Los datos se dividieron en tres grupos, el primero fue de 196 conjuntos de datos para el entrenamiento, el segundo con 49 para la validación y 24 para la etapa de prueba. El modelo mostró que tiene un mejor coeficiente de correlación que otras correlaciones, 0.977 y 0.9899 para P_b y B_{ob} , respectivamente.

Salem⁴⁹ et al (2015) presentaron 3 modelos de la inteligencia artificial para predecir B_{ob} , P_b , R_s , γ_g y γ_{API} . Un total de 760 conjuntos de datos fueron usados en este estudio, los datos provienen de distintas publicaciones. Los datos se dividieron en tres partes, 532 para el entrenamiento, 114 para la validación y 114 para la prueba de los modelos (backpropagation y función base radial) de redes neuronales. La topología de backpropagation (BP) fue de cuatro capas, una de entrada, dos ocultas y una de salida. Para la estimación de cada propiedad del aceite, se definieron distintos números de neuronas en las capas ocultas. Los resultados del backpropagation fueron comparados con las correlaciones empíricas, la función base radial (FBR) y la lógica difusa (LD). El estudio mostró que la lógica difusa supera a todos los modelos. En la publicación se logra

observar que, entre los resultados de los modelos de la inteligencia artificial no existió una gran diferencia, para B_{ob} , P_b y R_s , porque reportaron un coeficiente de correlación por arriba de 0.99 (BP, FBR y LD) y para γ_g y γ_{API} el coeficiente de correlación varía de 0.91-0.9782.

4.3. Metodología

La siguiente metodología es un compendio de los diferentes temas que involucra la recopilación, análisis, clasificación, procesamiento y la validación de los resultados de una red neuronal. La presente metodología tiene como objetivo proporcionar un proceso simplificado y confiable para el tratamiento de datos, pasando por el diseño de la arquitectura de la red hasta la fase de prueba.

4.3.1. Recopilación y clasificación de datos PVT

Actualmente estamos viviendo en la edad de los datos. El crecimiento insólito de volumen de datos es un resultado de la informatización de nuestra industria y de la necesidad de poder conocer con lo que se está trabajando. En este caso particular, los PVT no son la excepción, porque existen suficientes para definir un modelo mediante técnicas de aprendizajes de máquinas para obtener un mejor desempeño en la exactitud de lo que se pronostica. Sin embargo, no todos los datos pueden ser utilizados, por lo que debemos de aplicar métodos que permitan extraer los datos más representativos o mediante el establecimiento de criterios fundamentados.

De acuerdo a lo anterior, los criterios que se aplican a los datos tratados son la de McCain⁵⁰ y León García et al⁵¹. El primer criterio se usa para clasificar los datos que son provenientes de varias partes del mundo, por ser usada como una referencia estándar. Por otra parte, se ha observado que los criterios publicados en la literatura técnica internacional no son adecuados para clasificar los yacimientos de México, por lo que, se usa el nuevo enfoque que establece León García et al, publicada por la AIMP⁵¹.

La mayoría de los datos recopilados provienen de las literaturas publicadas, éstos se dividen en dos partes. El primer grupo de datos se derivan de diferentes partes del mundo, principalmente del Medio Oriente. El segundo grupo de datos provienen de los campos de México.

4. DESARROLLO DE UNA RED NEURONAL APLICADO EN LA INGENIERÍA PETROLERA

Tabla 4.1: Principales criterios propuestos para la clasificación de tipos de fluidos de los yacimientos.

Criterios propuestos para aceite negro		
Propiedad	León et al ⁵¹ . (Yacimientos de México)	McCain ⁵⁰
Factor de volumen del aceite (B_o , m^3/m^3)	<1.5	<2.0
Relación gas aceite (RGA, m^3/m^3)	<130	<356
Densidad del aceite (gr/cm^3)	>.865	>.8
Densidad del aceite ($^{\circ}API$)	<32	<45

4.3.2. Preprocesamiento de información

Cuando se trabajan con grandes volúmenes de datos, se requiere implementar técnicas de minería de datos, sin embargo, la información que se utiliza en el presente estudio, no es significativo para tales técnicas.

Aunque no se implementó explícitamente las técnicas de minería de datos, de alguna manera se ve reflejado en la etapa de clasificación de los tipos de aceites. Las etapas más importantes en el preprocesamiento de datos⁵² son:

Limpieza de datos. En esta fase se excluyen todos los datos que son incompletos (por ejemplo, cuando no se encuentra una variable en un conjunto de datos), corrección de datos ruidosos (pueden existir unidades de medidas diferentes) y/o remover los outliers (valores atípicos). Pueden existir conjuntos de datos consistentes, sin embargo, puede estar dentro del grupo como único, por ejemplo, la clasificación de aceite en el criterio de McCain indica que para aceite negro debe ser menor a 45 °API, pero, puede suceder que, de los 100 conjuntos, solo tres pertenece a los aceites extrapesados y los demás a los aceites pesados. Desde tal perspectiva, esos datos no serían representativo en el entrenamiento de la red neuronal o para otro método de estimación.

Integración de datos. Los datos pueden provenir de varios “almacenes”, esto implica una posible repetición de datos. En este caso, se ordenaron los datos de cualquier variable del conjunto de datos, posteriormente, manualmente se observó una variable y si existe coincidencia en los valores, se procede a comparar las demás variables de ambos conjuntos, si existe una coincidencia total, se elimina el conjunto repetido.

Reducción de datos. Existen casos en que se integran datos de diferentes fuentes y no son repetidos. Sin embargo, el porcentaje de datos de cada fuente puede

ser muy distinto y puede influir en los resultados esperados. En este caso, cada campo petrolero del mundo tiene diferentes comportamientos, por ejemplo, si el total de la información sólo 10 % de los datos pertenecen a otro campo, puede ser que sea necesario excluirla.

Transformación de datos. La transformación de datos es uno de los pasos más importante que se tiene que realizar para entrenar una red neuronal. Esto consiste en cambiar la dimensión de los datos reales, es decir, pasar de un rango original a un rango más pequeño. La normalización es una técnica que pertenece a esta etapa, y ayuda a acelerar la fase de aprendizaje de una red neuronal, como también la reducción del porcentaje de error. El método de normalización que se implementará, se conoce como Min-Max, la cual, establecemos un rango de $[-1,1]$, porque es el rango en el que trabaja la función de activación de la red neuronal(en este trabajo mostró mejores resultados la función tangente sigmoideal).

4.3.3. Elección del algoritmo RNA

El modelo de red backpropagation puede ser implementada mediante varios algoritmos^{*53}. Para el presente trabajo se elige el algoritmo de Levenberg-Maquardt^{54,55} por ser un método más sofisticado^{**}, la cual acelera el proceso de convergencia de manera más práctica.

Actualmente, los algoritmos que utilizan las redes neuronales, ya no es necesario programarlas, debido a la existencia de softwares que contienen funciones precargadas o incluso librerías completas de redes neuronales. Por conveniencia y para fines de este trabajo, se utilizará el software MATLAB. Las ventajas que proporciona MATLAB son muchas, pero la más importante para el presente estudio son las librerías de redes neuronales.

Para construir modelos de redes neuronales en MATLAB, es necesario entender el funcionamiento de sus librerías. Existen cuatro niveles de diseño de una red neuronal en MATLAB. La primera facilita su uso mediante una sencilla interfaz, donde sólo puedes cargar las variables de entradas y salidas. El segundo nivel también muestra una interfaz que permite modificar: la cantidad de neuronas de la capa oculta, el modelo de red neuronal, función de activación y el porcentaje de datos de aprendizaje (entrenamiento, validación y prueba). La tercera opción es realizar un pequeño algoritmo de ejecución: en este nivel se utiliza los scripts de MATLAB y se utilizan comandos que tienen argumentos con varias entradas; modelo de red, algoritmo de solución, vector de

*Se dividen en dos categorías: la heurística (técnicas informales o prácticos) y la de optimización numérica estándar.

** Cuando un algoritmo básico de backpropagation es aplicado a un problema real, el entrenamiento puede durar días o semanas.

4. DESARROLLO DE UNA RED NEURONAL APLICADO EN LA INGENIERÍA PETROLERA

elementos de entradas y salidas, porcentajes de división de datos para el aprendizaje y diseños de capas ocultas.

Para un mejor entendimiento del funcionamiento de las redes neuronales, en este trabajo se elige el cuarto nivel. Este nivel nos permite acceder todos los componentes (comandos específicos) de la librería. Utilizando la mayoría de los componentes de la librería se generó un nuevo algoritmo de programación enfocado a la predicción de las propiedades de los fluidos petroleros. Lo anterior, podemos establecer como nuestra primera etapa de programación, debido a que sólo son líneas de comandos, es decir, sólo son códigos.

MATLAB no sólo permite generar líneas de códigos, también ofrece herramientas para diseñar interfaces de usuarios. En este trabajo, se simplificará las dificultades de diseño y/o programación de la red mediante algoritmos de automatización y construcción de interfaces que cubren todos los procesos de tratamiento de datos, procesamiento y simulación de una red neuronal.

Las descripciones del uso de las interfaces desarrolladas son detalladas en el Apéndice A. OPEN FLUID es el nombre asignado al software desarrollado en este estudio. Cabe mencionar que este desarrollo fue una de las etapas más complicadas y de mayor requerimiento de tiempo.

4.3.4. Arquitectura y etapas de procesamiento de la Red Neuronal Artificial

La arquitectura de una red neuronal, se define con un proceso de prueba y error. Los números de capas y neuronas, varían de distintas formas hasta encontrar una combinación que muestre resultados razonables en nuestra predicción. El entrenamiento de la red neuronal forma parte de este proceso. Cabe mencionar que se requiere mucho tiempo para definir la arquitectura de una red neuronal, pueden ser horas o días.

Existen tres etapas de procesamiento en una red neuronal: la fase de entrenamiento, validación y prueba. El entrenamiento de la red, busca un modelo que ajuste o relacione los datos de entradas con los datos de salidas, hasta en encontrar un error mínimo. Dentro del proceso de entrenamiento se lleva a cabo la validación cruzada, este proceso ayuda a elegir el modelo más óptimo. La validación cruzada ya no busca ajustar los pesos del modelo RNA. La fase de prueba sólo utiliza datos nunca vistos por la red y se simula la predicción para conocer los errores que podremos esperar en una nueva estimación. En el primer caso de estudio se muestran las curvas de los tres procesos y puede ser más explícita la explicación.

4.3.5. Resultados y análisis de tendencia

Aunque la red muestre excelentes resultados estadísticos, debe ser sometido varios análisis de tendencia, para comprobar que el modelo sigue las leyes físicas de un yacimiento. Existen modelos que se ajustan correctamente a un comportamiento real, sin embargo, no logran seguir los fenómenos físicos de un objeto en estudio, por lo tanto, en cada caso de estudio se establecerá este proceso.

4.4. Primer caso de estudio: Predicción de la presión de burbuja y el factor de volumen del aceite en la presión de burbuja

4.4.1. Adquisición y análisis de datos

Después de adquirir, clasificar y preprocesar la información de las propiedades PVT, se recopilaron 303 conjuntos de datos, publicadas en diferentes literaturas: Glaso³⁴, Al-Mahourn³⁶ y Mahmood⁵⁷. Cada conjunto de datos contiene: P_b , γ_g , B_{ob} , $^\circ API$, R_s y T_y . Los rangos de las propiedades se establecen en la Tabla 4.2. Las entradas de la red neuronal están definidas por γ_g , γ_{API} , T_y y R_s , mientras que la salida son P_b y B_{ob} , una salida para cada modelo de red. La presión de burbuja ha recibido una atención especial en el desarrollo de las correlaciones. Primero, porque es la base para derivar otras propiedades del aceite y segundo, porque define el punto de transición de la región de aceite saturado y bajo saturado durante el decremento de presión⁵⁸.

Tabla 4.2: Rangos de las propiedades usadas (aceite negro).

	$R_s(\frac{m^3}{m^3})$	$^\circ API$	$T_y(^{\circ}C)$	γ_g
Mínimo	16.0285	27.2	26.6667	0.71
Máximo	347.2841	44.8	146.6667	3.4445

Cuando los dominios de los elementos de entradas de la red neuronal son considerablemente diferentes, provoca que durante el entrenamiento de la red sea más inestable, por lo tanto, los resultados pueden ser pocos exactos. Por ejemplo, el rango de P_b tiene un dominio de [10.1969 - 389.9437], mientras que B_{ob} tiene un dominio de [1.087 - 1.997], en kg/cm^2 y m^3/m^3 respectivamente. Con lo anterior, también se puede argumentar que el tipo de unidades de medidas reportadas pueden afectar el entrenamiento de la red, cada propiedad del aceite tiene un dominio diferente. Con el fin de eliminar el problema de los rangos de las entradas y salidas de una red neuronal, se preprocesa

4. DESARROLLO DE UNA RED NEURONAL APLICADO EN LA INGENIERÍA PETROLERA

los conjuntos de datos en un nuevo rango, limitándola entre $[-1,1]$, mediante el método de normalización de mínimo y máximo:

$$v_i' = \frac{v_i - \min_A}{\max_A - \min_A} (Nuevo_{\max_A} - Nuevo_{\min_A}) + Nuevo_{\min_A} \quad (4.1)$$

Donde:

v_i : define n valores observados, $v_1, v_2, v_3, \dots, v_n$

A : vector que contiene todos los elementos

v_i' : nuevo valor en el rango $[Nuevo_{\min_A} - Nuevo_{\max_A}]$

El proceso de desnormalización es similar, solamente se cambian en los términos de nuevo valores a unidades de medidas reales. Esto se requiere después de obtener los resultados de la red neuronal.

4.4.2. Arquitectura y etapas de procesamiento de la RNA

En este estudio, el algoritmo de Levenberg-Maquardt del modelo backpropagation es usado. Las redes backpropagation son de múltiples capas: entrada, ocultas y salida. Cada capa contiene neuronas que son conectadas a otras neuronas. Las conexiones tienen valores numéricos, conocidos como **pesos**, la cual, están asociadas entre las neuronas. Para que la red muestre razonables resultados, se tiene que modificar los pesos hasta alcanzar un error mínimo. Los pesos son modificados con la fase conocido como entrenamiento de la red neuronal, y usa un conjunto de datos para lograr su “aprendizaje”. Para evitar un sobreentrenamiento, se implementa un proceso de validación durante el entrenamiento de la red, esta etapa actualmente se considera como un proceso interno del entrenamiento. El conjunto de validación se ingresa a la red para comprobar si el error obtenido se encuentra dentro de un cierto rango. Estos conjuntos de validación no se usan para ajustar los pesos, sin embargo, ayuda a elegir la arquitectura de la red con los mejores pesos. Cabe mencionar que en el proceso de entrenamiento disminuye los errores conforme aumenta los enfoques (iteraciones). Si los errores del proceso de validación empiezan a incrementar, después de alcanzar un error mínimo y los errores del entrenamiento siguen disminuyendo, este proceso se detiene. Por lo tanto, los pesos del último enfoque son elegida para continuar con la fase de prueba. Este conjunto nunca se utiliza en los procesos de entrenamiento y validación. Una vez que se selecciona el modelo basado en el conjunto de validación, los datos del conjunto de prueba se aplican en el modelo de red y se encuentra el error para este conjunto. Los errores que se obtienen en el conjunto de prueba, es una representación del error que podemos esperar de los datos absolutamente nuevos para el mismo problema.

Modelo 1. Los datos son divididos en tres partes: entrenamiento (75 %), validación (15 %) y prueba (15 %). No existe una regla que permita definir el porcentaje de división del conjunto total de datos. Sin embargo, después de varias pruebas de entrenamiento,

4.4 Primer caso de estudio: Predicción de la presión de burbuja y el factor de volumen del aceite en la presión de burbuja

muestran mejores resultados, la proporción mencionada. Por otra parte, la arquitectura de la red neuronal se diseña a prueba y error, con la configuración siguiente: la primera capa se establece con cuatro neuronas, representando la R_s , γ_g , γ_{API} y T_y . La segunda capa (oculta) contiene doce neuronas y la tercera capa con una sola neurona, representando la p_b (ver Fig. 4.1a).

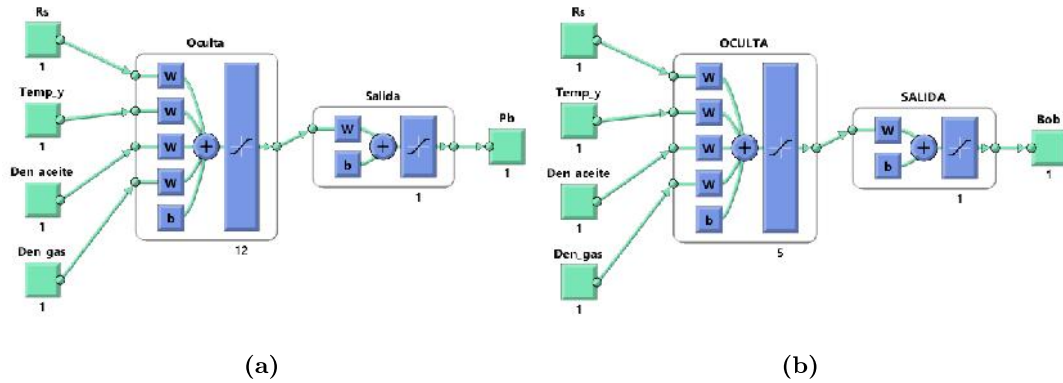


Figura 4.1: Arquitectura RNA: a) Presión de burbuja, p_b y b) Factor de volumen del aceite, B_{ob} .

Modelo 2. Para la estimación de B_{ob} , se usa una estructura de 4-5-1. La primera capa consiste de cuatro neuronas representando los valores de entrada de la R_s , γ_g , γ_{API} y T_y . La segunda capa se asignan cinco neuronas y la tercera capa una sola neurona, representando el factor de volumen del aceite en la presión de burbuja, B_{ob} (ver Fig. 4.1b).

4.4.3. Resultados y discusiones

Después de realizar varias configuraciones en la arquitectura de la red neuronal, los resultados de las curvas de errores: entrenamiento, validación y prueba, son mostradas en la Figura 4.2.

La mayoría de los trabajos publicados en ingeniería petrolera, no se muestran las curvas de errores, la cual, son muy importantes para analizar si el aprendizaje de la red fue realizado correctamente.

La curva de error del entrenamiento, generalmente disminuye conforme aumentan las iteraciones, en la curva azul presenta tal comportamiento. Por otro lado, en la curva de error de validación se busca un error mínimo para detener el entrenamiento, sin embargo, para conocer el valor mínimo del error, se requiere revisar el vector que contiene todos los errores de validación e identificar en que iteración se encuentra. En el algo-

4. DESARROLLO DE UNA RED NEURONAL APLICADO EN LA INGENIERÍA PETROLERA

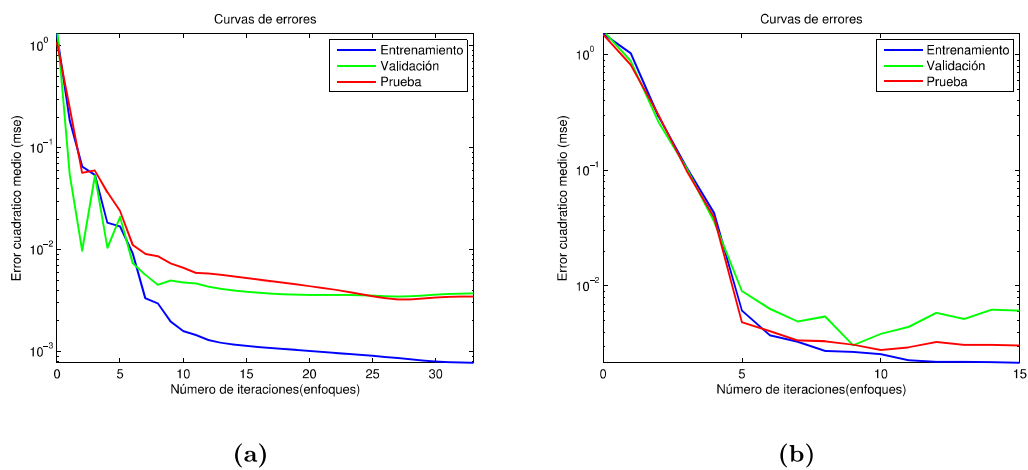


Figura 4.2: Curvas de errores: (a) Presión de burbuja, p_b y (b) Factor de volumen del aceite, B_{ob} .

ritmo se configuró para 6 enfoques (iteraciones) adicionales después del punto mínimo, para observar el incremento del error de validación y para detener el entrenamiento. La curva de error de la prueba debe ser similar a la curva de error de validación, porque tanto en la validación y prueba son valores insertados (desconocidos) en la red neuronal, por lo que, se espera obtener valores de errores similares en la fase de prueba. Si la curva de error de la etapa de prueba incrementa drásticamente por encima de la curva de error de validación, se considera que la red se sobreentrenó (sobreajuste o memorización). Lo anterior se verifica, después del punto mínimo de error de validación.

El siguiente paso de verificación es la revisión de las gráficas de regresiones de las tres fases. El parámetro estadístico más importante a identificar es el coeficiente de correlación (R^2 , coeficiente de determinación).

Modelo 1

En la Figura 4.3 se pueden observar el comportamiento de ajuste de cada fase durante el procesamiento de datos en la red neuronal.

La línea recta azul (entrenamiento), se traslapa sobre la línea de 45 grados, debido a que el ajuste de todos los valores esperados es estimado con gran estabilidad. Esta curva puede llegar a desviarse por arriba o por abajo de la línea de 45 grados, y eso dependerá si el valor estimado es superior o inferior al valor esperado, pero en este caso, se muestra un excelente resultado. De manera similar para la fase de validación y prueba, sin embargo, la fase de prueba ya no realiza ningún ajuste en la red neuronal, es

4.4 Primer caso de estudio: Predicción de la presión de burbuja y el factor de volumen del aceite en la presión de burbuja

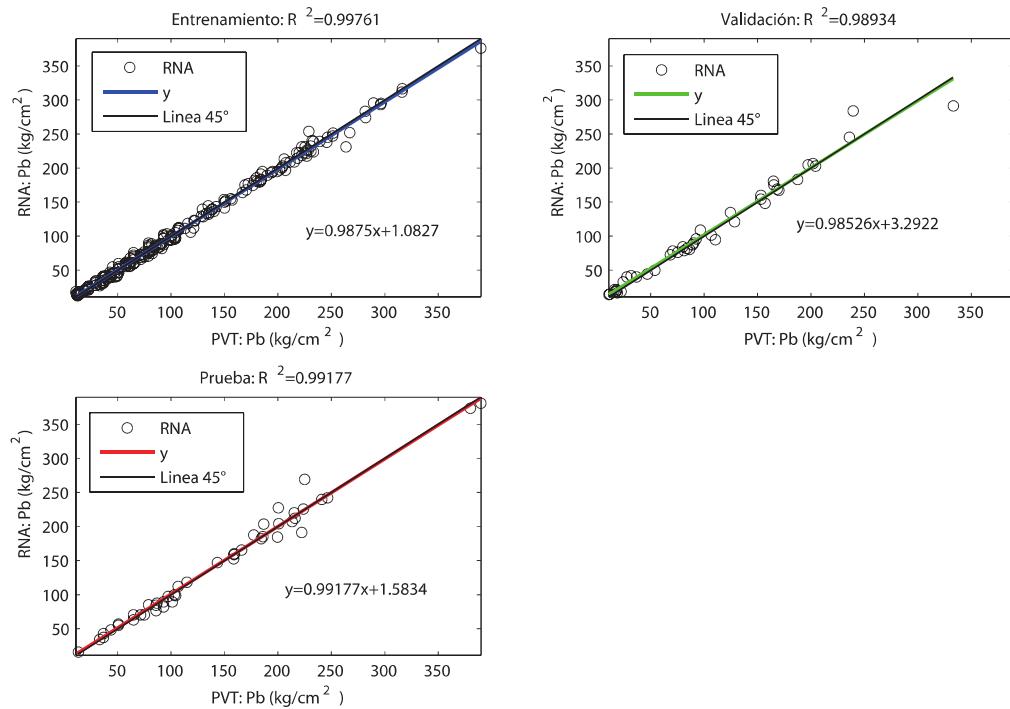


Figura 4.3: Gráficas de regresiones para el entrenamiento, validación y prueba del modelo de red de l_{pb} .

solamente el uso del modelo de red elegida. Para datos totalmente nuevos, la estimación esperada sería de la calidad reportada en la fase de prueba.

Las etapas mencionadas anteriormente, utilizaron un grupo de datos, la cual, fue dividido de la manera siguiente: entrenamiento 213 conjunto de datos (70%), validación 45 conjuntos de datos (15%) y 45 conjuntos de datos para la prueba (15%). Los resultados estadísticos de las tres fases para la p_b se muestran en la Tabla 4.3.

Con el fin de comprobar el desempeño y exactitud de nuestro modelo de red para la p_b , se compara con otras correlaciones empíricas. Los datos provienen principalmente del Medio Oriente, en consecuencia, se usan dos principales correlaciones desarrolladas para ésta área geográfica. Por otro lado, la correlación de Standing es recomendado para uso general y es uno de los modelos que se considera de referencia para desarrollar otras correlaciones⁵⁸. Las correlaciones usadas son: Al-Mahourn³⁶ (1988), Dokla-Osman⁵⁹ (1992) y Standing³¹ (1947), en la Figura 4.4 se pueden observar la estabilidad de cada modelo. Los resultados estadísticos son reportados en la Tabla 4.4.

4. DESARROLLO DE UNA RED NEURONAL APLICADO EN LA INGENIERÍA PETROLERA

Tabla 4.3: Parámetros estadísticos de las tres fases (p_b): entrenamiento, validación y prueba.

	ENTRENAMIENTO	VALIDACIÓN	PRUEBA
Error relativo promedio (%)	6.2128	10.8067	5.4843
Error relativo máximo(%)	66.8399	44.1978	19.7885
Error relativo mínimo (%)	0.0016	0.4672	0.0010
Coefficiente de correlación, R^2	0.9976	0.9893	0.9917
Conjuntos de datos	213	45	45

Tabla 4.4: Resultados estadísticos de cada modelo de predicción de p_b .

	Standing (1947)	Al-Mahourn (1988)	Dokla-Osman (1992)	RNA
ERP (%)	15.0877	17.0287	18.0421	5.4843
ERMAX(%)	87.7205	76.5031	79.0656	19.7885
ERMIN(%)	0.9259	0.0459	1.6444	0.0010
R^2	0.9612	0.9780	0.9206	0.9917

El porcentaje de error relativo promedio es un importante indicador de la exactitud de los modelos mostrados. En la Tabla 4.4 se reportan los errores relativos absolutos de todas las correlaciones. El modelo de RNA obtuvo un porcentaje de error relativo promedio (ERP) de 5.4843 %, mientras que otras correlaciones muestran errores más altos, Standing (1947), Al-Mahourn (1988) y Dokla-Osman (1992) con 15 %, 17 % y 18 %, respectivamente. El coeficiente de correlación de RNA, 0.9917, supera al de Standing, 0.9612, Al-Mahourn, 0.9780 y Dokla-Osman con 0.9206. El rango de aplicación de cada variable se muestra en la Tabla 4.6, solamente se considera para la fase de entrenamiento, la cual, coincide con la del B_{ob} .

Desde una perspectiva de comparación de datos esperados y de estimación, se contrasta en la Figura 4.5. Los ejes de las abscisas indican los números de muestras experimentales usadas para la fase de prueba, estos valores son iguales para cada modelo.

Modelo 2

Los resultados gráficos de regresión para las tres etapas de procesamiento de información de la RNA se muestran en la Figura 4.6.

4.4 Primer caso de estudio: Predicción de la presión de burbuja y el factor de volumen del aceite en la presión de burbuja

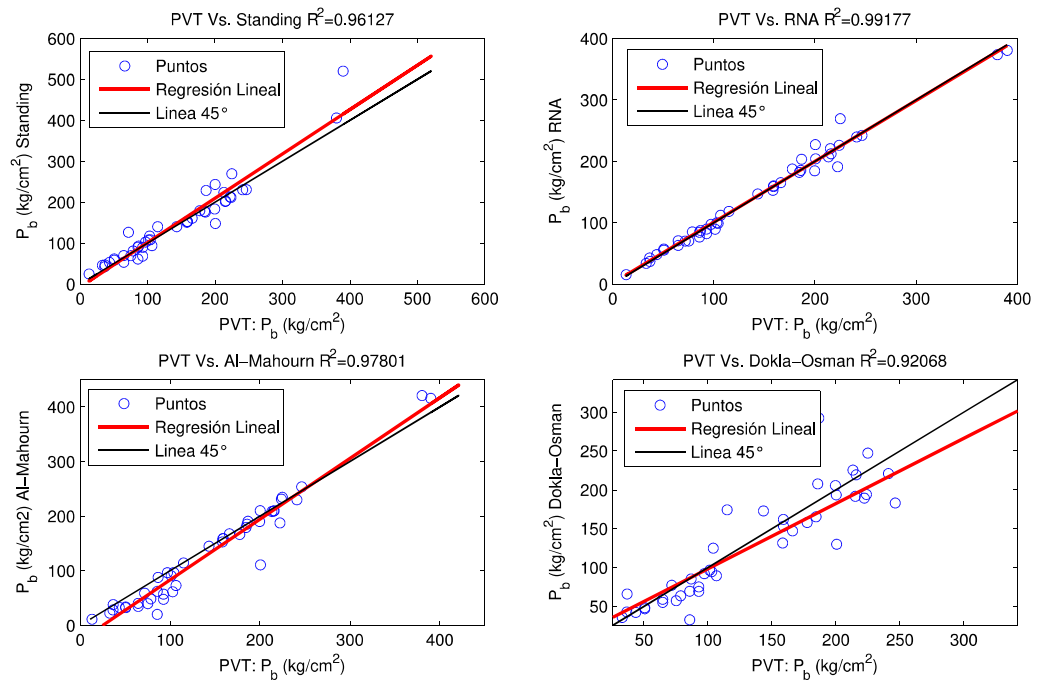


Figura 4.4: Comparación de modelos de predicción para p_b .

Las líneas de regresión de las tres etapas muestran un traslape con la línea de 45 grados, por lo tanto, significa que existe una excelente estabilidad en las tres fases de la red neuronal. Es importante analizar los diferentes tipos de porcentajes de errores que la red arroja. Estos datos estadísticos se muestran en la Tabla 4.5.

Tabla 4.5: Parámetros estadísticos de las tres fases de RNA para B_{ob} .

	ENTRENAMIENTO	VALIDACIÓN	PRUEBA
Error relativo promedio (%)	0.9146	1.0660	0.9995
Error relativo máximo (%)	6.4871	5.6867	4.0681
Error relativo mínimo (%)	0.0015	0.0418	0.0683
Coefficiente de correlación, R^2	0.9953	0.9929	0.9949
Conjuntos de datos	213	45	45

4. DESARROLLO DE UNA RED NEURONAL APLICADO EN LA INGENIERÍA PETROLERA

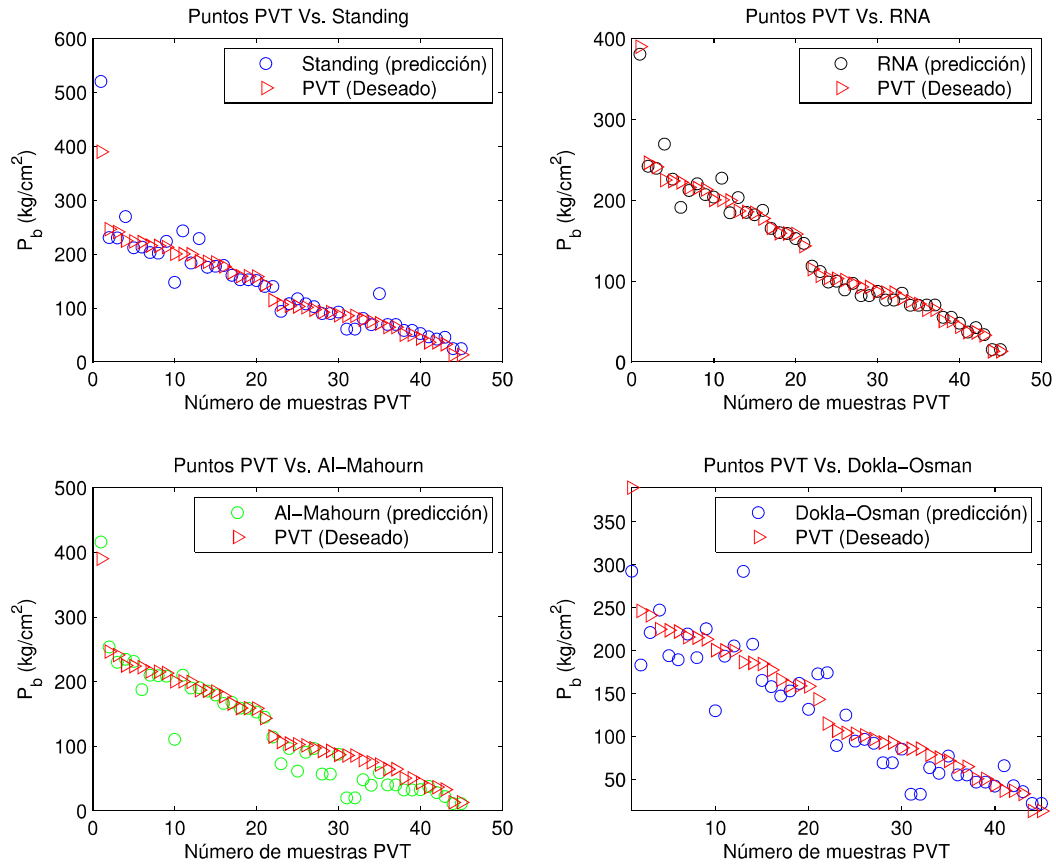


Figura 4.5: Comparación de modelos de predicción para p_b .

El porcentaje de error promedio de las tres fases son bastantes pequeños, por lo que, el modelo muestra gran potencial para la predicción de valores de B_{ob} . Los rangos de datos usados para las tres etapas son mostrados en la Tabla 4.6.

4.4 Primer caso de estudio: Predicción de la presión de burbuja y el factor de volumen del aceite en la presión de burbuja

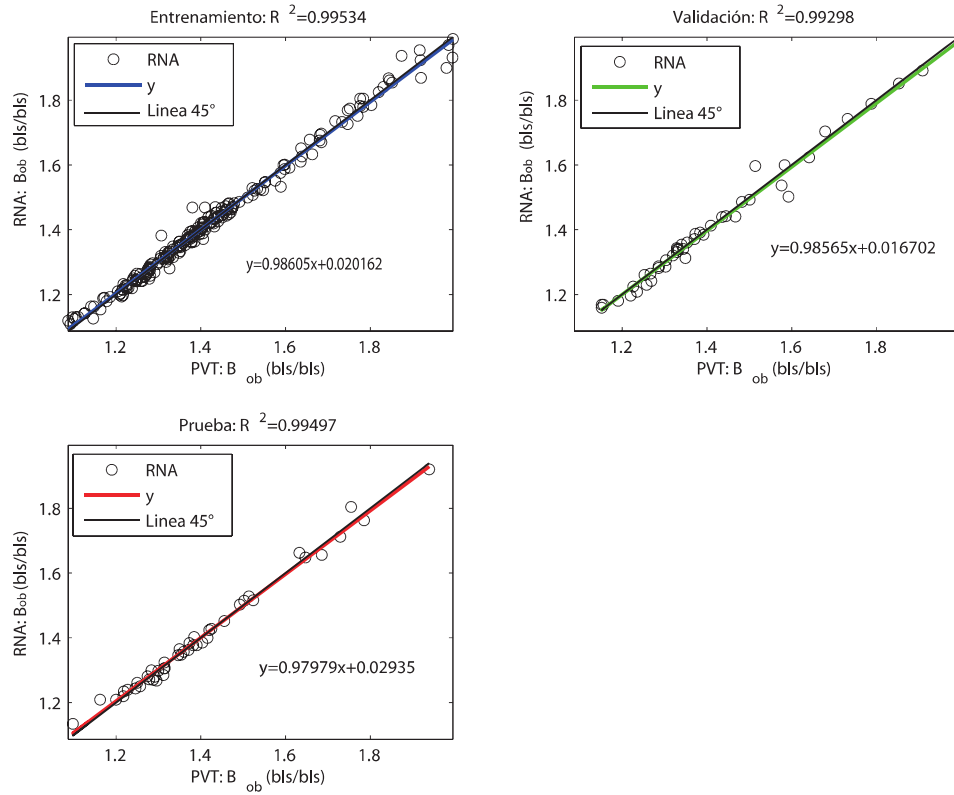


Figura 4.6: Gráficas de regresión (B_{ob}): entrenamiento, validación y prueba.

Tabla 4.6: Rango de datos usados para las tres etapas de la RNA (B_{ob}).

	ENTRENAMIENTO		VALIDACIÓN		PRUEBA	
	Mínimo	Máximo	Mínimo	Máximo	Mínimo	Máximo
$R_s(m^3/m^3)$	16.0285	347.2841	32.057	285.3072	16.3847	281.211
$^\circ API$	27.1	44.8	27.2	44.6	27.4	43.8
$T_y \text{ } ^\circ C$	26.6667	146.6667	23.3333	146.6667	26.6667	146.6667
γ_g	0.71	3.4445	0.755	2.1753	0.755	2.5585

Las correlaciones empíricas son usadas para estimar el parámetro B_{ob} , y son comparados con los resultados de la red neuronal. Los parámetros estadísticos son mostrados en la Tabla 4.7.

4. DESARROLLO DE UNA RED NEURONAL APLICADO EN LA INGENIERÍA PETROLERA

Tabla 4.7: Resultados estadísticos de cada modelo de predicción para B_{ob} .

	Standing (1947)	Al-Mahourn (1988)	Dokla-Osman (1992)	RNA
ERP (%)	2.3840	1.4323	2.5600	0.9995
ERMAX (%)	9.3779	8.4135	7.7761	4.0681
ERMIN (%)	0.0171	0.0062	0.2114	0.0683
R^2	0.9794	0.9839	0.9822	0.9949

El modelo de RNA supera las tres correlaciones, reportando un mayor coeficiente de correlación y un menor porcentaje de error promedio, 0.9949 y 0.9995% respectivamente. Para observar claramente la estabilidad de los modelos, en la Figura 4.7 se muestran las gráficas de regresiones.




Figura 4.7: Gráficas de regresiones para cuatro modelos.

Por último, se grafican los datos de B_{ob} contra la cantidad de muestras usadas en la fase de prueba, con el fin de lograr observar la diferencia de los puntos deseados y estimados (ver Fig. 4.8).

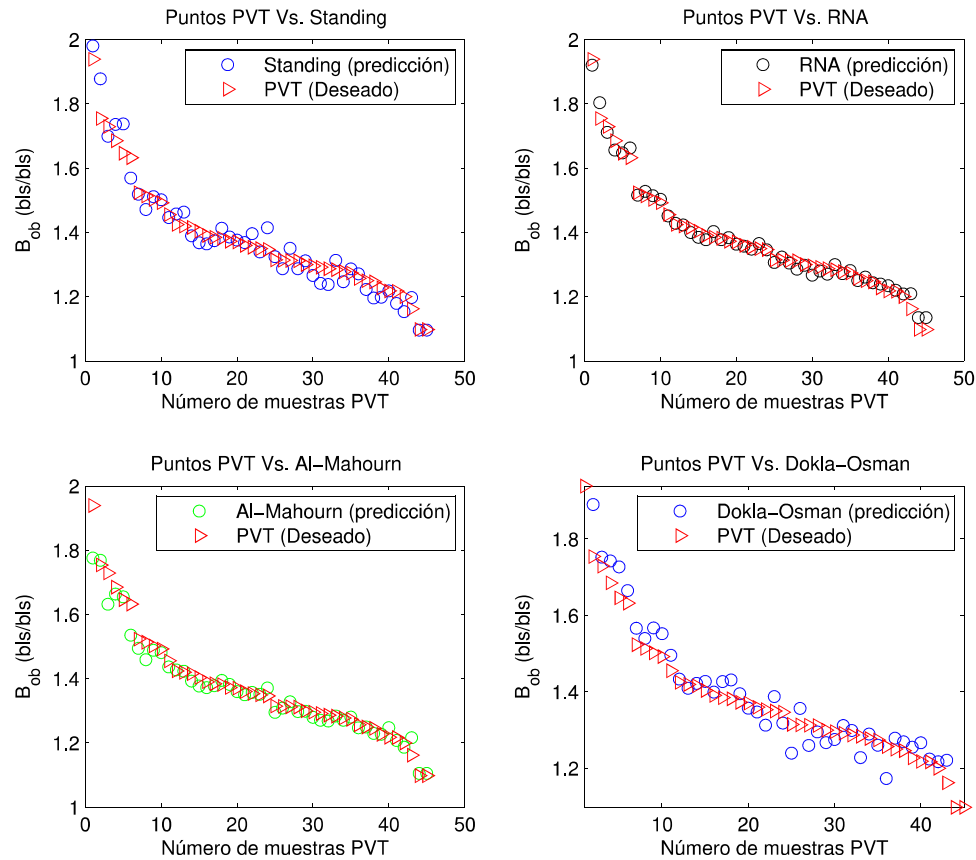


Figura 4.8: Gráficas de número de muestras contra modelo empleado.

4.4.4. Análisis de tendencia

Los dos modelos de red neuronal desarrollados superan a las correlaciones empíricas en la predicción de la presión de burbuja y el factor de volumen del aceite. Sin embargo, para comprobar que ambos modelos siguen los fenómenos físicos del yacimiento, se requiere realizar pruebas de tendencias. Estas pruebas se basan en la variación de una propiedad manteniendo constante las otras. Los valores de los parámetros (datos de entradas) son elegidas hipotéticamente. La p_b y B_{ob} será nuestro parámetro dependiente de R_s , T_y , γ_g y $^\circ API$.

4. DESARROLLO DE UNA RED NEURONAL APLICADO EN LA INGENIERÍA PETROLERA

Análisis 1: En las Figuras 4.9a y 4.9b se muestran las curvas de tendencias de la p_b y B_{ob} respectivamente, variando la R_s y cumpliendo con el rango de aplicación de ambos modelos. Tres parámetros se mantienen constante, $T_y = 90^\circ C$, $\gamma_g = 0.95$ y $^\circ API = 33$. Todos los modelos presentados en la Figura 4.9, cumplen con las leyes físicas de un yacimiento.

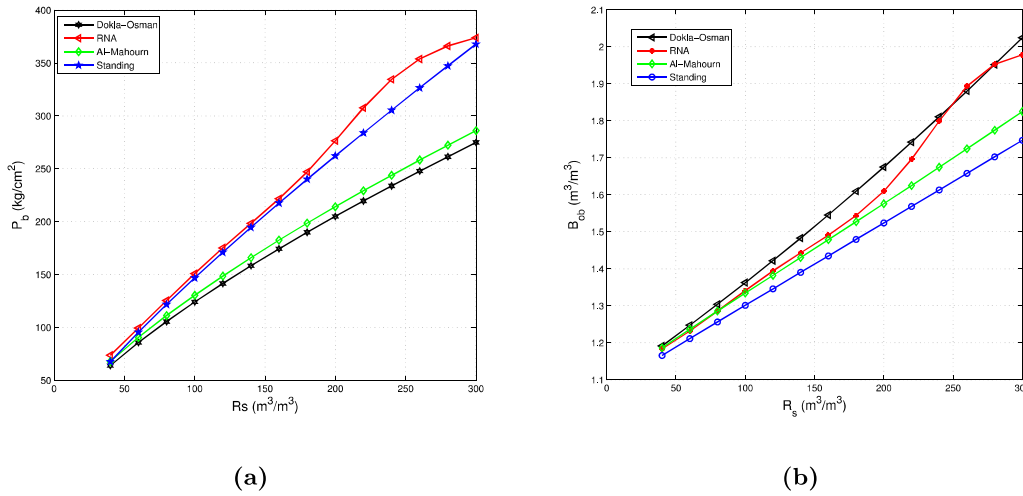


Figura 4.9: Comparación de modelos, variando R_s : (a) Modelos para p_b y (b) Modelos para B_{ob} .

Análisis 2: Ahora el parámetro de variación es la T_y , y se observa que no todos los modelos siguen las leyes físicas de los yacimientos (Fig. 4.10a y 4.10b). El modelo que abandona el comportamiento esperado de la presión de burbuja es la correlación de Dokla-Osman (Fig. 4.10a). Analizando desde un diagrama de fase, se puede verificar que conforme aumenta la temperatura, la presión de burbuja aumenta, por supuesto, considerando la limitación del punto crítico. Lo anterior, también fue demostrado en una publicación realizada por Al-Yousef y Al-Mahourm¹³, en un estudio de comparación de diferentes tipos de correlaciones empíricas. Por otra parte, también se observa que el modelo de Standing no logra seguir el comportamiento esperado para la estimación de B_{ob} (Fig. 4.10b). Los datos que se mantuvieron fijos son: $\gamma_g = 0.7$, $R_s = 70(m^3/m^3)$ y $^\circ API = 32$.

Análisis 3: Variación del parámetro densidad del aceite, manteniendo fijo $R_s = 120$, $T_y = 70$ y $\gamma_g = .8$. En la Figura 4.11a se observa nuevamente una variación del comportamiento de los modelos. La correlación de Dokla-Osman muestra una tendencia constante respecto al incremento de la densidad API, cuando los otros modelos mues-

4.4 Primer caso de estudio: Predicción de la presión de burbuja y el factor de volumen del aceite en la presión de burbuja

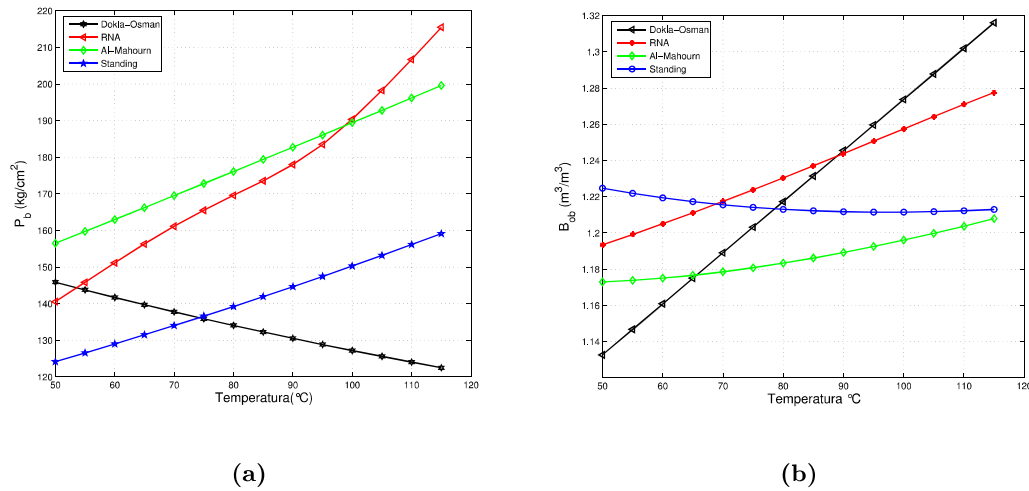


Figura 4.10: Comparación de modelos, variando T_y : (a) Modelos para p_b y (b) Modelos para B_{ob}

tran una tendencia de disminución de la p_b . Los tres modelos que muestran la misma tendencia están desarrollados con mayor conjunto de datos, por lo tanto, existe mayor probabilidad de generalizar el comportamiento de los fenómenos físicos, sin embargo, en el caso de las correlaciones empíricas, al tratar de generalizar su aplicación pierde la exactitud. Por otra parte, el modelo de red neuronal generaliza y mantiene su exactitud.

Análisis 4: En esta última variación se realiza con la densidad relativa del gas, γ_g . Para obtener las gráficas de la Figura 4.12, se mantiene constante la $R_s = 170$, $T_y = 100$ y $^\circ API = 40$. Los cuatro modelos no presentan mayor problema en el comportamiento de tendencia, esto es para la figura 4.12a y 4.12b. Podemos observar que la disminución de la presión de burbuja es función del incremento de la densidad relativa del gas. La curva de los modelos de RNA muestran una excelente estabilidad, por lo que, asegura una gran confiabilidad en la predicción de nuevos datos.

4.4.5. Conclusiones

1.- Un nuevo modelo fue desarrollado para estimar la presión de burbuja y el factor de volumen del aceite. El modelo fue desarrollado con redes neuronales artificiales, usando datos del Medio Oriente y Mar del Norte.

2.- De los 303 conjuntos de datos, 213 fueron usados para el entrenamiento, 45 para la validación y el resto se insertaron en la red para analizar su exactitud (fase de prueba). La división de datos es la misma para ambos modelos de red neuronal.

4. DESARROLLO DE UNA RED NEURONAL APLICADO EN LA INGENIERÍA PETROLERA

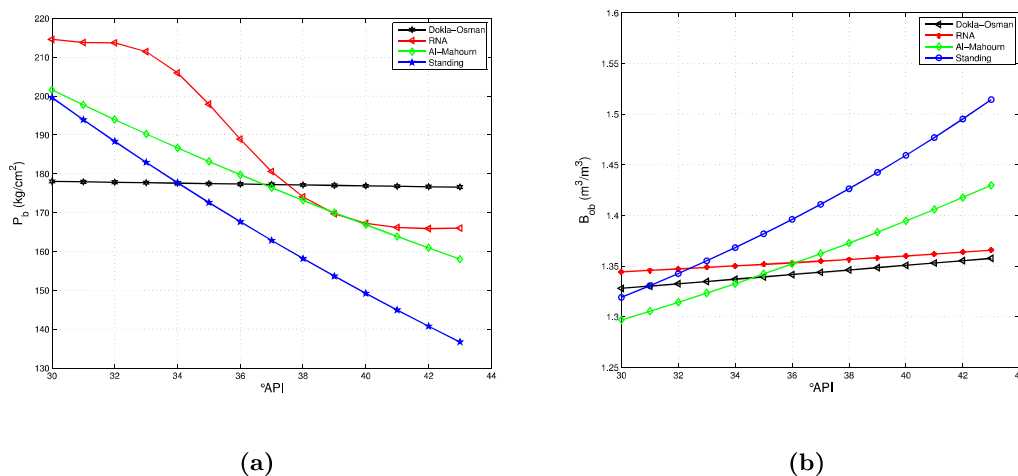


Figura 4.11: Comparación de modelos, variando °API: (a) Modelo para p_b y (b) Modelo para B_{ob} .

3.- La red construida para estimar la p_b , contiene tres capas: la primera capa (entrada) con 4 neuronas (γ , °API, R_s y T_y), la segunda capa 12 neuronas y la última capa con una neurona, representando la p_b . La arquitectura del segundo modelo (B_{ob}) está formada por tres capas: la capa de entrada con 4 neuronas, 12 en la capa oculta y 1 para la capa de salida.

4.- Los resultados de los dos modelos de red neuronal muestran mejores predicciones y con mayor exactitud que las correlaciones comparadas en este estudio. El coeficiente de correlación para la p_b y B_{ob} son de 0.9917 y 0.9949 respectivamente. Los porcentajes de errores también fueron reportados, el error promedio para p_b y B_{ob} son del 5.4843 % y 0.9995 % respectivamente.

5.- Ambos modelos fueron sometidos a un análisis de tendencia para verificar que realmente siga los comportamientos físicos de un yacimiento. En todas las pruebas, los modelos mostraron excelentes resultados, sin embargo, algunas correlaciones no cumplen con las leyes físicas de los yacimientos.

6.- El rango de aplicación de los modelos desarrollados pueden ser extendidos con mayor conjunto de datos.

4.5 Segundo caso de estudio: Generación completa del comportamiento de la curva B_o

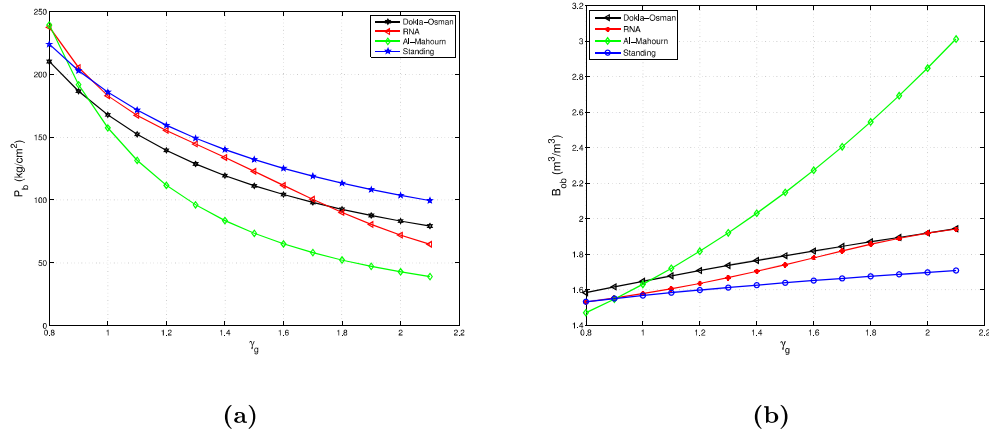


Figura 4.12: Comparación de modelos, variando γ_g : (a) Modelo para p_b y (b) Modelo para B_{ob} .

4.5. Segundo caso de estudio: Generación completa del comportamiento de la curva B_o

4.5.1. Introducción

Una gran cantidad de publicaciones han demostrado la efectividad de una red neuronal artificial en la predicción de dos principales propiedades, p_b y B_{ob} ^{44, 48, 41, 42, 60, 28, 46}. Sin embargo, son muy limitados los recursos que describen la generación del comportamiento completo de las propiedades volumétricas del aceite, usando redes neuronales^{*}.

Conocer el comportamiento completo de las propiedades PVT es de enorme importancia, porque permite definir los volúmenes, componentes, reservas, diseño de instalaciones superficiales y definir el costo de comercialización del aceite crudo.

Generalmente se obtienen muestras de hidrocarburos en el yacimiento con equipos especiales, manteniendo su condición original hasta el laboratorio, para lograr lo anterior se requiere de un gran suma de dinero y tiempo para obtener los resultados, y en ocasiones se requieren los reportes en momentos imprevistos. Una alternativa puede ser el uso de las técnicas de redes neuronales, la cual puede proporcionar los resultados de manera rápida y confiable para tomar las mejores decisiones en una situación inesperada.

^{*}Solo se encontró dos publicaciones, ambas describen muy breve el proceso.

4. DESARROLLO DE UNA RED NEURONAL APLICADO EN LA INGENIERÍA PETROLERA

Sin lugar a duda, en la industria petrolera se han presentado problemáticas por la falta de información, y por esto han desarrollado métodos indirectos para contrarrestar estos inconvenientes.

En consecuencia, el objetivo del presente estudio es desarrollar un modelo que permita generar el comportamiento completo de B_o , con pocas cantidades de datos.

4.5.2. Adquisición y análisis de datos

Un total de 12 reportes PVT fueron adquiridos. Estos reportes fueron obtenidos de los estudios realizados para los yacimientos de México. Los datos se dividieron en dos partes: para la zona saturada 84 conjuntos de datos y 50 para la zona bajosaturada. Los rangos de datos usados para el modelo saturado y bajo saturado se muestran en la Tabla 4.8. Cada conjunto de datos incluye las siguientes propiedades y componentes:

- R_{sb} : Relación de solubilidad
- T_y : Temperatura del yacimiento
- ρ_{ob} : Densidad del aceite saturado
- p : Presiones
- C_{1-5} : Composición del hidrocarburo

La composición del hidrocarburo proviene de los experimentos a composición constante (liberación flash). Solo se incluyen 5 componentes por dos motivos: 1) Algunos reportes PVT llegan hasta C_{6+} , entonces C_6 de un análisis composicional que tiene un alcance de C_{30+} es diferente a C_{6+} , 2) Tal vez exista alguna técnica que permita estandarizar tales inconvenientes, sin embargo, para fines de este trabajo sólo se considera estos parámetros.

4.5.3. Arquitectura y etapas de procesamiento de la RNA

Utilizando el algoritmo de Levenberg-Maquardt se construye dos modelos, saturado (primer modelo) y bajosaturado(segundo modelo). La arquitectura de ambos modelos se define con cuatro capas: la primera con 11 entradas, 10 en la oculta 1, 12 en la oculta 2 y una salida.

Para este tipo de estudio, existe una diferencia para la generación de datos de entrenamiento. Cada reporte PVT contiene un conjunto de datos y pueden ser función de una propiedad de interés. La red neuronal facilita involucrar una gran cantidad de entradas para una salida, encontrando la mejor relación existente entre las variables. Mientras exista más información representativa de entrada, la red puede mejorar por

4.5 Segundo caso de estudio: Generación completa del comportamiento de la curva B_o

Tabla 4.8: Rango de datos usados para el modelo saturado y bajosaturado.

	Mínimo	Máximo
R_s (m^3/m^3)	38.644	120.1913
ρ_o (gr/cm^3)	0.7276	0.8349
T_y ($^{\circ}C$)	46	105
Presión (kg/cm^2)	Sat. 0 y BajoSat. 140.647	Sat. 225.0352 y BajoSat. 351.6174
Metano (% mol)	10.9001	75.41
Etano (% mol)	2.0833	12.28
Propano (% mol)	2.2795	7.1029
i-Butano (% mol)	0.47	1.9463
n-Butano (% mol)	1.43	8.52
i-Pentano (% mol)	0.26	2.2085
n-Pentano (% mol)	0.3	3.4488

mucho más sus predicciones. Las entradas y salidas se detallan en los párrafos siguientes.

Entradas: Las entradas de la red neuronal son elegidas de las mediciones claves que pueden ser obtenidas en campo (in situ) mediante una plataforma de equipos móviles (paquete de hardware y software). El presente estudio utiliza metodologías usadas del PVT Express⁶² y de Varotsis⁴³ et al, donde las mediciones claves son obtenidas en cuatro etapas (módulos/equipos). El primer equipo obtiene mediciones como: densidad del fluido saturado, compresibilidad del fluido y la presión de saturación. Después de obtener las mediciones claves en la primera etapa, el fluido es desplazado a un segundo módulo, este equipo facilita la separación de una sola etapa de la muestra de fluido en condiciones controladas de temperatura y presión, que se establecen para estar cerca de las condiciones estándar. Al finalizar el proceso de liberación flash, se mide el gas liberado y la muestra de líquido, determinando la relación de solubilidad del aceite, R_s de una sola etapa de separación. Las muestras de gas y líquido obtenidas en la segunda etapa son inyectadas en el tercer módulo. Este módulo proporciona la composición (componentes puros y carbonos agrupados) de ambos fluidos, gas (C_{+12}) y líquido (C_{+36}). Todos los datos pueden ser medidos entre 8 a 12 horas usando una unidad móvil de PVT Express.

Para el presente caso de estudio, sólo se simula un estudio de PVT Express, porque los datos composicionales no pueden ser obtenidas mediante las redes neuronales (al

4. DESARROLLO DE UNA RED NEURONAL APLICADO EN LA INGENIERÍA PETROLERA

menos en este estudio). Sin embargo, es de gran importancia entender los procesos de predicción con estos tipos de modelos, además de que puede ser usado para generar nuevos puntos de interés de alguna propiedad PVT, por lo que, se convierte en una herramienta más y confiable.

Salida: En este caso, nuestro objetivo es generar la curva completa de B_o en función de la presión, pero lamentablemente la red neuronal no logra seguir la forma de la curva de B_o en todos los casos, es decir, el comportamiento de los fluidos de baja, media y alta volatilidad son diferentes, en consecuencia, una segunda transformación de datos es realizado. Ésta transformación se enfoca en establecer en un solo intervalo todos los valores de B_o , por lo que es necesario convertirlo en una variable adimensional⁶¹.

Transformación de datos B_o : Para realizar esta transformación se requiere identificar el valor del factor de volumen del aceite en la presión de burbuja y el factor de volumen del aceite a presión atmosférica, ambos a temperatura de yacimiento. Este tipo de transformación ha sido usada por las problemáticas existentes respecto a las correlaciones empíricas y trata de seguir el comportamiento de distintos tipos de fluidos, es decir, aceite negro o aceite volátil. La ecuación de transformación es la siguiente:

$$B_{oD} = \frac{B_{ob} - B_o}{B_{ob} - B_{oa}} \quad (4.2)$$

Una vez que los datos son transformados, una nueva relación entre variables puede ser implementada. En la Figura 4.13 se muestran los diferentes comportamientos de cada tipo de fluido. En este trabajo se reproducirán las curvas de la región de baja a media volatilidad, como se muestra en la Figura 4.14.

Superando la problemática de los tipos de comportamientos de cada aceite (se detalla en el análisis), se procede a entrenar la red con el 80% de los datos, 10% para validación y 10% para la fase de prueba. Los valores de los coeficientes de correlación para el modelo saturado se muestran en la Figura 4.15 y para bajosaturado en la Figura 4.16.

En las Figuras 4.15 y 4.16 se reportan valores de [-1,1] de los ejes de x y y , por la transformación específica que usa la red neuronal. Realmente son valores de B_{oD} generadas con los datos reales de B_o , pero sufre una segunda transformación para el rango en que opera la red neuronal. Ambos modelos muestran excelentes valores de coeficientes de correlación, pero, la red será sometida a pruebas de tendencias más adelante, para asegurar su confiabilidad.

4.5.4. Análisis y resultados

Para cumplir el propósito del estudio presente, fue necesario construir adicionalmente tres tipos de red. Los modelos de red neuronal son para determinar la p_b , B_{ob} y




Figura 4.13: Comportamiento baja, media y alta volatilidad, mediante B_{oD} .

B_{oa} , cada uno con diferentes conjuntos de datos, pero con una misma clasificación de aceite crudo, esto es para aceites de México⁵¹ (aunque la mayoría de los datos no son de México). La clasificación mencionada anteriormente es elegida porque los datos que se usan para entrenar la red neuronal del primer y segundo modelo, son totalmente para campos de México. La diferencia existente entre las dos (saturada y bajosaturada) y tres modelos adicionales, es que los primeros son entrenados con todos los valores de presiones para generar la curva completa de B_o (de cada PVT), y por otro lado, los tres modelos que se utilizaran de apoyo son entrenados con valores puntuales. Ambos grupos de red son fundamentales, porque, por ejemplo, el modelo que determina la presión de burbuja definirá la zona de transición de un aceite saturado y bajosaturado. El modelo que predice el valor de B_{ob} servirá para transformar los datos adimensionales a valores reales y como también formar un par de valores, la presión de burbuja con su correspondiente B_{ob} . El último modelo, definirá el valor de B_{oa} para una presión igual a cero a temperatura de yacimiento, también forma parte para la conversión de los valores adimensionales a valores reales.

De forma general, para el modelo B_{ob} y p_b , se utilizaron 210 conjuntos de datos (R_s , T_y , γ_o y γ_g), ambos incluyen el proceso de validación y prueba de la red, en las Tablas 4.9 y 4.10 se muestran los rangos de datos usados de los respectivos modelos. Para el B_{oa} (ver rango en la Tabla 4.11), solo se logró recopilar 21 conjuntos de datos, todas

4. DESARROLLO DE UNA RED NEURONAL APLICADO EN LA INGENIERÍA PETROLERA




Figura 4.14: Comportamiento adimensional de los datos B_o de cada PVT.

provenientes de los campos de México (valores puntuales de, R_{sb} , T_y , γ_o y γ_g), aunque es poca información, la red estima valores aceptables de B_{oa} . Los datos de entradas de cada modelo de red mencionados anteriormente usaron las siguientes propiedades: $R_{sb} = 104.8(m^3/m^3)$, $T_y = 83(^{\circ}C)$, $^{\circ}API = 26.8291$ y $\gamma_g = 1.0876$.

Ahora con todos los modelos disponibles, se procede a generar la curva completa de B_o . Primero se obtuvieron los valores de p_b , B_{ob} y B_{oa} , posteriormente se determinaron los valores adimensionales de B_o con el modelo de red saturado y luego para bajosaturado. Los datos calculados por la red se transforman a valores reales con la fórmula siguiente:

$$B_o = B_{ob} - B_{oD}(B_{ob} - B_{oa}) \quad (4.3)$$

En la Figura 4.17, se muestra la curva completa generada por la red, después de su transformación. Podemos notar que la región bajosaturado presenta una curva común para esta región. La región saturada es más difícil de generar su comportamiento, sin embargo, la red muestra un aceptable comportamiento suavizado.

Para comprobar la exactitud de los valores estimados por la red neuronal, se compara con los valores reales del PVT, como se muestra en la Figura 4.18. Se observa una gran aproximación a los valores reales y la red trata de seguir la curvatura del PVT.

4.5 Segundo caso de estudio: Generación completa del comportamiento de la curva B_o

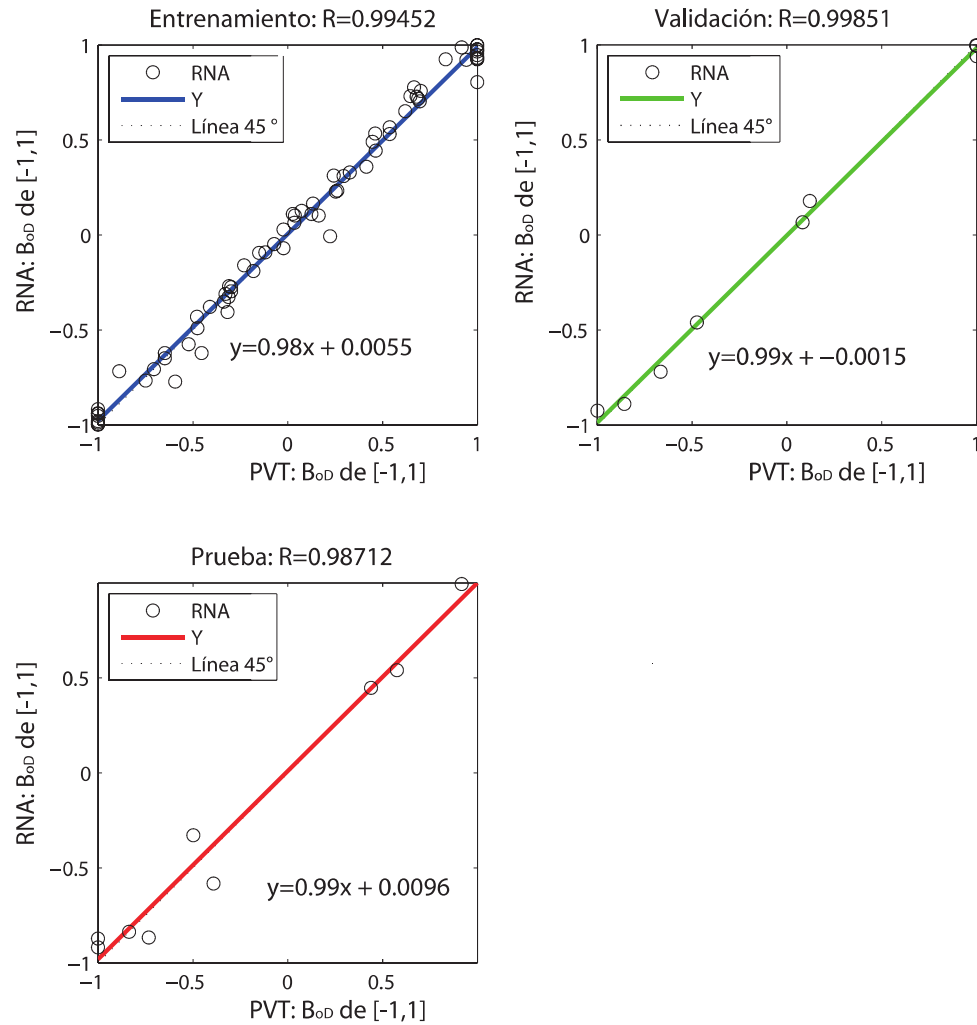


Figura 4.15: Coeficientes de correlación para el modelo saturado

Tabla 4.9: Rango de datos usados para el modelo B_{ob} .

	$R_s(m^3/m^3)$	$^{\circ}API$	$T_y(^{\circ}C)$	γ_g
Mínimo	1.5334	19	27	0.612
Máximo	125.0793	32	140	3.4445

4. DESARROLLO DE UNA RED NEURONAL APLICADO EN LA INGENIERÍA PETROLERA

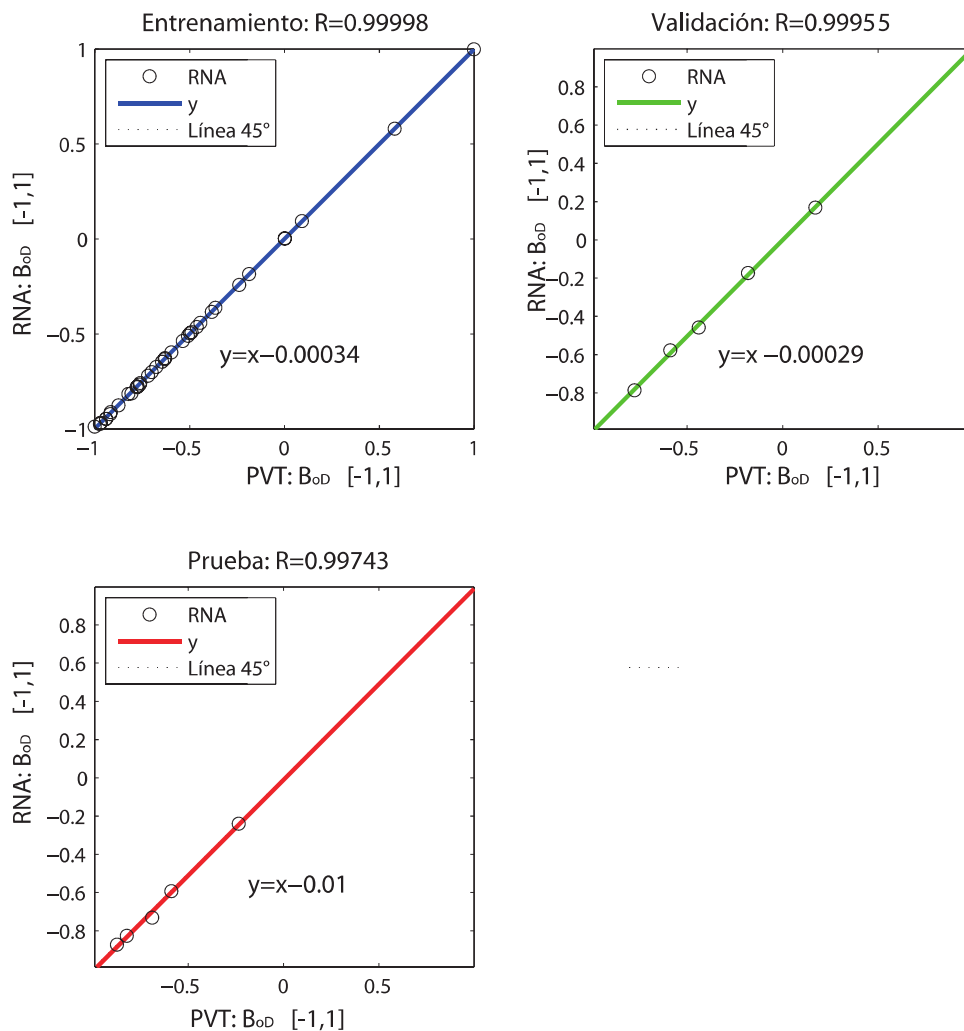


Figura 4.16: Coeficientes de correlación para el modelo bajosaturado.

Tabla 4.10: Rango de datos usados para el modelo p_{ob} .

	$R_s(m^3/m^3)$	$^{\circ}API$	$T_y(^{\circ}C)$	γ_g
Mínimo	4.5183	19	26.6667	0.612
Máximo	125.0793	32	140	3.4445

4.5 Segundo caso de estudio: Generación completa del comportamiento de la curva B_o

Tabla 4.11: Rango de datos usados para el modelo B_{oa} .

	$R_s(m^3/m^3)$	$^{\circ}API$	$T_y(^{\circ}C)$	γ_g
Mínimo	52.765	18.2354	69	0.634
Máximo	120.1913	30.5848	108	1.217




Figura 4.17: Curva B_o generada por la red neuronal.




Figura 4.18: Comparación de valores reales contra valores estimados por la RNA.

Además de comparar los valores reales de B_o contra los valores estimados por la RNA, se ejecutan dos modelos empíricos, la de Standing³¹ y Petrosky-Farshad³⁷. Standing se considera como un modelo de referencia y Petrosky-Farshad es elegido porque se desarrolló para aceites del Golfo de México. Los resultados gráficos son mostrados en la Figura 4.19.

Los valores estimados de B_o por la red neuronal junto con los del reporte PVT, son mostrados en la Tabla 4.12 y los rangos de datos usados para entrenar los dos modelos de red neuronal son reportados en la Tabla 4.13.

Podemos notar que la red neuronal se aproxima por mucho más a la forma de la curva de B_o , además de presentar un mayor grado de exactitud respecto a los dos modelos empíricos presentados. La red supera a los dos modelos, porque su salida está relacionada con mayor número de entradas, en cambio las correlaciones empíricas no rebasan más de cuatro variables.

Cabe mencionar, que cada modelo presentado se ha desarrollado con diferentes tipos de muestras de aceites. La red se desarrolló con 12 muestras de fluidos (reportes PVT de México). Para Standing³¹ y Petrosky-Farshad³⁷ fueron desarrollados con 22 y 81 muestras de aceites, respectivamente.

4.5 Segundo caso de estudio: Generación completa del comportamiento de la curva B_o

Tabla 4.12: Valores estimados de B_o por la red neuronal y del reporte PVT.

Presión RNA (kg/cm^2)	B_o RNA (m^3/m^3)	Presión PVT (kg/cm^2)	B_o PVT (m^3/m^3)
351	1.3507	351	1.3462
281	1.3634	281	1.3582
260	1.3678	210	1.3710
230	1.3733	147	1.2891
208	1.3771	91	1.2245
180	1.3457	49	1.1620
170	1.3303	24	1.1112
150	1.2961	7	1.0690
130	1.2661	1	1.0557
100	1.2303		
80	1.2067		
60	1.1766		
40	1.1346		
20	1.0841		
0	1.0513		

4. DESARROLLO DE UNA RED NEURONAL APLICADO EN LA INGENIERÍA PETROLERA




Figura 4.19: Comparación de modelos para generar la curva completa de B_o .

Tabla 4.13: Rango de datos usados para el modelo saturado y bajosaturado.

	Mínimo	Máximo
R_s (m^3/m^3)	38.644	120.1913
ρ_o (gr/cm^3)	0.7276	0.8349
T_y ($^{\circ}C$)	46	105
Presión (kg/cm^2)	Sat. 0 y BajoSat. 140.647	Sat. 225.0352 y BajoSat. 351.6174
Metano (% mol)	10.9001	75.41
Etano (% mol)	2.0833	12.28
Propano (% mol)	2.2795	7.1029
i-Butano (% mol)	0.47	1.9463
n-Butano (% mol)	1.43	8.52
i-Pentano (% mol)	0.26	2.2085
n-Pentano (% mol)	0.3	3.4488

4.5.5. Análisis de tendencia

En este apartado, se modificarán dos variables de entrada para predecir el comportamiento de la curva B_o . En este análisis identificaremos si el modelo sigue las leyes físicas del yacimiento.

De las 11 entradas de la red neuronal, dos variables son modificadas, R_s y T_y . Con una $T_y = 70(^{\circ}C)$ y $R_s = 70(m^3/m^3)$ se obtuvieron dos curvas de B_o , mostradas en la Figura 4.20.




Figura 4.20: Tres curvas de B_o , mediante RNA.

Analizando las gráficas de la Figura 4.20, podemos observar que efectivamente disminuye la presión de burbuja, cuando disminuye la temperatura del yacimiento, es decir, de $T_y = 83^{\circ}C$ a $T_y = 70^{\circ}C$. Lo anterior, puede ser explicado de manera explícita con un diagrama de fase. Antes del punto crítico de un diagrama de fase, podemos encontrar la máxima presión de burbuja con su respectiva temperatura. Entonces es lógico que, al disminuir la temperatura, la p_b disminuye, porque la composición del fluido se mantiene constante.

En la zona bajosaturada, presenta una pequeña separación entre las dos curvas (roja y azul), debido a que el modelo de predicción para B_{ob} sigue correctamente las leyes físicas del yacimiento, y los demás puntos depende de éste valor, B_{ob} .

Para la curva negra, es más drástico el cambio del comportamiento de B_o . Es claro que disminuye el valor del factor volumétrico del aceite en la presión de burbuja, ya que,

4. DESARROLLO DE UNA RED NEURONAL APLICADO EN LA INGENIERÍA PETROLERA

la relación de solubilidad es un indicador de la cantidad de gas que puede estar contenido en un fluido a una determinada presión y temperatura. Si existe menos gas, es obvio que el factor de volumen de aceite disminuye (analizando a partir de su definición) y en efecto también la presión de burbuja (los diagramas de fases para aceites con menos componentes ligeros, son más inclinados hacia el eje de la temperatura). La curva no presenta una buena “suavidad”, debido a los pocos datos usados en la construcción de la red, incluso puede variar a una escala mayor con otros puntos de interés, aunque estén en el rango. Por último, este estudio muestra el mejor resultado de los dos modelos de red (saturado y bajosaturado), y la metodología usada está basada en la que se implementa en la generación del PVT EXPRESS⁶².

4.5.6. Conclusiones

Dos modelos de red neuronal fueron construidos, una para la región saturada y otra para la zona bajosaturada. El comportamiento completo de B_o fue generado utilizando 5 modelos de red neuronal.

El comportamiento de B_o del reporte PVT se comparó con tres modelos, dos correlaciones empíricas y la curva generada por los modelos de red neuronal. Los valores estimados por los modelos de red neuronal, muestran mayor exactitud, por lo tanto, se ajusta mejor a la curva real, de acuerdo al tipo de fluido.

La red sólo puede operar un rango muy pequeño por la cantidad de datos usados.

El estudio realizado utiliza una metodología similar al que se usa para generar una curva de B_o en un reporte PVT sintético, conocido como PVT EXPRESS.

Capítulo 5

Conclusiones

Para el presente estudio, podemos concluir que el enfoque de red neuronal tiene muchas ventajas, porque no se requiere ser un experto para resolver un problema en estudio, sólo se establecen relaciones entre las entradas y salidas.

El campo de las redes neuronales es muy grande, sin embargo, existen herramientas que ayudan a facilitar su diseño. En este trabajo, fue documentado de manera general el algoritmo interno de la red neuronal usada. Aunque existan herramientas de apoyo en el diseño de una red, es importante conocer los procesos que lleva a cabo para interpretar y encontrar los mejores resultados.

Actualmente las redes neuronales son aplicadas en la industria petrolera. Los estudios con mayor documentación están enfocados para obtener los registros geofísicos de pozos. En la mayoría de los trabajos muestran excelentes resultados y por encima de los métodos convencionales(indirectos). Por otra parte, varios estudios han sido publicados últimamente para la estimación de las propiedades PVT, pero para valores puntuales. Las publicaciones sobre el uso de las redes neuronales provienen principalmente del Medio Oriente.

Durante décadas se han desarrollado un sin número de correlaciones empíricas, sin embargo, cada una de ellas funcionan para la región en que fue desarrollada. Existen correlaciones universales, pero a pesar de utilizar una gran cantidad de datos para su desarrollo, aún no muestran excelentes resultados.

Las publicaciones relacionadas con la predicción de las propiedades PVT mediante redes neuronales fueron resumidas brevemente, mencionando su arquitectura (capas y neuronas), la cantidad de datos usados, la división del total de datos, para la fase de entrenamiento, validación y prueba y los resultados estadísticos.

5. CONCLUSIONES

En este trabajo los datos usados para el primer caso de estudio provienen de distintas partes del Medio Oriente y que están publicadas en la literatura. El proceso de diseño de la arquitectura de la red neuronal es el proceso que más tiempo se requiere, además de la recopilación de datos. La estimación de la presión de burbuja es el parámetro más importante en la predicción de las propiedades PVT. Dos modelos fueron desarrollados, uno para estimar la presión de burbuja y el otro para predecir el factor de volumen del aceite en la presión de burbuja. Los valores reales esperados y tres correlaciones empíricas fueron comparados con los resultados de la red neuronal. Se identificó que existen parámetros estadísticos muy representativos para identificar la estabilidad y exactitud de una red neuronal, por ejemplo, el coeficiente de correlación para la estabilidad y el porcentaje promedio para la exactitud. En el análisis de tendencia se demostró que algunas correlaciones empíricas no siguen las leyes físicas del yacimiento, y las que son universales pierden la exactitud en sus predicciones. En cambio, la red neuronal cumple con los fenómenos físicos que suceden en el yacimiento y mientras más datos usados muestra mejor exactitud (caso contrario para las correlaciones empíricas).

En el segundo caso de estudio, fue más complicado por los pocos datos obtenidos para diseñar la red neuronal, aunque existen una gran cantidad de datos (reportes PVT), no es de fácil obtención. En este desarrollo se usaron más datos como entradas de la red, y se identificó que es muy importante conocer el origen de cada dato, por ejemplo, la composición del aceite puede ser obtenida mediante un estudio de laboratorio con la metodología de separación diferencial, a composición constante o con el fluido que se encuentra en el separador. El de nuestro interés fue el de composición constante, sin embargo, no todos los reportes PVT presentan tal estudio, por lo que, algunos fueron descartados. Por otro lado, existen estudios de separación flash, pero, presentan diferentes alcances en el estudio de la composición del fluido, es decir, algunos se reportan para, C_{6+} , C_{7+} o incluso C_{30+} . Por lo tanto, la composición del fluido como elementos de entradas solo llegan hasta C_5 . El desempeño de cada fase de la red para el modelo saturado y bajosaturado fueron reportados.

Tres modelos adicionales fueron desarrollados para poder generar la curva completa de B_o . La transformación adimensional de datos fue de los pasos más importantes para mejorar los resultados en la predicción de la red neuronal. Los datos adimensionales (saturado y bajosaturado) y valores puntuales (B_{ob} , B_{oa} y p_b) obtenidos por la red, se usaron para generar la curva completa del factor de volumen del aceite.

Los resultados del modelo saturado y bajosaturado se compararon con dos modelos empíricos, mostrando mejor comportamiento y exactitud la red neuronal. También se aplicó el análisis de tendencia para comprobar que efectivamente el modelo sigue las leyes físicas del yacimiento.

Es importante clasificar el aceite por su grado API (extra pesado, pesado, ligero o súper ligero), cuando existen datos muy dispersos. No obstante, cuando se tiene una gran cantidad de datos que, si cubre en todo el intervalo mediante una clasificación específica, es decir, a veces basta con la clasificación por su diagrama de fase (aceite negro o volátil en este caso). Este es una gran ventaja que ofrecen las redes neuronales, porque logra encontrar la relación que existe entre las variables de entradas y salidas, aunque sean muy complejas, la cual, a veces un modelo matemático no puede seguir.

Existen pocos estudios respecto a la generación del comportamiento completo de una propiedad volumétrica del aceite.

México carece de estudios para predecir las propiedades PVT mediante el uso de redes neuronales. Actualmente cuenta con suficientes datos y sería interesante implementarla para aceites negros, volátil y gas y condensado.

Las propiedades y composiciones de los fluidos deben ser calculados mediante estudios de laboratorios, sin embargo, existen diferentes motivos por la que no se realizan. Esta metodología puede ayudar a estimar las propiedades PVT con gran exactitud y confiabilidad. Las redes neuronales no pretenden sustituir a los estudios de laboratorios, pero puede contribuir el ahorro de tiempo, costos y riesgos de un proyecto en ejecución.

Un software (nombrado como OPEN FLUID) fue desarrollado para obtener todos los resultados y análisis antes mencionados.

Los estudios desarrollados en este trabajo, puede ser la base de posteriores aplicaciones de RNA en la predicción de las propiedades de los fluidos petroleros. Indiscutiblemente, ésta metodología puede ser extendida para integrar estudios geológicos y petrofísicos a la red neuronal, lo que en definitiva podrá aprovecharse para generar un potente software aplicado a las diversas áreas de la industria petrolera.

Apéndice A

Interfaces Open Fluid

Solamente se documenta de manera general para la predicción de propiedades volumétricas. El programa inicia de la manera siguiente:

Para entrar a la siguiente ventada, clic en ir y se mostrará una interfaz con varias opciones en la parte superior de la ventana. Cada opción contiene un conjunto de opciones o botones que permiten realizar ciertas tareas (ver Fig.A.2).

Al dar clic en el boton **Preprocesamiento**, mostrará dos opciones, **Importar datos** y **Normalización**. En la parte de Importar datos aparecerá un boton **Cargar datos**, desde un excel nombrado como **DATOSENTRENAMIENTO** en la hoja **DATOS**, realizará una lectura de datos cuando sea dado un clic. Es muy importante tener solo un encabezado en la hoja de cálculo y el 1 que se encuentra en la parte superior de los encabezados, no debe ser eliminado.

La normalización de datos se puede realizar después de escoger las columnas de donde se encuentran los datos de interés, esto es, las entradas y salidas que tendrá la red neuronal. La selección de varias columnas pueden ser elegidas presionando Ctrl + clic en cada una de ellas. También es importate indicar la fila de donde inician valores numéricos. Por el momento solo se puede normalizar de [-1,1].

En el botón **Arquitectura RNA**, se establecen nombres de las capas, entradas, números de entradas y números de capas. Cuando se asignan las neuronas en cada capa, se debe dar clic en **Agregar capas preestablecidas** y luego elegir la capa en el boton de opciones. La función de activación puede ser escogida a su criterio. En la parte de **Algoritmo y partición de datos** se asignan los porcentajes de la cantidad de datos que se usaran para cada fase de la red neuronal. También se presenta varias opciones del algoritmo de entrenamiento, todas son para Backpropagation.

Después de configurar la parte de **Arquitectura de RNA**, seguimos con el **En-**




Figura A.1: Ventana de inicio RNA PVT.

trenamiento, validación y prueba. En esta parte, existe más tratamiento de datos, el primer botón, **Entradas y salidas** (Fig. A.6) define explícitamente los datos de entradas y salidas. Posteriormente sigue la fase de corrida de la red neuronal, **RNA EVP(ajuste)**. Éste apartado es donde se requiere más tiempo para elegir el mejor entrenamiento, a veces es necesario correr la red las veces necesarias para alcanzar un coeficiente de correlación y un porcentaje de error deseado, la red nunca mostrará los mismos resultados en cada corrida porque internamente sus pesos son modificados (valores aleatorios) cada vez que se corre, **Correr RNA-PVT**. Cuando encuentren el mejor modelo, deben guardar esa red inmediatamente, para seguir con los posteriores pasos. Los **Modelos comparativos**, son incluidos para comparar los resultados de la red contra los resultados de las correlaciones empíricas. En los **Resultados** se muestran parámetros estadísticos para los resultados de todos los modelos. El botón **Gráficas** (Fig. A.7) contiene diferentes opciones: Regresión lineal EVP, Error medio cuadrático EVP, Gráficas RNA y PVT, Regresiones-Modelos y Gráficas Modelos. Es necesario haber ejecutado alguna de las opciones mostradas en la parte de **Modelos comparativos** para que todas las opciones puedan ser mostradas. Esta puede ser



Figura A.2: Ventana de inicio para propiedades volumétricas.

uno varios modelos y es necesario dar un clic a la propiedad que se desea predecir para que se muestra una nueva ventana de carga de datos (seleccionados por la red neuronal).

La exportación de datos se puede elegir para un Excel o un texto plano que solamente puede ser usado por Matlab. Algunas opciones mostradas siguen desactivadas*.

Cuando se requiere simular con nuevos datos, teniendo listo una red, solamente accederíamos al botón **Simular RNA** (Fig. A.8). Primeramente se debe elegir el modelo de red que se usará para predecir datos de interés. En **Importar valores**, solamente se eligen variables de entradas, **Agregar columnas**. La parte fundamental de ésta ventana es donde se definen los datos que usó la red cuando fue diseñada, por lo tanto debe haber un registro de esos datos (en la parte de Exportar resultados ya lo incluye). Cuando todo esté definido correctamente, podremos dar clic en **Predecir valor...** y los resultados serán mostrados.

*El programa está en mejora.

A. INTERFACES OPEN FLUID

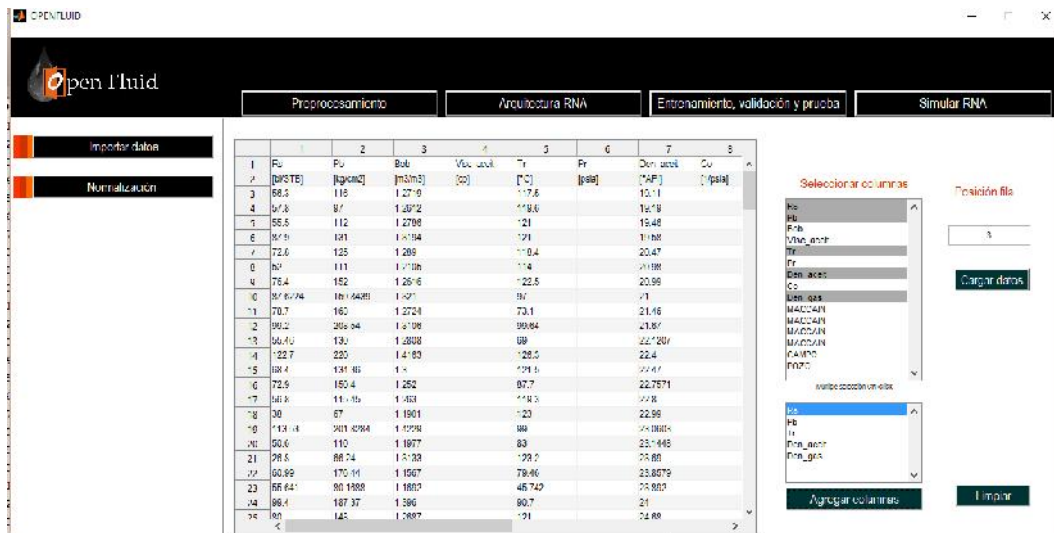


Figura A.3: Ventana del botón Importar datos.

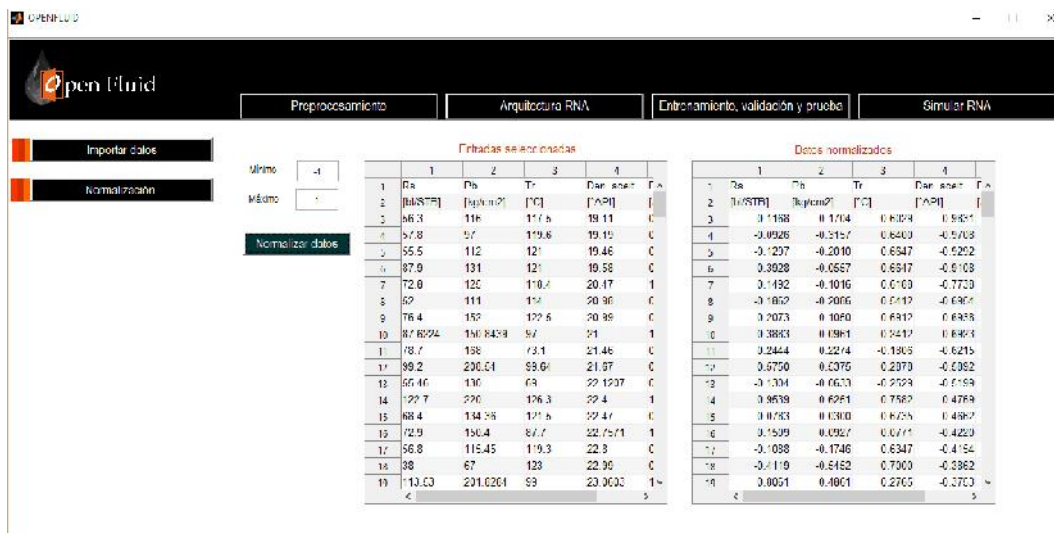


Figura A.4: Ventana del botón Normalización.

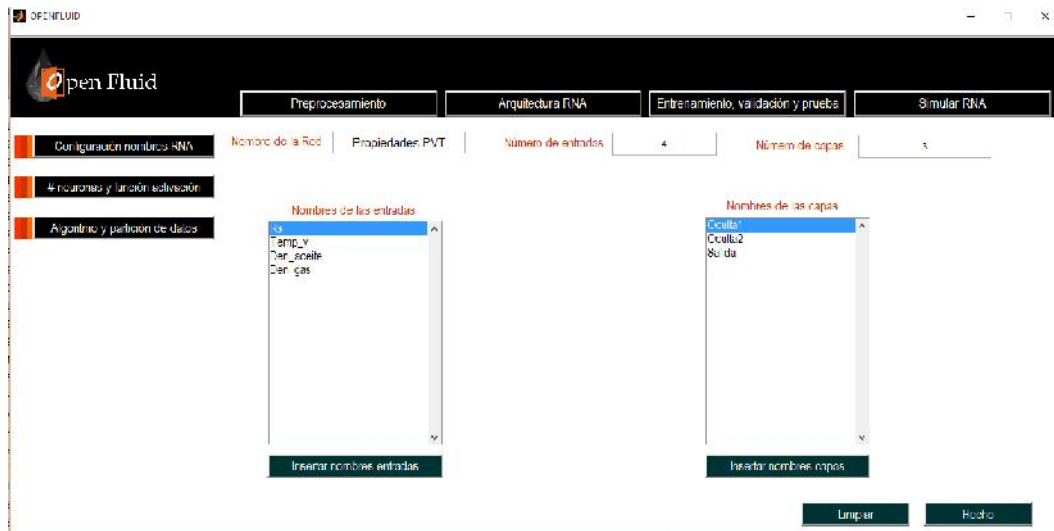


Figura A.5: Ventana del botón Arquitectura RNA.

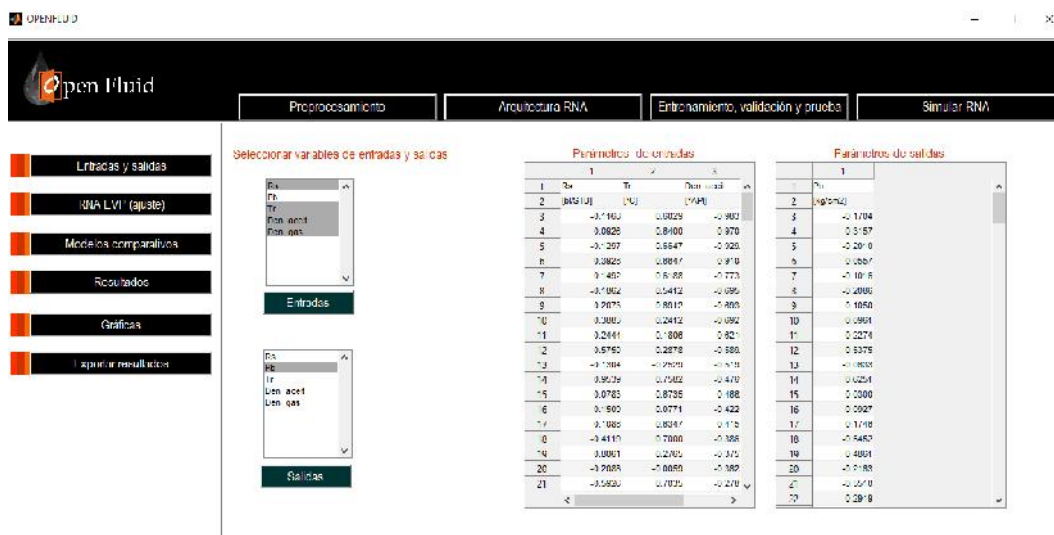


Figura A.6: Ventana del botón Entradas y Salidas.

A. INTERFACES OPEN FLUID

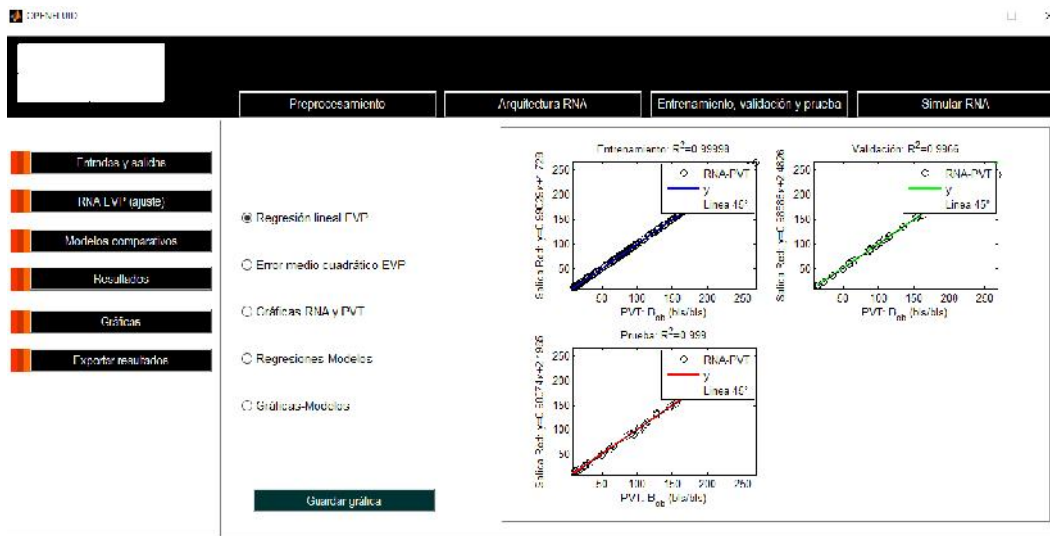


Figura A.7: Ventana del botón Gráficas(Regresión lineal EVP).

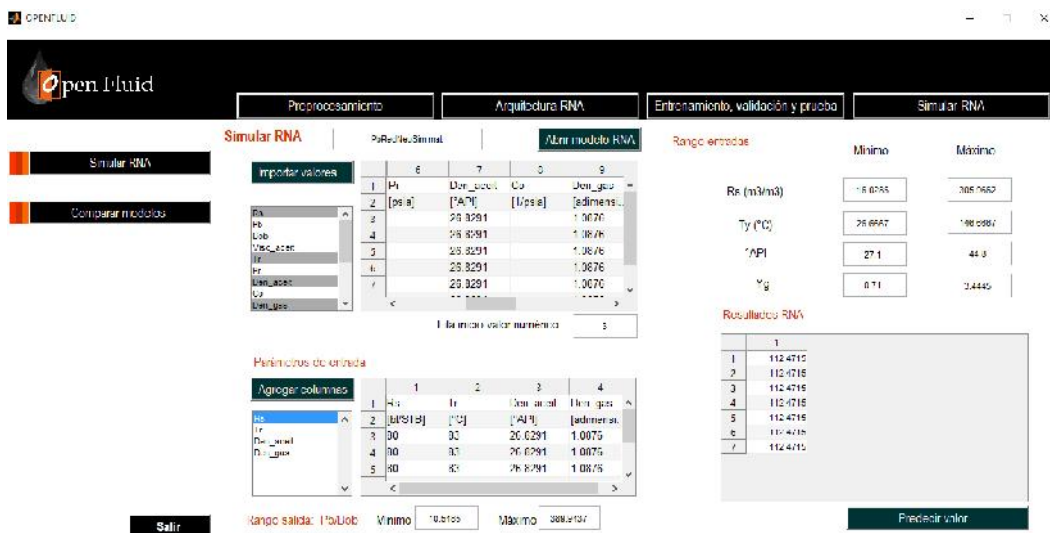


Figura A.8: Ventana Simular RNA.

Bibliografía

- ¹ Flores Hidalgo María del Carmen. *Introducción a las Redes Neuronales Artificiales y sus Apliaciones en la Ingeniería Eléctrica-Electrónica*. Tesis, Facultad de Estudios Superiores Cuautitlán, UNAM, 2010. [7](#), [8](#), [10](#), [17](#), [19](#)
- ² Aguilar Sánchez Alma Rosa. *Las Redes Neuronales Artificiales como una Herramienta Alternativa o Complementaria a los Métodos de Clasificación Tradicionales*. Tesina, Facultad de Estudios Superiores Acatlán, UNAM, 2008. [11](#), [17](#), [19](#), [21](#)
- ³ A. Boden Margaret. *Artificial Intelligence and Natural Man*. Basic Books, New York, 1977. [1](#)
- ⁴ Barrat James. *Artificial Intellegence and the End of Human Era, Our Final Invention*. Thomas Dunne Books, New York, October 2013. [1](#)
- ⁵ Ponce Cruz Pedro. *Inteligencia Artificial con Aplicaciones en la Ingeniería*. Alfaomega, primera edición, 2010. [2](#), [29](#)
- ⁶ Shubhendu Shukla S. and Jaiswal Vijay. *Applicability of Artificial Intelligence in Different Fields of Life*, volume 1. International Journal of Scientific Engineering and Research (IJSER). [2](#)
- ⁷ G.A. Alzate, A. Arbeláez-Londoño, and others. *Generating Synthetic Well Logs by Artificial Neural Networks (ANN) Using MISO-ARMAX Model in Cupiagua Field*. SPE 169388, 2014. [3](#)
- ⁸ E.A Osman, Ahmed O.A, Almarhoun, and A. M. *Prediction of oil PVT properties using Neuronal Networks*. SPE 68233, March 2001. [3](#), [64](#), [67](#)
- ⁹ J.L. Baldwin, D.N. Otte, and others. *Application of Neural Network Simulators to Problems in Well Log Interpretation*. SPE 19619, 1989. [3](#)
- ¹⁰ Ridha B. C. Gharbi, SPE, and others. *Neural Network Model for Estimating the PVT Properties of Middle East Crude Oils*. SPE 56850, 1999. [3](#)
- ¹¹ Mohaghegh Shahab. *Virtual-Intelligence Applications in Petroleum Engineering: Part 1—Artificial Neural Networks*. Distinguished Author Series, SPE 58046, 2000. [3](#)

- ¹² Nada. S. Ahmedzeki, Iqdam. M. Ridha, and others. *Development of PVT Correlation for Iraqi Crude Oils Using Artificial Neural Network*, volume 13. Iraqi Journal of Chemical and Petroleum Engineering, September 2012. [3](#)
- ¹³ Al-yousef, H. Y., AL-Marhoun, and M. A. *Discussion of Correlation of PVT Properties for UAE Crudes l₁*. SPEE 80, March 1993. [3](#), [84](#)
- ¹⁴ RC Chakraborty. *Fundamentals of Neuronal Networks*. AI Course, Lecture 37-38, Slides 03-12, June 01, 2010. [6](#), [7](#), [19](#)
- ¹⁵ María Genoveva Gonzáles Morán. *Santiago Ramón y Cajal a Cien Años del Premio Nobel*. Facultad de Ciencias, UNAM, Diciembre, 2006. [6](#)
- ¹⁶ Guadalupe Lugo, Patricia López, and Michel Olguín. *El Cerebro, 86 Mil Millones de Neuronas*. Gaceta UNAM, Semana Internacional en varias Entidades, 6 de abril de 2015. [6](#)
- ¹⁷ Cilimkovic Mirza. *Neural Networks and Back Propagation Algorithm*. Institute of Technology Blanchardstown. [7](#)
- ¹⁸ I.A. Basheera and M. Hajmeerb. *Artificial neural networks: fundamentals, computing, design, and application*. Journal of Microbiological Methods, Elsevier, 2000. [7](#)
- ¹⁹ Kriesel David. *A Brief Introduction to Neural Networks*. 2005. [11](#), [13](#), [19](#)
- ²⁰ [Sundar Pichai](#). *La prioridad de Google ya es la Inteligencia Artificial*. Forbes, Abril 28, 2016. [11](#)
- ²¹ Hayking Simon. *Neural Networks, A Comprehensive Foundation*. Pearson Prince Hall, second edition. [13](#)
- ²² Laurene Fausett. *Fundamentals of Neuronal Networks*. Architectures, Algorithms and Applications. [24](#)
- ²³ Graupe Daniel. *Principles of Artificial Neural Networks*. World Scientific, second edition. [33](#)
- ²⁴ Luisa Rolon et al. *Using Artificial Neural Networks to Generate Synthetic Well Logs*. Journal of Natural Gas Science and Engineering, Elsevier, October, 2009. [37](#)
- ²⁵ M Bhuiyan et al. *An Intelligent System's Approach to Reservoir Characterization in Cotton Valley*. M.S. West Virginia University, Morgantown, West Virginia. [38](#)
- ²⁶ Mohaghegh et al. *An Intelligent System Approach to Reservoir Characterization*. West Virginia University, Norwegian Formation Evaluation Society, 2002/2003, Season Stavanger May Meeting. [38](#)
- ²⁷ Bhatt Alpna. *Reservoir properties from well logs using neural networks*. Department of Petroleum Engineering and Applied Geophysics, Norwegian University of Science and Technology, 2002. [45](#)

-
- ²⁸ J. Naseryan Moghadam, K. Salahshoor, and R. Kharrat. *Introducing a New Method for Predicting PVT Properties of Iranian Crude Oils by Applying Artificial Neural Networks*. Petroleum Science and Technology, 22 March, 2011. 56, 68, 87
- ²⁹ Mohaghegh S., Ameri S., and West Virginia University. *Artificial Neural Network As A Valuable Tool For Petroleum Engineers*. SPE 29220, 1995. 64
- ³⁰ Mohaghegh Shahab and West Virginia U. *Neural Network: What It Can Do for Petroleum Engineers*. JPT, 1995. 64
- ³¹ Standing and M. B. *A Pressure-Volume-Temperature for Mixtures of California Oils and Gases*. Presented at the spring meeting of the Pacific Coast District, Division of Production, Los Angeles, California, May 16, 1947. 65, 77, 96
- ³² Standing and M. B. *Volumetric and Phase Behavior of Oil Field Hydrocarbon System*. Millet Print Inc., Dallas, 1977. 65
- ³³ Lasater and J. A. *Bubble Point Pressure Correlation*. SPE 957-G, TRANS AIME, p. 65-67, May 1958. 65
- ³⁴ Glaso and O. *Generalized Pressure-Volume-Temperature Correlations*. SPE 8016, JPT, p. 785-795, May 1980. 65, 73
- ³⁵ Vasquez and Beggs. *Correlation for Fluid Physical Property Predictions*. JPT, p. 968-970, June, 1980. 65
- ³⁶ Al-Mahourn and M. A. *PVT Correlations for Middle East Crude Oils*. SPE 13718, JPT, p. 650-666, May 1988. 65, 73, 77
- ³⁷ Petrosky, G. E., and Farshad. *Pressure-Volume-Temperature Correlations for Gulf Mexico Crude Oils*. SPE 51395, JPT, p. 416-420, 3 October, 1993. 65, 66, 96
- ³⁸ Chew, J. N., Connally, and C. A. *A Viscosity Correlation for Gas-Saturated Crude Oils*. AIME, P. 23, June, 1959. 65
- ³⁹ Beggs, H.D., Robison, and J.R. *Estimating the Viscosity of Crude Oil Systems*. JPT, September, 1975. 65
- ⁴⁰ Beal and C. *The Viscosity of Air, Water, Natural Gas, Crude Oil and its Associated Gases at Oilfield Temperatures and Pressures*. AIME, 165, p. 94, 1946. 66
- ⁴¹ Gharbia, R. B., Elsharkawy, and A. M. *Neural-Network Model for Estimating the PVT Properties of Middle East Crude Oils*. SPE 37695, March 15-18, 1997. 66, 87
- ⁴² Gharbi and Elsharkawy others. *Universal Neural Network Based Model for Estimating The PVT Properties of Crude Oil Systems*. SPE 38099, April 14-16, 1997. 66, 87

BIBLIOGRAFÍA

- ⁴³ Varotsis N., SPE, et al. *A Novel Non-Iterative Method for the Prediction of the PVT Behavior of Reservoir Fluids*. SPE 56745, 3-6 October, 1999. [67](#), [89](#)
- ⁴⁴ M.A. Al-Marhourn and E.A. Osman. *Using Artificial Neural Networks to Develop New PVT Correlations for Saudi Crude Oils*. SPE 78592, 2002. [67](#), [87](#)
- ⁴⁵ E.A. Osman, SPE, et al. *Artificial Neural Networks Models for Predicting PVT Properties of Oil Field Brines*. SPE 93765, 2005. [67](#)
- ⁴⁶ O. Omole, O.A. Falode, and Deng A. Deng. *Prediction of Nigerian Crude Oil Viscosity using Artificial Neural Network*. Petroleum & Coal, 2009. [67](#), [87](#)
- ⁴⁷ C. T. Ako F.A Makinde et al. *Prediction of Crude Oil Viscosity Using Feed-Forward Backpropagation Neural Network (FFBPNN)*. Petroleum & Coal, June 5, 2012. [68](#)
- ⁴⁸ Ebuka Godwin Afoama, Ogbunude Basil, and Kevin Igwilo. *Generalized Regression Neural Network - A Better Predictive Tool For Estimating PVT Properties of Niger Delta Crude Oils*. Petroleum & Coal, October 6, 2014. [68](#), [87](#)
- ⁴⁹ Salem O. Baarimah et al. *Artificial Intelligence Techniques for Predicting the Reservoir Fluid Properties of Crude Oil Systems*, volume 02. International Research Journal of Engineering and Technology (IRJET). [68](#)
- ⁵⁰ McCain William D. and Jr. *The Properties of Petroleum Fluids*. PennWellBooks, Second edition, 1990. [69](#), [70](#)
- ⁵¹ A. C. Nancy, L. G. Alfredo, and G. H. Francisco. *Clasificación de los yacimientos de México: Un nuevo enfoque*. Asociación de Ingenieros Petroleros de México, Congreso Mexicano del Petróleo, 2012. [69](#), [70](#), [91](#)
- ⁵² H. Jiawey, P. Jian, et al. *Data Mining Concepts and Techniques*. Elsevier, Horgan Kaufmann, third edition, 2012. [70](#)
- ⁵³ T. Martin et al. *Neural Network Design*. eBook, second edition. [71](#)
- ⁵⁴ Hao Yu and M. Bogdan Wilamowski. *Intelligent Systems*, volume Chapter 12, Levenberg-Marquardt. The Industrial Electronics Handbook, CRC Press, second edition. [71](#)
- ⁵⁵ C. García José F. *Técnicas de Optimización Modernas para Problemas Complejos*. Universidad de Málaga, Escuela Técnica Superior de Ingeniería Informática, Mayo de 2003. [71](#)
- ⁵⁶ H. Mark, T. Martin, et al. *Neural Network Toolbox, User's Guide*. MathWorks, R2015b.
- ⁵⁷ M. A. Mahmood and M. A. Al-Mahourn. *Evaluation of Empirically derived PVT Properties for Pakistani Crude Oils*. Elsevier, Journal of Petroleum Science and Engineering, June, 1996. [73](#)

- ⁵⁸ U. K. Austin, S. I. Sunday, et al. *Globalization of Black Oil PVT Correlations*. SPE 172494, August, 2014. [73](#), [77](#)
- ⁵⁹ M.E Dokla and M.E Osman. *Correlation of PVT Properties for UAE Crudes*. SPE 21342, 1990. [77](#)
- ⁶⁰ J. Naseryan Moghadam, K. Salahshoor, and R. Kharrat. *Introducing a New Method for Predicting PVT Properties of Iranian Crude Oils by Applying Artificial Neural Networks*. Petroleum Science and Technology,, 2011. [87](#)
- ⁶¹ Chapman Cronquist et al. *Dimensionless PVT Behavior of Gulf Coast Reservoir Oils*. SPE-AIME. [90](#)
- ⁶² I.A. Khan et al. *Reservoir Fluid Analysis Using PVT Express*. SPE 101219, 2006. [89](#), [100](#)
- ⁶³ R.M Hristev. *The ANN Book*. GNU, first edition, 1998.