



UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO

PROGRAMA DE MAESTRÍA Y DOCTORADO EN INGENIERÍA

FACULTAD DE INGENIERÍA

DIVISIÓN DE ESTUDIOS DE POSGRADO

*“ESTIMACIÓN DE PROPIEDADES PVT PARA YACIMIENTOS
DE ACEITE NEGRO Y VOLÁTIL MEDIANTE UNA RED
NEURONAL ARTIFICIAL”*

TESIS

QUE PARA OPTAR EL GRADO DE MAESTRO EN
INGENIERÍA DE EXPLORACIÓN Y EXPLOTACIÓN DE
RECURSOS NATURALES

PRESENTA:

ANALLELY CAMARGO CASTAÑÓN

TUTOR:

DR. ERICK EMANUEL LUNA ROJERO
PROGRAMA DE MAESTRÍA Y DOCTORADO EN INGENIERÍA

Ciudad Universitaria, Cd. Mx., Agosto 2016



Universidad Nacional
Autónoma de México



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.

JURADO ASIGNADO:

Presidente: (Dr. Berumen Campos Sergio)

Secretario: (M. C. Escobedo Zenil David)

Vocal: (Dr. Luna Rojero Erick Emanuel)

1 er. Suplente: (M. en C. Santillan Piña Noé)

2 d o. Suplente: (M. en I. Sánchez Vela José Juventino)

Ciudad Universitaria, México D.F.

TUTOR DE TESIS:

Dr. Luna Rojero Erick Emanuel

Erick E. Luna R.

Copyright © 2016 por Anallely Camargo Castañon. Todos los derechos reservados.

Agradecimientos

Este trabajo está dedicado a cada persona que creyó en mí, que estuvo conmigo en este esfuerzo conjunto como lo es Dios llenando de paz mi alma, corazón y alineando mi pensamiento constantemente.

A mis Padres que a cada instante me apoyaron y lucharon conmigo para hacer posible este reto, dos seres que han estado conmigo en cada momento sea bueno o malo y que amo con mi corazón.

A mi hermano Gus y mi hermana Susy que aunque somos totalmente distintos siempre apoyaron mis decisiones y fueron constantes hacia mí, gracias por su cariño.

A mi hermano Oscar (+) y mi sobrino Aarón (+) que se me adelantaron en el camino y aun así me iluminaron para continuar.

A mi Esposo que me apoyo, me guió y se involucró para lograr este reto, que me dio aliento en los momentos de desesperación para no caer y seguir luchando, gracias por tu amor y paciencia.

A mi nena hermosa que me motivo estando dentro de mí, dando razones para seguir adelante y luchar con todo para lograr mi objetivo e iluminando mi camino.

A mis sobrinos Oscar, Andy y Sofí que con esas tiernas sonrisas me cambiaron mis días para seguir con la mejor actitud.

A mi Tutor el Dr. Erick Emmanuel Luna Rojero que confío en mí y en el desarrollo de este trabajo que con su apoyo se logró, gracias por la paciencia y por compartir conmigo su conocimiento, por su humildad y enseñanza.

A mis Sinodales:

M. C. David Escobedo Zenil que gracias a su enseñanza y seguimiento este trabajo ha sido posible, gracias por cada revisión y tips, por su paciencia e interés fue y es de gran valor para mí.

M. I. José Juventino Sánchez Vela gracias por el compañerismo y el apoyo brindado, eres un ser humano que aporta mucho académicamente.

M. C. Noé Santillán Piña pues le expreso mi gratitud por que desde el propedéutico fue una persona con un panorama amplio de la enseñanza, siempre orientando y con mucha objetividad, gracias por lograr hacer cambios académicos en mí.

Dr. Sergio Berumen Campos recuerdo sus clases y muchos de los momentos que compartió, como experiencias laborales, información, siempre alentándonos a ser mejores, gracias por compartir y por regar ese conocimiento hacia nosotros.

Para cada una de estas personas mi respeto y admiración por que cada uno puso una semilla confiando en que daría fruto.

A mis profesores.

Simplemente sin cada uno de ustedes no se logra el objetivo, su tolerancia, tiempo, enseñanza, participación, etc. fueron cruciales para alcanzar la meta, ser determinantes y no detenerse en el camino. Que Dios siga iluminando su camino y ampliando su conocimiento ya que gracias a eso logran difundirlo.

Agradezco el apoyo en la parte laboral ya que sin ellos no hubiese culminado este trabajo, a Enrique Paredes Enciso que me compartió conocimiento e información para el desarrollo de este trabajo, a Luis Manuel Perera Pérez, Alfonso Olimpo García y Rafael Pérez Herrera que llevaron mi seguimiento técnico y administrativo.

A cada persona que hizo posible esto, gracias dios por las bendiciones repartidas, por el amor proyectado y por hacer llegar las palabras adecuadas a mi boca.

Contenido

Resumen.....
Introducción
Capítulo I	1
Antecedentes	1
Capítulo II	4
Definición del problema	4
Hipótesis.....	4
Objetivo.....	4
Alcances	4
Capítulo III.....	5
Pruebas y validación PVT para aceite negro y volátil.....	5
3.1 Pruebas PVT para aceite negro	5
3.1.1 Muestreo de fondo y Composición del fluido del yacimiento	5
3.1.2 Muestreo de superficie.....	6
3.1.3 Prueba de expansión a composición constante.....	6
3.1.4 Prueba de liberación diferencial.....	9
3.1.5 Prueba de viscosidad.....	11
3.1.6 Prueba de separadores.....	11
3.1.7 Separación diferencial y separación instantánea.....	12
3.1.8 Limitaciones de las pruebas de laboratorio.....	13
3.2 Pruebas de consistencia de un análisis PVT para aceite negro.....	13
3.2.1 Prueba de condiciones de recombinación.....	13
3.2.2 Prueba de densidad.....	14
3.2.3 Prueba de la Función Y.....	15

3.2.4 Prueba de Balance de Masa	16
3.2.5 Prueba de la desigualdad.....	18
3.3 Pruebas PVT para aceite volátil	18
3.3.1 Composición del fluido del yacimiento.....	19
3.3.1.1 Muestra bifásica.....	19
3.3.1.2 Muestra monofásica.....	20
3.3.2 Pruebas CCE (Expansión a composición constante).....	20
3.3.3 Prueba CVD (Agotamiento a volumen constante).....	21
3.3.4 Prueba de viscosidad.....	21
3.3.5 Prueba de separador.....	22
3.4 Pruebas de consistencia de un análisis PVT para aceite volátil.....	22
3.4.1 Representatividad.....	23
3.4.2 Consistencia de los resultados.....	23
3.4.2.1 Prueba de la Función Y.....	23
3.4.2.2 Recombinación matemática.....	23
3.4.2.3 Balance molar de la prueba CVD (agotamiento a volumen constante) para un aceite volátil.....	24
3.4.2.4 Método de Bashbush.....	27
3.4.2.5 Método de Whitson.....	28
3.4.2.6 Criterio de Hoffman-Crump and Hocott.....	29
Capítulo IV.....	30
Redes Neuronales Artificiales.....	30
4.1 Introducción	30
4.2 Red Neuronal biológica.....	32
4.3 Red Neuronal artificial	34

4.3.1 Funciones de activación.....	36
4.3.2 El Perceptrón multicapa.....	36
4.4 Métodos de aprendizaje.....	41
4.4.1 Algoritmo de propagación hacia atrás (BackPropagation).....	41
4.4.2 Algoritmo de Levenberg – Marquardt.....	43
Capítulo V.....	45
Red Neuronal de los parámetros Bob , Pb , Rs y Co para un aceite negro y volátil.....	45
Generalidades.....	45
5.1 Red Neuronal Artificial para la estimación de Rs de un aceite negro.....	47
5.1.1 Estructura de la red.....	47
5.1.2 Algoritmo de RNA para la estimación de Rs en aceite negro.....	47
5.1.3 Resultados.....	49
5.2 Red Neuronal Artificial para la estimación de Bob de un aceite negro.....	50
5.2.1 Estructura de la red.....	50
5.2.2 Algoritmo de RNA para la estimación de Bob en aceite negro.....	50
5.2.3 Resultados.....	51
5.3 Red Neuronal Artificial para la estimación de Co de un aceite negro.....	52
5.3.1 Estructura de la red.....	52
5.3.2 Algoritmo de RNA para la estimación de Co en aceite negro.....	53
5.3.3 Resultados.....	55
5.4 Red Neuronal Artificial para la estimación de Pb de un aceite negro.....	55
5.4.1 Estructura de la red.....	55
5.4.2 Algoritmo de RNA para la estimación de Pb en aceite negro.....	56
5.3.3 Resultados.....	57
5.5 Red Neuronal Artificial para la estimación de Rs de un aceite volátil.....	58

5.5.1 Estructura de la red	58
5.5.2 Algoritmo de RNA para la estimación de Rs en aceite volátil.....	59
5.5.3 Resultados	60
5.6 Red Neuronal Artificial para la estimación de Bob de un aceite volátil	61
5.6.1 Estructura de la red	61
5.6.2 Algoritmo de RNA para la estimación de Bob en aceite volátil.....	62
5.5.3 Resultados	63
5.7 Red Neuronal Artificial para la estimación de Co de un aceite volátil.....	64
5.7.1 Estructura de la red	64
5.7.2 Algoritmo de RNA para la estimación de Co en aceite volátil.....	65
5.7.3 Resultados	66
5.8 Red Neuronal Artificial para la estimación de Pb de un aceite volátil	67
5.8.1 Estructura de la red	67
5.8.2 Algoritmo de RNA para la estimación de Pb en aceite volátil.	68
5.8.3 Resultados	69
Conclusiones y recomendaciones	71
Bibliografía	73

|

Resumen

Dentro de la industria petrolera un problema frecuente es que no se cuenta con la suficiente información de comportamiento de fase del aceite (PVT) para poder alimentar los modelos y así mismo simular adecuadamente los yacimientos, de tal manera que lo más rápido es utilizar datos de campos análogos, ver que es más parecido a la realidad y usarlos. Esto se hace por que para llevar a cabo un estudio PVT es necesario programarlo una vez que se tenga conocimiento de perforación de pozos para evaluar si es o no factible realizarlo en cuanto a la parte económica.

Para los ingenieros de yacimientos esta información es esencial, solo que no siempre es suficiente una justificación técnica para permitir realizar dicho análisis. Debido a esto, es necesario el desarrollo de nuevas herramientas de trabajo que permitan resolver esta problemática, por lo que la introducción de redes neuronales es altamente factible en este caso, ya que permite predecir parámetros confiables de gran exactitud.

Este trabajo muestra una fusión de disciplinas de gran utilidad para la industria petrolera, aplicables en cualquier área de la ingeniería petrolera ya sea yacimientos, productividad, y perforación, entre otros.

El uso de redes neuronales en conjunto con la validación y consistencia de análisis presión-temperatura (análisis PVT) generan herramientas con gran valor agregado para la determinación de parámetros acordes al tipo de yacimiento y el comportamiento de los fluidos.

La aplicación de Redes Neuronales Artificiales, la Programación Evolutiva y la Lógica Difusa son algunos de los paradigmas que están clasificados como Inteligencia Virtual. La Inteligencia Virtual puede definirse como un conjunto de nuevas herramientas de análisis que intenta imitar la vida. Las técnicas de inteligencia virtual muestran una capacidad de aprender y hacer frente a nuevas situaciones. Estas técnicas poseen uno o más atributos de la "razón", como la generalización, el descubrimiento, la asociación y la abstracción, Ponce (2010).

La tendencia ahora parece ser la integración de estas herramientas en conjunto, con herramientas convencionales tales como el análisis estadístico, que permita la construcción de sofisticados sistemas que puede resolver problemas difíciles.

En la industria del aceite y gas estas herramientas se utilizan para resolver problemas relacionados con el análisis de presión estática, así como la interpretación de registros, caracterización de yacimientos, la selección de pozos candidatos para la estimulación, análisis PVT Express entre otras aplicaciones.

Introducción

El análisis PVT de hidrocarburos constituye una herramienta de gran ayuda para estimar el comportamiento de los fluidos contenidos en el yacimiento.

Para que la muestra de fluido sea representativa, los PVT deben validarse, lo cual consiste en verificar la representatividad del fluido original existente comparando las condiciones del yacimiento con las de laboratorio y evaluar su consistencia mediante las metodologías de prueba de densidad, prueba de la función “Y”, prueba de la desigualdad, entre otras.

Un problema frecuente en la ingeniería de yacimientos radica en que, en ocasiones, no se cuenta con un análisis PVT de un pozo, por lo que deben usarse pruebas de pozos análogos, suponer valores de esa prueba, o en su caso correlaciones que sirven para estimar algunos de esos parámetros.

Las correlaciones PVT, son expresiones matemáticas que se obtienen a partir de múltiples pruebas de laboratorio cuyo objetivo es determinar las propiedades físicas de los fluidos. Sin embargo, muchas de las correlaciones en la literatura usan datos de yacimientos que distan de ser similares al aceite que se quiere modelar.

La introducción y uso de Redes Neuronales Artificiales (RNA) constituye una nueva línea de trabajo para la estimación de parámetros que difiere de métodos convencionales. Esta herramienta simula el proceso cognitivo del cerebro y es de mucha utilidad para resolver aquellos problemas que no pueden ser solucionados cuando no se dispone de mucha información. Las RNA, funcionan como sistemas dinámicos no lineales que aprenden a reconocer patrones a través del entrenamiento, Ponce (2010).

En este trabajo se muestra un conjunto de arquitecturas de redes neuronales artificiales para la estimación de parámetros de presión, volumen y temperatura, entrenándola con información de yacimientos de aceite negro y volátil con la finalidad de obtener el mínimo error.

Capítulo I

Antecedentes

El uso de las Redes Neuronales Artificiales en el área de la Ingeniería Petrolera para la estimación de parámetros utilizados en el modelado estático y dinámico de yacimientos de hidrocarburos es relativamente nuevo, lo cual abre enormes posibilidades en el futuro inmediato para su aplicación de manera generalizada.

En el área de yacimientos la adición de disciplinas como lo son las redes neuronales y el análisis PVT (presión-volumen-temperatura), tiene como finalidad obtener parámetros de los diferentes fluidos (gas y aceite), mediante un modelo con varias entradas y una salida o varias salidas, entrenando la red con datos de yacimientos que producen aceite negro y volátil.

Las pruebas PVT son empleadas con el propósito de analizar los yacimientos, además de esto, estudiar y cuantificar el comportamiento de fase y propiedades del fluido de un yacimiento simulando las condiciones de recuperación con el fin de estudiar las propiedades de los fluidos del yacimiento en el laboratorio.

Existen varias pruebas PVT, cada una de ellas tiene diferentes desarrollos, resultados y análisis, pero hay algo que las caracteriza y que hace en gran parte el éxito de cada una de ellas, esto es la recolección de la muestra representativa. Es por ello que en el análisis PVT debemos considerar sumamente importante los datos que se están registrando de modo que éstos sean bastante representativos y den la seguridad de resultados certeros.

Los análisis PVT son absolutamente necesarios para llevar a cabo el cálculo de reservas, análisis de pruebas de presión-producción, diseño de instalaciones de producción, análisis nodales, diversas actividades de la ingeniería de yacimientos, permiten predecir la vida productiva, definir los esquemas óptimos de producción, evaluar métodos de recuperación mejorada y demás propiedades que predicen el comportamiento de pozos a medida que son explotados.

Otra herramienta de apoyo para el desarrollo de modelos, en la caracterización de yacimientos, son las correlaciones PVT, que en el pasado fueron presentadas en forma tabular y/o gráfica; sin embargo, con la aparición de las calculadoras manuales programables y las computadoras personales, tales correlaciones han sido reducidas a simples ecuaciones numéricas o expresiones analíticas con el propósito de utilizarlas en programas de computación Ponce (2010).

Las diferentes correlaciones han sido desarrolladas tomando como base a un tipo específico de aceite de alguna región del mundo en particular, por lo que al aplicar estas correlaciones en aceites de otra área, con una composición química distinta, se pueden generar errores significativos difíciles de evitar, López y Loreto (2013).

Por ejemplo, Standing, (1947) realizó diferentes correlaciones, entre ellas como calcular la Pb (presión de burbuja), ésta se obtuvo a partir de 105 experimentos utilizando 22 tipos de crudo y gas de California. El error promedio de la correlación fue aplicado a los datos usados para el desarrollo del método y resultó ser del 4.8 %. Los gases involucrados en el desarrollo del método no contenían hidrógeno ni sulfuro de hidrógeno, algunos contenían dióxido de carbono en cantidades insignificantes. La correlación puede aplicarse a otros tipos de petróleo, tomando en cuenta sus características.

Lasater, (1958), presentó una correlación para el cálculo de la Pb, a partir de información de aceites de América del Sur, Canadá y Estados Unidos. Se basó en 158 presiones conocidas de 137 sistemas y esta expresada en términos de los parámetros de campo generalmente conocidos como son: densidad relativa del gas y del aceite, presión y temperatura. Entre los valores medidos y calculados obtuvo un error promedio de 3.8%.

Por otro lado M.E. Vázquez y H.D. Beggs (1976), presentaron una correlación para determinar la relación gas disuelto-aceite y el factor de volumen de aceite saturado, en estas se utilizan diferentes coeficientes, según la densidad relativa del aceite. Los errores promedio porcentuales obtenidos para las correlaciones de relación gas disuelto-aceite, fueron de 0.7 y 4.7 respectivamente.

Posteriormente se desarrollaron algunas otras correlaciones para cálculo de Pb, Rs, Bo, Bt, etc. como la de O. Glaso (1980), la de C.F.P. la Total (1980), entre otros autores, con la finalidad de comparar con los diferentes tipos de aceite o gas.

El presente trabajo muestra diversas redes neuronales artificiales entrenadas con datos PVT de aceite negro y volátil, con la finalidad de obtener parámetros PVT que proporcionan información detallada de campos de la Región Sur de México. Debido a que no siempre se tiene el capital para realizar este tipo de estudios ya que son altamente costosos, la red funciona como herramienta de trabajo para predecir la información de los fluidos con datos reales previamente validados y consistentes extraídos de los análisis PVT.

El usuario podrá introducir los datos en una macro de Excel y obtener resultados confiables, sin necesidad de tener un gasto adicional.

El uso de Redes Neuronales Artificiales (RNA) constituye una nueva línea de trabajo, que excede la capacidad de predicción de los métodos convencionales. La ventaja de esta técnica es que no requiere que todos los parámetros y las relaciones entre ellos sean especificados explícitamente.

Las redes “aprenden” a resolver problemas a través de ejemplos y resultan especialmente adecuadas para procesos subjetivos e interpretativos que los humanos pueden llevar a cabo fácilmente, pero que no pueden describirse en términos de algoritmos o conjunto de ecuaciones, Mohagheh (1995). También tienen en cuenta, por ejemplo, la no linealidad en la distribución, como es el caso de la permeabilidad, ya que son independientes de cualquier forma de función.

Capítulo II

Definición del problema

Debido a que no se cuenta con la suficiente información de análisis PVT para alimentar modelos de balance de materia, estimación de reservas, simulación numérica de yacimientos y análisis nodal entre otros, es necesario usar métodos alternativos para la estimación de estos parámetros. En particular, las Redes Neuronales Artificiales (RNA), son modelos no lineales con la habilidad de aprender gracias a su previo entrenamiento y generalizar dicho aprendizaje a la resolución de nuevos problemas cuando no se dispone de mucha información.

Hipótesis

Mediante una Red Neuronal Artificial (RNA), entrenada con información PVT validada de yacimientos mexicanos de la Región Sur, es posible estimar la Presión de burbuja, Relación solubilidad, compresibilidad del aceite y factor de volumen del aceite a la presión de burbuja, a partir de información básica de pozo de la región.

Objetivo

Definir la arquitectura de una Red Neuronal Artificial (RNA) y entrenarla para predecir parámetros PVT a partir de información básica de pozo.

Alcances

- Recopilar y validar información PVT de pozos de aceite negro y volátil.
- Clasificar el tipo de aceite y elección de parámetros a estimar.
- Construir una base de datos y normalizarla.
- Definir la o las arquitecturas de redes neuronales.
- Generar un algoritmo de entrenamiento de las RNA (redes neuronales artificiales).
- Desarrollar y aplicar macro en Excel para estimar parámetros PVT.

Capítulo III

Pruebas y validación PVT para aceite negro y volátil.

3.1 Pruebas PVT para aceite negro

3.1.1 Muestreo de fondo y Composición del fluido del yacimiento

El método de fondo convencional consiste en bajar un dispositivo de muestreo, por lo general denominado "muestreador de fondo de pozo", a cierta profundidad. Las muestras de fondo de pozo pueden ser tomadas en cualquier pozo entubado o no. Se toma una muestra del fluido del pozo a esa profundidad a través de un muestreador.

El muestreador es llevado a la superficie donde es represurizado y es restaurada la muestra a condiciones de una fase, entonces puede ser transferida a un recipiente de presión adecuado para el transporte al laboratorio.

Los muestreadores de fondo de pozo están disponibles en una variedad de configuraciones (detalles de diseño e instrucciones de uso se pueden obtener a partir de los proveedores de tales equipos). El método de muestreo de fondo se utiliza a menudo cuando la presión de fondo es mayor que la presión de saturación.

Las técnicas usadas en la determinación de la composición de una mezcla de hidrocarburos incluyen cromatografía y destilación. Muestras gaseosas son analizadas únicamente por cromatografía desde el C_1 hasta el C_{11+} . Muchas veces el análisis solo alcanza hasta el C_{6+} o C_{7+} .

La composición de una muestra de fondo o recombinada se puede obtener haciendo una liberación instantánea (flash) en el laboratorio y el gas liberado es analizado separadamente del líquido remanente. En este caso es necesario hacer recombinaciones para obtener la composición de la muestra de yacimiento. *Core Laboratories Inc.*, determina la composición de las muestras de yacimiento por medio de destilación fraccionada a baja temperatura.

La fracción remanente de C_{7+} se caracteriza a través de su gravedad API y de su peso molecular. Otros métodos usados en la determinación de la composición son: destilación simulada por cromatografía y espectrometría de masa.

3.1.2 Muestreo de superficie.

Si bien una muestra tomada en superficie podría resultar menos representativa de la que podría obtenerse del fondo de un pozo; el muestreo de superficie, es el método más utilizado, tanto para tomar muestras de: Gas, gas y condensado, y aceite.

Para tomar una medición adecuada a condiciones de superficie de un pozo produciendo a condiciones estabilizadas, deben registrarse cuidadosamente las condiciones del yacimiento, pozo, y separador durante la medición. Así mismo, los volúmenes de fluidos recuperados deben ser suficientes para el recombinado. En general, para una muestra de fondo basta con tres contenedores de 600 cm³ de fluidos del yacimiento para realizar los experimentos en el laboratorio, en tanto que para una muestra superficial se requieren de 600 cm³ de líquido y 20 litros de gas para el recombinado.

El recombinado de fluidos superficiales, usualmente del separador, se realiza con el objetivo de obtener nuevamente la composición inicial del fluido del yacimiento. Para ello, debe tenerse en cuenta la relación gas-aceite producido y la presión del sistema.

3.1.3 Prueba de expansión a composición constante.

Es una prueba de liberación instantánea donde la muestra original es sometida a un proceso de expansión a composición y temperatura constante (igual a la temperatura de la muestra en el yacimiento). El gas liberado se mantiene en contacto con el aceite. La prueba se realiza en una celda de acero con volumen del orden de medio litro, la cual resiste alta presión (>10000 psi) y temperatura (>350°F).

La muestra representativa del aceite de yacimiento es llevada a la celda PVT la cual se mantiene a una temperatura constante igual a la del yacimiento. La presión de la muestra en la celda se controla introduciendo o retirando mercurio de la celda por medio de un pistón accionado hidráulicamente, como se muestra en la Fig. 3.1.




Figura 3.1 Expansión a composición constante para aceite negro. Fuente: modificada de Tarek Ahmed.2005. "Reservoir Engineering Handbook".

La prueba se inicia aumentando la presión de la muestra a un valor superior a la P_b "presión de burbuja" y del yacimiento. Luego la presión es disminuida por etapas y en cada oportunidad del volumen total "V" del contenido del fluido (gas o líquido) es medido.

Tan pronto se alcanza la P_b es liberado gas del aceite y la compresibilidad total del sistema aumenta considerablemente. A presiones menores a P_b , se necesita extraer mayor volumen de mercurio para alcanzar una determinada caída de presión, como se muestra en la Fig. 3.2 la P_b corresponde al cambio de pendiente de la curva P vs V. A partir de esta prueba se obtienen las siguientes propiedades:

- Presión de burbuja (P_b).
- Volumen relativo en función de presión ($V_r = V/V_b$).
- Compresibilidad del aceite (C_o).




Figura 3.2 Comportamiento del volumen en función de la presión. Noviembre 2014. Modificado de http://historiaybiografias.com/los_gases

Después de obtener en el laboratorio el comportamiento volumétrico de las muestras en función de la presión con las pruebas mencionadas anteriormente, se puede verificar si la presión de burbuja reportada con el equipo de análisis de PVT es correcta o no, mediante un cálculo matemático llamado función “Y” es validado el comportamiento que permite a su vez optimizar el punto de burbuja.

A continuación se presenta la siguiente ecuación para cálculo de la función “Y”;

$$Y = \frac{P_b - P}{P \left(\frac{V_t}{V_b} - 1 \right)}; \text{adimensional.} \quad (1)$$

Donde P_b es la “presión de burbuja”, P es la presión a la cual está siendo calculada la función “Y” (presión de interés), y V_t/V_b es el volumen correspondiente a la presión P respecto al volumen medido a la presión de burbuja. Cuando se grafican los valores de función “Y” vs los valores de presión, se obtendrá una recta similar a la Fig. 3.3.

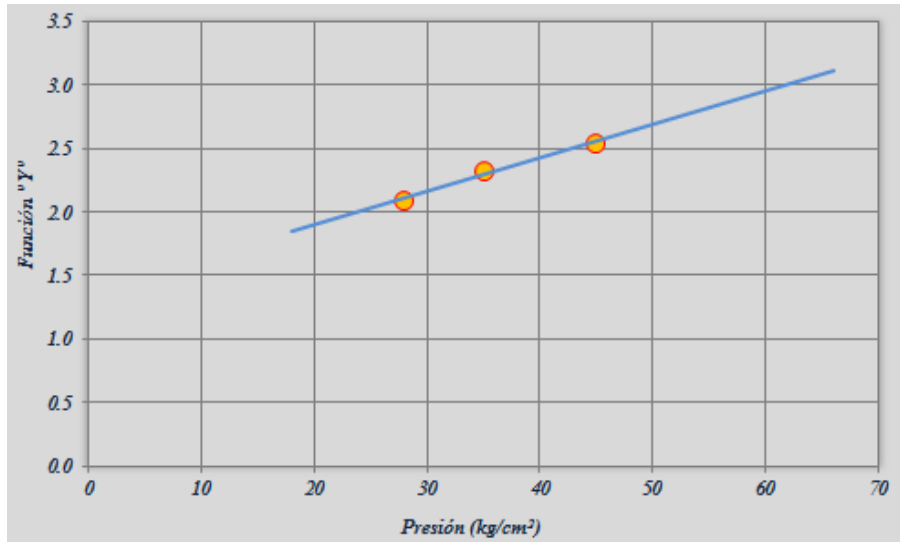


Figura 3.3 Comportamiento del gráfico de la función Y. Recuperado de Paredes 2014. PVTVAL.

Si el gráfico obtenido presenta un comportamiento lineal, la prueba es válida. En caso contrario, se considera que el análisis es inconsistente; si la curva no presenta una desviación severa, ésta se puede modificar para hacerla rectilínea y obtener la presión de burbuja corregida.

3.1.4 Prueba de liberación diferencial

Es un estudio de expansión a composición variable, la cual se realiza en el laboratorio para simular el comportamiento de los fluidos en el yacimiento durante el agotamiento de presión.

En el laboratorio se efectúa un proceso diferencial aproximado a través de una serie de diez pasos normalmente, de separaciones instantáneas a la temperatura del yacimiento.

Se comienza a una presión igual a la de burbuja ya que a una $P > P_b$ la liberación diferencial es igual a la liberación instantánea. Posteriormente se expande la muestra hasta una presión inferior a la P_b . La celda es agitada hasta alcanzar equilibrio entre las fases.

El gas liberado es desplazado de la celda a presión constante Fig. 3.4 y expandido a través de un separador hasta la presión atmosférica. Conocidos los volúmenes del gas a $P=14.7$ psia y $T=60$ °F es calculada Z.

En el separador se puede formar líquido si ocurre condensación retrograda, esto ocurre cuando el gas liberado es rico (gas condensado). La formación de grandes volúmenes de líquido en el separador indica que el aceite es del tipo casi crítico (alta volatilidad). Al gas separado se le debe

medir su gravedad específica y composición. Se debe reportar la reducción (encogimiento) del volumen de líquido debido a la liberación diferencial del gas.

El líquido restante en la celda, el cual es un líquido saturado con menor contenido de gas que el original, es expandido de nuevo a una menor presión. Este procedimiento se repite hasta alcanzar la presión deseada ($\approx 100\text{-}200$ psi) a T_{yac} . Posteriormente a este líquido restante se le realiza una liberación flash a P_{atm} y T_{yac} , luego se deja enfriar hasta una $T=60$ °F para obtener el líquido residual del proceso de liberación diferencial.

De esta prueba se obtienen las siguientes propiedades:

- Relación gas/ aceite en solución, R_s .
- Factor de volumen del aceite, B_o .
- Factor de volumen del gas, B_g .
- Factor de volumen total, B_t .
- Densidad del aceite, ρ_o .
- Gravedad específica del gas, γ_g .
- Gravedad API del aceite residual, $^{\circ}API$.
- Factor de compresibilidad (o Desviación) del gas, Z .




Figura 3.4 Esquema del experimento de liberación diferencial. Fuente: Paris de Ferrer M. 2010. "Fundamentos de Ingeniería de yacimientos".

3.1.5 Prueba de viscosidad.

El estudio de viscosidad se realiza dentro del equipo para análisis PVT, ya algunos equipos contienen un viscosímetro capilar o electromagnético en su interior.

La viscosidad de un fluido de yacimiento varía con el cambio de la temperatura y de presión, en los equipos PVT se puede medir la viscosidad con la variación de la presión a temperatura constante de yacimiento obteniéndose una curva como se muestra en la Fig. 3.5, donde la viscosidad tiene un comportamiento descendente, mientras la presión es menor hasta llegar al punto de burbuja, debido a que el gas se encuentra en solución, pero cuando se empieza a liberar gas la viscosidad comienza a incrementar por el desprendimiento del mismo.




Figura 3.5 Variación de la viscosidad en función de presión. Cuautli. 2005. Modificado de Propiedades de los fluidos petroleros y aplicaciones

3.1.6 Prueba de separadores.

La prueba de separadores, son separaciones (flash) instantáneas, que se realizan con un separador en el laboratorio, con el objeto de cuantificar el efecto de las separaciones sobre las propiedades del aceite (B_{ob} y R_{sb}) cuando se cambian las condiciones de presión y temperatura, la prueba se inicia a la presión de burbuja y a la temperatura de yacimiento, haciendo pasar la muestra a través de un separador repetidas ocasiones hasta llegar a la presión atmosférica.

Por medio de esta prueba se puede saber cuál es la presión óptima de separación que produce la mayor cantidad de líquido y la menor cantidad de gas en el tanque, Fig. 3.6.

De esta prueba se obtienen los siguientes parámetros:

- Factor de volumen del aceite a P_b , B_{ob} .
- Gravedad API del aceite de tanque.
- Relación Gas-Aceite en solución a P_b , R_{sb} .
- Composición del gas separado.

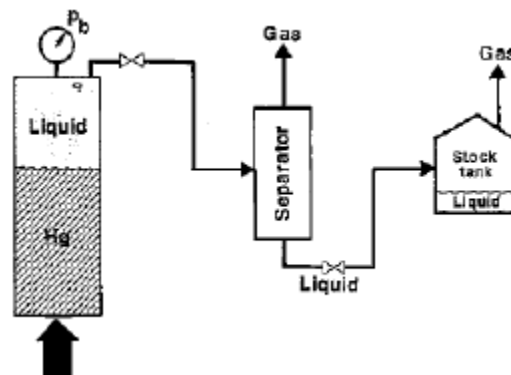


Figura 3.6 Prueba de separadores. Fuente: McCain, 1973 “The Properties of Petroleum Fluids”.

3.1.7 Separación diferencial y separación instantánea.

Los volúmenes de gas liberado durante los procesos de separación instantánea y diferencial son muy diferentes en el caso de aceites ligeros y volátiles, con alto contenido de hidrocarburos intermedios: C_{4+} y C_{5+} . Más gas se escapa en la separación (flash) instantánea que en la diferencial, se debe a que las moléculas intermedias escapan más fácil cuando existe una zona (capa) de gas en contacto con el aceite (proceso flash) que cuando no existe esta zona (proceso diferencial).

Por esta razón el gas restante en la solución a una presión dada es menor en la liberación instantánea que en la diferencial y en general se cumple:

$$*R_{S\ DIF} > R_{S\ FLASH}$$

$$*B_{O\ DIF} > B_{O\ FLASH}$$

3.1.8 Limitaciones de las pruebas de laboratorio.

La muestra de fluido tomada no representa adecuadamente la composición original de los fluidos del yacimiento. Esto ocurre cuando la muestra se toma a presiones de yacimientos menores que las de burbujeo, o el pozo produce agua y/o gas.

Los procesos de liberación del laboratorio no simulan exactamente el proceso combinado diferencial-instantáneo que ocurre en el yacimiento. La extrapolación de resultados de laboratorio al campo debe hacerse con mucho cuidado debido a que pequeños errores en la pruebas producen graves errores en los cálculos de balance de masa, comprobación y predicción de yacimientos.

En el muestreo de separador, pequeños errores del (5%) en los gastos de aceite y gas producen errores en la presión de burbujeo del orden de 150 psi.

3.2 Pruebas de consistencia de un análisis PVT para aceite negro.

Los datos reportados en un análisis PVT están sujetos a errores de medida en el laboratorio, y por esto es necesario verificar su consistencia antes de usarlos en estudios de yacimientos. La verificación de la consistencia se hace a través de las siguientes pruebas:

- Verificar la temperatura de la prueba.
- Verificar las condiciones de recombinación.
- Prueba de densidad.
- Prueba de linealidad de la función Y.
- Prueba de balance de masa.
- Prueba de la desigualdad.

3.2.1 Prueba de condiciones de recombinación

Para las muestras tomadas en el separador, se debe cumplir que las condiciones de presión y temperatura de recombinación en el laboratorio sean iguales a las del separador de alta presión. De igual manera se deben verificar las condiciones de presión y temperatura del separador al momento de la toma de la muestra de gas que estas sean iguales a las del momento de la toma de la muestra de líquido.

3.2.2 Prueba de densidad.

Esta prueba simple consiste en comparar que la densidad del aceite saturado con gas a la presión de burbuja durante la prueba de liberación diferencial debe ser muy parecida a la calculada a partir de los datos obtenidos a las condiciones de separación. Esta prueba se considera consistente cuando la diferencia de ambos valores obtenidos no exceda de un 5%.

$$\rho_{oPb} = \frac{\text{Masa de aceite de tan.} + \text{Masa de gas del sep.} + \text{Masa de gas de tan.}}{\text{Unidad de volumen de aceite a } P_b \text{ y } T} \quad (2)$$

$$\rho_{ob} = \frac{\gamma_o \cdot \rho_w}{B_{oPb}} + \frac{0.0763277}{B_{oPb}} ((\gamma_g R_s)_{sep} + (\gamma_g R_s)_{tan}); \left(\frac{gr}{cc}\right) \quad (3)$$

Donde;

ρ_{ob} = Densidad del aceite saturado a P_b .

γ_o = Gravedad específica del aceite de tanque (agua = 1).

γ_g = Gravedad específica del gas separado (aire = 1).

ρ_w = Densidad del agua, $\left(\frac{gr}{cc}\right)$.

R_s = Relación de solubilidad, $\left(\frac{m^3}{m^3}\right)$.

B_{oPb} = Factor de volumen del aceite en la prueba del separador a P_b , $\left(\frac{m^3}{m^3}\right)$.

Si se tienen varias pruebas de separador se usa el valor de $(\gamma_g R_s)_{sep}$ correspondiente a la presión óptima.

3.2.3 Prueba de la Función Y.

La presión de burbuja es el resultado más importante de la prueba Expansión a Composición Constante (CCE) y su medición es más precisa en tanto que mayor sea el contraste entre las compresibilidades del fluido bajo saturado y saturado.

En la medida que el crudo es más pesado y tiene menor volumen de gas disuelto, el cambio de compresibilidad que experimenta al pasar de estado bajo saturado a saturado es mucho más sutil y por consiguiente se complica identificar en el laboratorio.

Las pruebas de liberación instantánea (flash), se validan por medios estadísticos con ayuda de la Función "Y". La ecuación de esta línea recta es una función denominada "Función Y", la cual es ampliamente usada para validar estas pruebas. Esta dada por la siguiente expresión dada por algunos autores;

$$Y = \frac{(P_b - P)}{P \left(\frac{V}{V_b} \right) - 1} \quad (4)$$

Donde;

P_b = Presión de burbuja, psia.

P = Presión de interés, psia.

V/V_b = Volumen correspondiente a presión de interés, respecto al volumen medido a la P_b .

Esta validación se realiza graficando la función "Y" con respecto a la presión en cada etapa de separación del experimento de liberación instantánea y determinando la mejor recta con mínimos cuadrados.

Si el gráfico obtenido presenta un comportamiento lineal, la prueba es válida. En caso contrario, se considera que el análisis es inconsistente; si la curva no presenta una desviación severa, ésta se puede modificar para hacerla rectilínea y obtener la presión de burbuja corregida.

3.2.4 Prueba de Balance de Masa.

Esta prueba consiste en verificar si la R_s experimental de la prueba de liberación diferencial es igual a la R_s calculada por balance de masa. La diferencia entre los dos valores no debe exceder el 5%.

Los cálculos consisten en un balance de masas realizado entre etapas de presión sucesivas, repitiendo la misma secuencia seguida en el laboratorio. La relación gas-aceite, los factores volumétricos del aceite y gas, la gravedad API del aceite residual y la gravedad específica del gas liberado en cada etapa de liberación es la información necesaria para validar la prueba.

El nuevo cálculo de la prueba de liberación diferencial se inicia desde la presión más baja de la última etapa de expansión, es decir, desde presión y temperatura atmosféricas y finaliza a la presión de burbuja y temperatura del yacimiento.

Tomando como base 1 litro de aceite residual a condiciones normales (60°F y 14.7 psia) se tiene:

$$m_{o1} = (\gamma_o \rho_w) \frac{g}{cm^3} * 1000 cm^3 \quad (5)$$

La gravedad específica del aceite (γ_o) es calculada a partir de la gravedad API como se muestra en la siguiente ecuación dada por algunos autores:

$$\gamma_o = \frac{141.5}{131.5 + API} \quad (6)$$

A condiciones atmosféricas, la masa de gas disuelta en el aceite es cero, luego que se cumple:

$$m_{g1} = 0$$

$$V_{g1} = 0$$

$$R_{s1} = 0$$

Al pasar a temperatura del yacimiento en la primera etapa de separación, cierto volumen de gas entra en solución en el aceite. La masa en gramos de la fase líquida a esta nueva presión es:

$$m_{oi} = (\beta_{odi} \rho_{odi}) \frac{g}{cm^3} * 1000 cm^3 \quad (7)$$

La masa de gas a estas condiciones es igual a la diferencia entre la masa de aceite a la presión correspondiente a la etapa "i" menos la masa de aceite a la presión correspondiente a la etapa "i - 1". La masa de gas en gramos se calcula mediante la siguiente expresión:

$$m_{gi} = m_{oi} - m_{oi-1} \quad (8)$$

La masa de gas se usa para estimar el volumen de gas y posteriormente la relación gas-aceite. Conocida la masa de gas, se divide por su densidad para encontrar el volumen que esa masa de gas ocupa:

$$V_g = \frac{m_{gi}}{\rho_{gi}} = \frac{m_{gi}}{\gamma_{gi} * \rho_{aire}} \quad (9)$$

La densidad del aire se puede estimar como el cociente entre el volumen que ocupa una libra-mol de aire a condiciones normales dividido por el peso molecular del aire:

$$\rho_{aire} = \frac{28.96 \text{ lb/mol}}{379.4 \text{ lb/mol}} \quad (10)$$

El volumen de gas en solución a esas condiciones viene dado por:

$$V_{gi} = \frac{379.4}{28.96 * 454.7} \frac{m_{gi}}{\gamma_{gdi}} = 0.02881 \frac{m_{gi}}{\gamma_{gdi}} \quad (11)$$

La relación gas aceite es entonces:

$$R_{si} = R_{si-1} + V_{gi} \quad (12)$$

Donde;

d= diferencial.

i = nivel de presión.

Este procedimiento se repite para todas las etapas de separación del experimento liberación diferencial. La diferencia entre los valores calculados y los experimentales no debe exceder nunca de 5%. En caso de que la diferencia exceda el 5% la prueba debe ser descartada.

3.2.5 Prueba de la desigualdad.

Una restricción importante que deben cumplir los datos PVT para que sean consistentes es:

$$\frac{dB_o}{dP} < B_g \frac{dR_s}{dP} \quad (13)$$

En esta prueba se debe cumplir que la derivada del factor volumétrico del aceite (B_o) con respecto a la presión debe ser menor al producto del factor de volumen del gas (B_g) y la derivada del R_s con respecto a la presión.

3.3 Pruebas PVT para aceite volátil

El aceite volátil tiene dos características que los diferencian claramente de los otros tipos de aceite como se muestra a continuación:

- Alta volatilidad y cercanía al punto crítico de la mezcla original. Al caer ligeramente la presión (50 psi) por debajo de la presión de burbuja, ocurre una vaporización del líquido (del orden de 40%). Esto genera cambios importantes en la composición de las fases gaseosa y líquida que deben ser tomados en cuenta en los cálculos de reservas de gas y líquido de estos yacimientos.
- El gas asociado (libre y en solución) en los aceites volátiles son del tipo gas rico y condensado. Estos gases desprenden en la superficie grandes cantidades de líquido que deben ser tenidas en cuenta en los cálculos de balance de masa. En el caso de aceite negro, el gas asociado es pobre y no desprende líquido en superficie (sistema de separación).

Para el caso de aceites volátiles se usan celdas visuales similares a las utilizadas en las pruebas PVT de gas condensado. El punto de burbuja se observa visualmente en el momento en que empiezan a desprenderse burbujas de gas de la fase líquida.

Las pruebas de laboratorio incluyen:

- Composición del fluido del yacimiento.
- Prueba CCE.
- Prueba CVD.
- Prueba de viscosidad.
- Prueba de separadores.

3.3.1 Composición del fluido del yacimiento

3.3.1.1 Muestra bifásica

Se llevan al laboratorio las muestras de gas y líquido tomadas en el separador de alta. A la muestra de gas se le determina la composición por cromatografía y a la de líquido se le hace una separación instantánea obteniéndose muestras de gas y líquido a presión atmosférica a estas mezclas se les determina su composición (cromatografía, destilación simulada o espectrometría de masas) luego se hace una recombinación matemática obteniéndose la composición de la muestra líquida del separador.

Esta prueba se recombina matemáticamente por medio de un balance molar de las muestras de gas y líquido tomadas en el separador a una presión P y temperatura T .

Como se observa en la Fig. 3.7, las composiciones del gas y líquido del separador se recombinan matemáticamente para obtener finalmente la composición del fluido del yacimiento.




Figura 3.7 Diagrama para determinar la composición del fluido del yacimiento a partir de una muestra bifásica (Separador). Mijares y Andryus 2013. Modificado de desarrollo de una herramienta computacional para evaluar varias metodologías de balance de materiales en yacimientos de gas con condensación retrógrada.

Donde;

Y'_i, X'_i = Composición del gas y líquido obtenidos de la separación instantánea @ P y T atmosférica de la muestra de líquido del separador.

RM = Recombinación Matemática.

3.3.1.2 Muestra monofásica

A la muestra monofásica tomada en el fondo o en el cabezal del pozo se le hace una separación instantánea a presión atmosférica y luego se le determina las composiciones del gas (Y_i) y líquido (X_i), conocidas las composiciones se hace una recombinación matemática a partir de la relación gas-líquido medida en la separación instantánea, como se ilustra en la Fig. 3.8.




Figura 3.8 Diagrama de trabajo para determinar la composición del fluido del yacimiento a partir de una muestra monofásica (Fondo o cabezal). Mijares y Andryus 2013. Modificado de desarrollo de una herramienta computacional para evaluar varias metodologías de balance de materiales en yacimientos de gas con condensación retrógrada.

3.3.2 Pruebas CCE (Expansión a composición constante).

Como se explicó en el tema de aceite negro (3.1.3), en esta prueba se somete la muestra de fluido a un proceso de expansión a composición y temperatura constante (sin retirar fluido de la celda, a masa constante). Se determina la presión de burbuja (P_b) del aceite volátil, volumen relativo en

función de la presión y la compresibilidad isotérmica del aceite a presiones superiores a la de burbuja ($P > P_b$).

3.3.3 Prueba CVD (Agotamiento a volumen constante).

Es una prueba de agotamiento a volumen constante donde se agota la presión retirando gas de la celda y manteniendo el volumen constante.

En este caso la composición de la muestra varía continuamente durante la prueba, como se observa en la Fig. 3.9. A continuación se expande la muestra hasta una presión P_2 ($P_2 < P_b$), se espera a que ocurra equilibrio entre las fases (P_2) permanece constante y se retira gas de la celda manteniendo la presión (P_2) constante hasta alcanzar el volumen original.

Este procedimiento se repite por etapas hasta alcanzar bajas presiones. Cada etapa de presión se determinan los volúmenes de gas y líquido, la masa de fluido retirado de la celda y propiedades de las fases gas y líquido.




Figura 3.9 Representación del experimento de Agotamiento a volumen constante (CVD). Fuente. Barragán A. 2001. “Seminario de modelamiento composicional de fluidos” <http://es.slideshare.net>

3.3.4 Prueba de viscosidad.

La viscosidad de la fase líquida es determinada a temperatura del yacimiento y diferentes presiones de saturación. A presiones por debajo de la presión de burbuja se separa del líquido el gas liberado y se le mide la viscosidad al líquido (aceite saturado) a P y T utilizando un viscosímetro de bola

rodante, electromagnético, rotacional o capilar. Los dos primeros son los más usados en los estudios PVT.

3.3.5 Prueba de separador.

Esta prueba esta mencionada con anterioridad en el punto 3.1.5. El anterior estudio de separadores se puede hacer teóricamente por medio de un cálculo de fases numéricas utilizando las K_i obtenidas de la prueba CVD.

La prueba de separadores permite optimizar las presiones de las etapas para recuperar la mayor cantidad de líquido en el tanque (termodinámicamente significa estabilizar en fase líquida la mayor cantidad de moléculas de hidrocarburo de la mezcla bifásica) y obtener el factor de volumen del aceite y relación gas-aceite en solución para corregir los resultados de la prueba de liberación diferencial por efecto de la separación *flash* en superficie.

3.4 Pruebas de consistencia de un análisis PVT para aceite volátil.

La validación de una prueba PVT incluye dos análisis: representatividad y consistencia de los resultados. La tabla 3.1 ilustra un resumen de las pruebas que se deben realizar a los resultados de una prueba PVT de aceite volátil.

Representatividad	Consistencia
$T_{yac} = T_{lab}$	<i>Recombinación matemática.</i>
$RGL_i = RGL_{lab}$.	<i>Linealidad de la función Y.</i>
<i>La prueba CCE debe mostrar punto de burbuja, si muestra punto de rocío el yacimiento es de gas condensado o la muestra estaba contaminada con gas.</i>	<i>Balance molar de la prueba CVD.</i>
<i>Pozo estabilizado.</i>	<i>Criterio de Hoffman (Separador y prueba CVD).</i>
<i>Psep y Tsep constantes durante la toma de muestras.</i>	
$P_{yac} \geq P_b$.	

Tabla 3.1 Resumen de las pruebas que se deben realizar a los resultados de una prueba PVT de aceite volátil.

3.4.1 Representatividad

Es necesario comprobar que:

- a) La temperatura a la que fue realizada la prueba en el laboratorio debe ser igual a la del yacimiento, o a la de la zona (profundidad) donde se tomó la muestra, para conocer la variación de composición y propiedades del aceite.
- b) La relación gas-aceite de la muestra recombinada (m^3/m^3), debe ser similar a la inicial de las primeras pruebas de producción del yacimiento o de la zona donde se tomó la muestra.
- c) La prueba CCE debe mostrar punto de burbuja, si muestra punto de rocío, el yacimiento es de gas condensado o la muestra estaba contaminada con gas y no es representativa. Puede ocurrir que el yacimiento presente variación de composición con profundidad y la zona donde se tomó la muestra corresponda a gas condensado.
- d) El pozo debió estar produciendo en forma estabilizada durante la toma de la muestra. Si el pozo no logra estabilizar su producción no se recomienda tomarle muestras para estudios PVT.
- e) En el caso de muestras de separador, su presión y temperatura debieron permanecer constantes durante la toma de muestras.

3.4.2 Consistencia de los resultados.

El objetivo es determinar que la prueba PVT no tiene errores de medición que la invaliden.

3.4.2.1 Prueba de la Función Y.

En este caso se procede de forma similar al procedimiento explicado en sección (3.2.3) de aceite negro.

3.4.2.2 Recombinación matemática.

Esta prueba consiste en recombinar las corrientes de gas y líquido para obtener la composición de la mezcla. La recombinación radica en hacer un balance molar a la presión y temperatura del separador donde se realiza la separación instantánea (*flash*) que pueden ser las condiciones atmosféricas o del separador de alta.

La ecuación usada para determinar la composición de la mezcla se puede escribir para aceite volátil en la siguiente forma:

$$Z_i = \frac{\frac{Y_i RGL}{379.4} + \frac{X_i \rho_L}{Ml}}{\frac{RGL}{379.4} + \frac{\rho_L}{Ml}} \quad (15)$$

Donde;

RGL = Relación gas-líquido (PCN/BN)_{sep}, metros cúbicos por barriles de líquido @ P y T de la separación instantánea (condiciones atmosféricas o de alta P y T).

ρ_L = Densidad del líquido a las condiciones de separación (lbm/Bls)_{sep}.

Ml = Peso molecular del líquido separado, lbm/lbmol.

Regularmente se conoce ρ_L y Ml entre los resultados de las pruebas PVT. Los Zi calculados con la ec. 15 ($Z_{i calc}$) se comparan con los del PVT ($Z_{i exp}$). Se recomienda que los porcentajes de diferencia para los componentes bandera sean: % Dif. $C_1 \leq 2\%$ y % Dif. $C_{7+} \leq 5\%$.

3.4.2.3 Balance molar de la prueba CVD (agotamiento a volumen constante) para un aceite volátil.

El procedimiento es muy similar al del condensado retrógrado con la única diferencia en la ecuación del cálculo de N_t , ya que la prueba se inicia con la celda llena de aceite volátil a Pb. Ecuación usada:

$$N_t = \frac{V_s \rho_l}{Ml} \quad (16)$$

Donde;

N_t = masa de crudo volátil inicial en la celda, lbmol.

V_s = volumen de muestra, pie^3 .

ρ_l = densidad del aceite volátil a Pb, lbm/pie^3 . (Se puede tomar un volumen base de 1 pie^3 para facilitar los cálculos).

Ml = peso molecular del aceite volátil a Pb, lbm/lbmol.

Los valores de ρl y Ml se leen directamente del informe PVT.

Posteriormente se calcula la composición del líquido (X_i) y la constante de equilibrio ($K_i = Y_i/X_i$) a cada nivel de presión se debe verificar que se cumpla:

$$X_i > 0$$

$$\sum Y_i = 1 \text{ y } \sum X_i = 1$$

Los $\text{Log}(Y_i)$ y $\text{Log}(X_i)$ vs P son curvas con variaciones suaves (sin cambios bruscos o presencia de jorobas) como ilustra en la Fig. 3.10 y 3.11. Las K_i deben mostrar disminución con el aumento del peso molecular del hidrocarburo a una presión dada. Esto debido a que la constante de equilibrio es una medida de la volatilidad de una sustancia.

$M_i \uparrow K_i \downarrow @ P$ constante.

En la Fig. 3.12 para cada componente, las curvas no se deben cruzar (muestran cierto grado de paralelismo) ni mostrar cambios bruscos, consideran que esta verificación es la más importante y sensible en la validación de los resultados de una prueba CVD.




Figura 3.10 Variación de presión de la composición del gas prueba CVD. Recuperado de Alfredo León, Fernando Samaniego y José Luis Bashbush. Marzo 2015 VI. Validación Composicional de los Análisis PVT de los Yacimientos de Aceite Negro.




Figura. 3.11 Variación con presión de la composición del líquido retirado de la prueba CVD. Recuperado de Alfredo León, Fernando Samaniego y José Luis Bashbush. Marzo 2015 VI. Validación Composicional de los Análisis PVT de los Yacimientos de Aceite Negro.




Figura 3.12 Variación de las constantes de equilibrio con presión. Recuperado de Alfredo León, Fernando Samaniego y José Luis Bashbush. Marzo 2015 VI. Validación Composicional de los Análisis PVT de los Yacimientos de Aceite Negro.

3.4.2.4 Método de Bashbush

Bashbush (1981) propuso un método para validar los datos PVT de muestras de fluidos de aceite volátil y gas y condensado.

El método consiste en calcular el número de moles que existen en un volumen unitario, tomando como base la presión de rocío o la presión de burbuja.

Una vez que se conocen las moles de gas en la celda, de gas extraído y de líquido en la celda, es posible calcular la composición del líquido en cada etapa del experimento y los valores K (Constantes de equilibrio) a diferentes presiones, basándose en la información que se obtienen del experimento CVD.

La relación de equilibrio o constante de equilibrio se define como la relación que guarda la fracción mol de la fase gas de un componente, con su fracción mol de la fase líquida.

Al graficar el logaritmo de los valores K de cada uno de los componentes contra la presión a la que fue evaluada en cada una de las etapas de agotamiento, las líneas deben presentar una tendencia suavizada (sin inflexiones o jorobas bruscas en las curvas de los componentes) y sin que se crucen entre ellas, como se muestra en la Fig. 3.13.

La información utilizada para el método es la siguiente:

- Composición inicial del fluido.
- Composición del fluido producido para cada etapa de presión
- Factor de desviación “ Z ” del gas
- Cantidad de gas desplazado (% Mol) en cada etapa
- Volumen en la fase líquida en la celda PVT

Al aplicar esta metodología se detectan aquellas medidas que son erróneas. Además si los errores no son muy severos, permite la corrección de datos experimentales hasta obtener un conjunto consistente de valores K . Este conjunto puede usarse directamente en un simulador composicional, o como preámbulo indispensable al ajuste de los parámetros de una ecuación de estado (EDE).




Figura 3.13 Ejemplo de validación con el método Bashbush. Recuperado de Alfredo León, Fernando Samaniego y José Luis Bashbush. Marzo 2015 VI. Validación Composicional de los Análisis PVT de los Yacimientos de Aceite Negro.

3.4.2.5 Método de Whitson

El método de Whitson (1981), está basado en efectuar un balance de masa utilizando información derivada del experimento de AVC (agotamiento a volumen constante). Se define el volumen de hidrocarburos que ocuparía un mol a la presión de burbuja o de rocío; para gas y condensado se utiliza la ley general de los gases y para aceite volátil se requiere conocer el peso molecular y la densidad del aceite a la presión de burbuja.

Aplicando este método se pueden calcular los siguientes parámetros:

- a).- Composición del líquido en cada etapa del experimento de agotamiento a volumen constante.
- b).- Constantes de equilibrio.
- c).- Densidad del líquido y del vapor.
- d).- Peso molecular de la fracción $C7^+$ para la fase líquida.
- e).- Peso molecular promedio para el sistema de 2 fases.

Whitson (1981), recomienda verificar la consistencia de las constantes de equilibrio (composición del líquido) es utilizando el método de Hoffmann-Crump el cual consiste en construir una gráfica de $\log K_p$ (constante de equilibrio) contra el (factor de caracterización) F . Adicionalmente se debe calcular la densidad del gas para verificar la consistencia del factor de desviación Z .

3.4.2.6 Criterio de Hoffman-Crump and Hocott

El método de Hoffmann-Crump (1953), consiste en determinar un Factor de caracterización "B", que está en función de las Temperaturas Críticas de los componentes C_1 a C_6 . Este factor al ser graficado por el producto de las constantes de equilibrio (K) con la presión en cada etapa de separación.

Es decir, a una presión dada, los puntos ($\log (K_i * P)$, FB) correspondientes a varios componentes ($C_1 - C_6$) deben alinearse a través de una recta. Así, al aplicar este criterio a la prueba CVD (constant volumen depletion) se debe obtener un número de rectas igual al número de presiones de los agotamientos.

El método de HC se generó para aplicarse en yacimientos de gas y condensado. Con el tiempo se han hecho adecuaciones para su aplicación en yacimientos de aceite volátil.

Capítulo IV.

Redes Neuronales Artificiales

4.1 Introducción

Las redes neuronales artificiales (RNA), son muy utilizadas en diversos ámbitos de la ciencia e ingeniería porque permiten resolver problemas complejos, que muchas veces no son fáciles de resolver utilizando técnicas tradicionales como la regresión lineal o polinómica.

Las redes neuronales permiten obtener un modelo no explícito que relaciona un conjunto de variables entrada con un conjunto de variables salida. Para realizar estimaciones con el modelo es necesario disponer de un conjunto de observaciones de las variables. Estas observaciones son usadas como patrones de entrenamiento para que la red aprenda y sea capaz de predecir una salida del modelo, ante nuevas observaciones. Por tanto, las capacidades de la red van a depender en gran medida de esta fase de entrenamiento.

En la fase de entrenamiento es necesario controlar muchos parámetros y distintos algoritmos de optimización, por lo que el usuario de una red neuronal debe tener conocimiento suficiente de cuáles son estos parámetros y cómo funcionan. Por otro lado, una vez entrenada la red, es muy importante también evaluar la robustez del modelo creado, comprobando que es adecuado para nuevos datos.

Las redes neuronales artificiales son aproximaciones matemáticas no lineales a la forma en que funciona el cerebro; por lo tanto no deben compararse directamente ni confundir los principios que fundamentan el funcionamiento de las redes neuronales artificiales y el cerebro, ni pensar que las redes neuronales se basan únicamente en las redes biológicas ya que sólo emulan en una parte muy simple el funcionamiento del cerebro humano.

Además se debe considerar que las redes biológicas son generadoras de procesos neurobiológicos en que se establecen relaciones de complejidad muy alta, las cuales no se puede lograr con redes monocapas ni con redes multicapas.

Algunas áreas donde se aplican RNA son:

- Automóviles: Sistemas de piloto automático, detección de fallas por reconocimiento externo de vibraciones.
- Bancos: Lectura de cheques y otros documentos, evaluación de aplicaciones de créditos.
- Electrónica: Predicción de secuencia de códigos, control de procesos, análisis de fallas, visión artificial, reconocimiento de voz.
- Finanzas: Tasa real de los bienes, asesoría de préstamos, previsión en la evolución de precios.
- Seguimiento de hipotecas. Análisis de uso de línea de crédito, evaluación del riesgo en créditos, identificación de falsificaciones, interpretación y reconocimiento de firmas.
- Manufactura: Control de la producción y del proceso, análisis y diseño de productos, diagnóstico de fallas en el proceso y maquinarias, identificación de partículas en tiempo real, inspección de calidad mediante sistemas visuales, análisis de mantenimiento de máquinas.
- Medicina: Análisis de células portadoras de cáncer mamario, análisis de electroencefalograma y de electrocardiograma, reconocimiento de infartos mediante ECG, diseño de prótesis, optimización en tiempos de trasplante y reducción de gastos hospitalarios.
- Robótica: Control dinámico de trayectoria, robots elevadores, controladores y sistemas ópticos.
- Seguridad: Códigos de seguridad adaptivos, criptografía y reconocimiento de huellas digitales.
- Telecomunicaciones: Compresión de datos e imágenes, automatización de servicios de información y traslación en tiempo real de lenguaje hablado.
- Transporte: Diagnóstico de frenos en camiones, sistemas de ruteo y seguimiento de flotas.
- Voz: Reconocimiento de voz. Clasificación de vocales y transformación de texto escrito a voz.
- Ingeniería petrolera: PVT express, estimación de presiones estáticas de yacimiento y Registro geofísico sintético.

A continuación se presenta un panorama general de los fundamentos biológicos de las redes neuronales naturales, sin profundizar mucho en este campo de la neurociencia, ya que el entendimiento de un tema tan extenso como éste requiere de mucha literatura especializada para su estudio. Aquí sólo se desarrolla una idea básica que sirve como planteamiento para el estudio de las redes neuronales artificiales.

4.2 Red Neuronal biológica

En el cuerpo humano encontramos 3 elementos fundamentales: los órganos receptores que recogen información del exterior; el sistema nervioso que transmite la información, la analiza y en parte almacena, y envía la información elaborada y, los órganos efectores (órganos que ejecutan las respuestas del sistema nervioso) que reciben la información de parte del sistema nervioso y la convierte en una cierta acción.

La unidad fundamental del sistema nervioso es la neurona. Una neurona biológica es una célula especializada en procesar información. Está compuesta por el cuerpo de la célula (soma) y dos tipos de ramificaciones: el axón y las dendritas. La neurona recibe las señales (impulsos) de otras neuronas a través de sus dendritas y transmite señales generadas por el cuerpo de la célula a través del axón.

La Fig. 4.1 muestra los elementos de una red neuronal natural. En general, una neurona consta de un cuerpo celular más o menos esférico, de 5 a 10 micras de diámetro, del que salen una rama principal, el axón y varias ramas más cortas que corresponden a las dendritas. Una de las características de las neuronas es su capacidad de comunicarse.

En forma concreta, las dendritas y el cuerpo celular reciben señales de entrada; el cuerpo celular las combina e integra y emite señales de salida. El axón transmite dichas señales a las terminales axónicas, los cuales distribuyen la información. Se calcula que en el cerebro humano existen aproximadamente 10¹⁵ conexiones.

Las señales que se utilizan son de dos tipos: eléctricas y químicas. La señal generada por la neurona y transportada a lo largo del axón es un impulso eléctrico, mientras que la señal que se transmite entre los terminales axónicas de una neurona y las dendritas de la otra es de origen químico.

Para establecer una similitud directa entre la actividad sináptica y la analogía con las redes neurales artificiales podemos considerar que las señales que llegan a la sinapsis son las entradas a la neurona; éstas son ponderadas (atenuadas o simplificadas) a través de un parámetro denominado peso, asociado a la sinapsis correspondiente.

Estas señales de entrada pueden excitar a la neurona (sinapsis con peso positivo) o inhibirla (peso negativo). El efecto es la suma de las entradas ponderadas. Si la suma es igual o mayor que el umbral de la neurona, entonces la neurona se activa (da salida). Esta es una situación de todo o nada; cada neurona se activa o no se activa. La facilidad de transmisión de señales se altera mediante la actividad del sistema nervioso.

Las sinapsis son susceptibles a la fatiga, deficiencia de oxígeno y la presencia de anestésicos, entre otros. Esta habilidad de ajustar señales es un mecanismo de aprendizaje.




Figura 4.1 Elementos de una red neuronal biológica. Recuperado de Ponce. (2010). Inteligencia artificial con aplicaciones a la ingeniería.

4.3 Red Neuronal artificial

Las redes neuronales artificiales son modelos matemáticos que tratan de emular las características y propiedades de las redes neuronales biológicas. En general, consisten en una serie de unidades denominadas neuronas, conectadas entre sí, Ponce (2010). Cada neurona recibe un valor de entrada, el cual transforma según una función específica denominada función de activación.

Dicha señal transformada pasa a ser la salida de la neurona. Las neuronas se conectan entre sí según una determinada arquitectura. Cada conexión tiene un determinado peso que pondera cada entrada a la neurona. De esta manera la entrada de cada neurona es la suma de las salidas de las neuronas conectadas a ella, multiplicadas por el peso de la respectiva conexión. La Fig. 4.2 muestra dicho concepto:

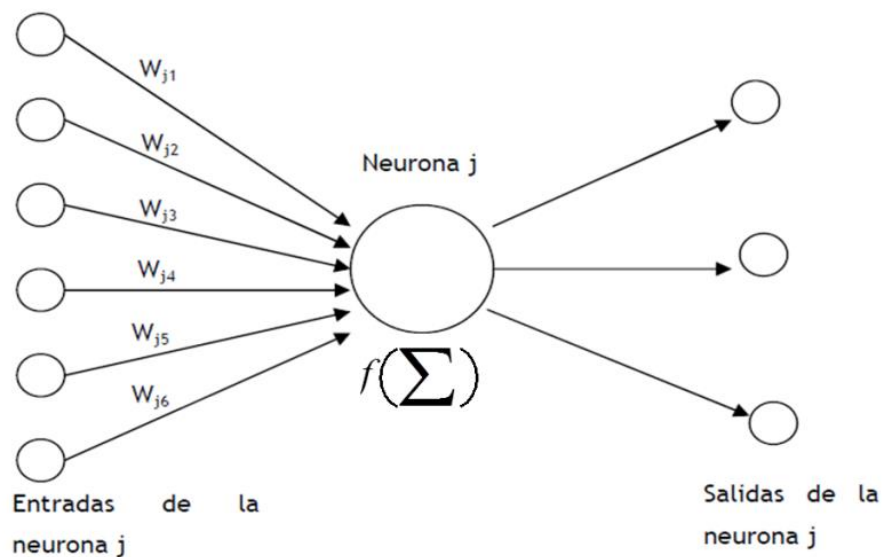


Figura 4.2. Esquema del funcionamiento de una neurona. Recuperado de Ponce. (2010).- Inteligencia artificial con aplicaciones a la ingeniería.

En este modelo, la neurona j recibe una serie de entradas x_1, x_2, \dots, x_n . Cada señal se multiplica por el peso asociado a su conexión, $w_{j1}, w_{j2}, \dots, w_{jn}$. Luego, se suman estas entradas ponderadas y se les aplica la función de activación $f(\cdot)$ para generar la señal de salida de la neurona j . Los valores de los pesos son ajustados durante la fase de aprendizaje, Fig. 4.3.

Como se ha comentado anteriormente, estas neuronas están conectadas entre sí de acuerdo a una determinada *arquitectura*. Es decir, las neuronas se agrupan en distintas capas: *una capa de entrada, otra de salida, y en el caso de existir, una o varias capas ocultas*.

La salida de cada neurona se propaga por igual por estas conexiones hasta las neuronas de destino. Cada conexión tiene un peso asociado que pondera el valor numérico de la señal que viaja por esta. Así pues, una red de neuronas artificial puede verse como un grafo cuyos nodos tienen funcionamiento similar, los cuales propagan la información a través de las distintas conexiones.

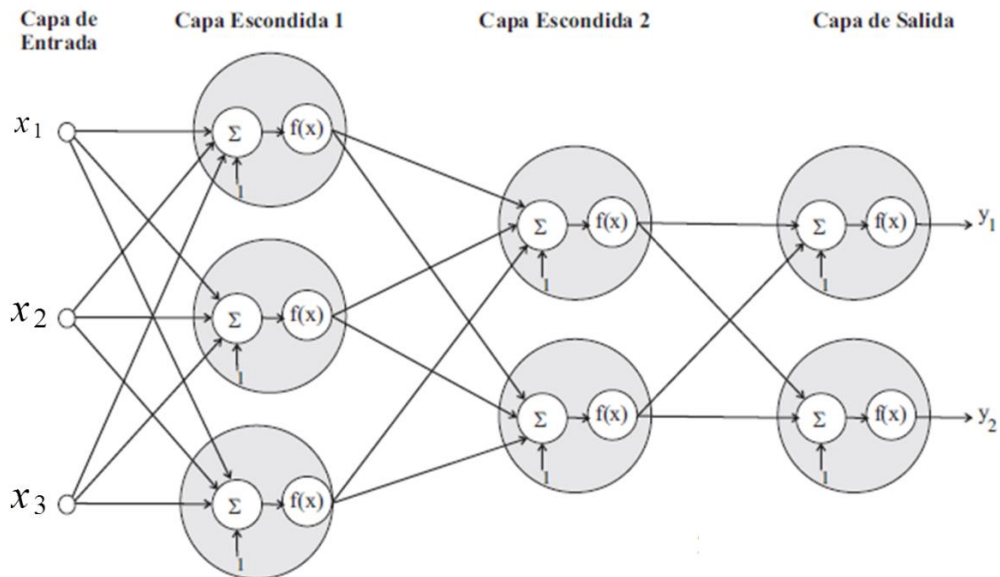


Figura 4.3. Esquema del funcionamiento de una red neuronal con capas ocultas. En esta red se muestran 3 entradas y 2 salidas y con dos capas ocultas, todas con función de activación f . Recuperado de Ponce. (2010). Inteligencia artificial con aplicaciones a la ingeniería.

La función $f(\cdot)$ puede ser sigmoideal, tangente hiperbólica, escalón, entre otras. Cada unidad de proceso tiene una tarea simple: recibe la entrada de otras unidades o de fuentes externas y procesa la información para obtener una salida que se propaga a otras unidades.

Las entradas externas son aplicadas en la primera capa, y las salidas se consideran la última capa. Las capas internas que no se observan como entradas o salidas se denominan *capas ocultas*. Por convención las entradas no se consideran como capa porque no realizan procesamiento. La entrada total u de una unidad k es la suma de los productos de los pesos por las entradas, más un bias b :

$$u_i = \sum_j w_{ij}x_j + b_i \quad (18)$$

Si el peso w_{ij} es positivo se habla de una *excitación* y si el peso es negativo se considera una imbibición de la entrada.

4.3.1 Funciones de activación

Algunas de las funciones de activación usadas en área de las redes neuronales son las siguientes

Función identidad

$$f(x) = x \quad (19)$$

Función sigmoidal

$$f(x) = \frac{1}{1+e^{-x}} \quad (20)$$

Función tangente hiperbólica

$$f(x) = \frac{1-e^{-x}}{1+e^{-x}} \quad (21)$$

La principal diferencia entre la función sigmoidal y la función tangente hiperbólica es el rango de sus valores de salida. Mientras que para la primera su rango es $[0,1]$, para la segunda es $[-1,1]$. El uso de las funciones de activación debe estar acorde con los datos a usar. Estos datos deben normalizarse para que estén dentro de los rangos de $[0,1]$, o de $[-1,1]$.

4.3.2 El Perceptrón multicapa

Entre los diversos modelos que existen de RNA el más utilizado como aproximador universal de funciones resulta el perceptrón multicapa asociado al algoritmo de aprendizaje back-propagation error (propagación del error hacia atrás), también denominado método de gradiente decreciente, Casacuberta (2012).

Este tipo de red exhibe la capacidad de “aprender” la relación entre un conjunto de entradas y salidas a través del ajuste de los pesos de manera iterativa en la etapa de aprendizaje y posteriormente aplica esta relación a nuevos vectores de entrada que el sistema no ha visto nunca en su etapa de entrenamiento dando una salida activa si la nueva entrada es parecida a las

presentadas durante el aprendizaje. Esta capacidad de generalización convierte a las redes perceptrón multicapa en herramientas de propósito general, flexibles y no lineales.

La arquitectura perceptrón multicapa está compuesto por una capa de entrada, una de salida y una o más capas ocultas; en la Fig. 4.4 podemos observar una red de este tipo. Para identificar la estructura de una red multicapa se utiliza la notación $R: s^1: s^2$, donde el número de entradas (R) va seguido por el número de neuronas en cada capa (s) y el exponente indica la capa a la cual la neurona corresponde.

En esta disposición, los elementos del vector de entrada p están conectados solo hacia delante sin que exista retroalimentación por lo que comúnmente se les clasifica en el grupo de redes con arquitectura *feedforward* (*alimentación hacia adelante*). Las entradas se vinculan a través de la matriz de pesos (W) a cada una de las neuronas donde se transforman en una suma ponderada con valores limitados por los biases (b) o umbrales de la neurona, el cual puede verse como un número que indica a partir de qué valor de potencial postsináptico la neurona produce una salida significativa, Marcano (2010), este término es añadido a la suma ponderada para formar el vector modificado $[n]$ de S elementos (uno por cada neurona) de la red, los que finalmente son afectados por la función de activación para formar el vector columna de las salidas $[a]$; si existe más de una capa estas salidas se pueden convertir en entradas de la próxima sobre las que se repite nuevamente el proceso.




Figura 4.4. Representación de una RNA de 3 capas con 4 entradas y una salida. En la capa 1, 3 neuronas, en la capa 2, 2 neuronas y en la capa 3, 1 neurona.

En la Fig. 4.4 el vector de entrada es expresado de la siguiente manera;

$$X_j = \begin{pmatrix} x_1 \\ x_2 \\ x_3 \\ x_4 \end{pmatrix} \quad (22)$$

Dónde:

$$x_1 = \text{Presión en } \left(\frac{kg}{cm^2}\right)$$

$$x_2 = \text{Densidad del aceite } \left(\frac{gr}{cm^3}\right)$$

$$x_3 = \text{Densidad relativa del gas (adimensional)}$$

$$x_4 = \text{Temperatura de Yacimiento } (^{\circ}C)$$

$$Y = \text{Factor de volumen del aceite a la Pb } (m^3/m^3)$$

Los bias y/ polarización son representados de la siguiente manera:

Para la primera capa queda expresado;

$$b_i^1 = \begin{pmatrix} b_1^1 \\ b_2^1 \\ b_3^1 \end{pmatrix} \quad (23)$$

Para la segunda capa;

$$b_k^2 = \begin{pmatrix} b_1^2 \\ b_2^2 \end{pmatrix} \quad (24)$$

Para la tercera capa;

$$b_1^3 = b_1^3 \quad (25)$$

Quedando las matrices siguientes para obtener los pesos sinápticos (capa 1);

$$W_{ij}^1 = \begin{pmatrix} W_{11}^1 & W_{12}^1 & W_{13}^1 & W_{14}^1 \\ W_{21}^1 & W_{22}^1 & W_{23}^1 & W_{24}^1 \\ W_{31}^1 & W_{32}^1 & W_{33}^1 & W_{34}^1 \end{pmatrix} \quad (26)$$

Capa 2;

$$W_{ki}^2 = \begin{pmatrix} W_{11}^2 & W_{12}^2 & W_{13}^2 \\ W_{21}^2 & W_{22}^2 & W_{23}^2 \end{pmatrix} \quad (27)$$

Capa 3;

$$W_{1k}^3 = (W_{11}^3 \quad W_{12}^3) \quad (28)$$

Donde, las entradas netas quedan expresadas de la siguiente manera;

$$a_i^1 = f_3^1(n_i^1) \quad (29)$$

$$a_k^2 = f_2^2(n_k^2) \quad (30)$$

y la salida se muestra a continuación;

$$y = f^3(n_1^3) \quad (31)$$

Usando la función de activación mostrada por el autor ;

$$f(x) = \frac{1}{1 + e^{-x}} \rightarrow \text{logsig} \quad (32)$$

A continuación se muestra el algoritmo luego de que la red ha sido entrenada;

1) Dar el vector de entrada

$$X_j = \begin{pmatrix} x_1 \\ x_2 \\ x_3 \\ x_4 \end{pmatrix} \quad (33)$$

2) Evaluar para $i=1$ hasta 3 (Capa 1)

$$n_i^1 = \sum_{j=1}^4 W_{ij}^1 x_j + b_i^1 \quad (34)$$

Obteniendo la siguiente salida neta;

$$a_i^1 = f^1(n_i^1) \quad (35)$$

3) Evaluar para $k=1$ hasta 2 (Capa 2)

$$n_k^2 = \sum_{i=1}^3 W_{ki}^2 a_i^1 + b_k^2 \quad (36)$$

Obteniendo la siguiente salida neta;

$$a_k^2 = f^2(n_k^2) \quad (37)$$

4) Evaluar (Capa 3)

$$n_1^3 = \sum_{k=1}^2 W_{1k}^3 a_k^2 + b_1^3 \quad (38)$$

Obteniendo la siguiente salida neta;

$$y = f^3(n_1^3) \quad (39)$$

4.4 Métodos de aprendizaje

Las (RNA) redes neuronales artificiales son sistemas de aprendizaje basados en datos que son utilizados como patrones. Por ello la capacidad de una red de resolver un problema está muy ligada a los patrones utilizados durante su fase de aprendizaje.

El *aprendizaje* de una red neuronal consiste en hallar los valores precisos de los pesos de sus conexiones para que pueda resolver un determinado problema. El proceso general consiste en ir introduciendo una serie de datos patrón y ajustar los pesos siguiendo un determinado criterio.

Los criterios que se van a utilizar en este proyecto se fundamentan en el error cometido por la red, lo que nos obliga a conocer la salida que se debería obtener para cada uno de ellos. Es lo que se conoce como entrenamiento supervisado.

De esta manera, primero se introducen los patrones, se reajustan los pesos, posteriormente se comprueba si se ha cumplido un determinado criterio de convergencia, de no ser así se repite todo el proceso.

4.4.1 Algoritmo de propagación hacia atrás (BackPropagation)

Es el algoritmo básico de aprendizaje que usa el perceptrón multicapa, mediante el cual se van adaptando todos los parámetros de la red. El tipo de entrenamiento que se sigue para la red es supervisado, el aprendizaje de la red se plantea como un problema de minimización de una determinada función de error. En general se usa como función del error, el error medio cuadrático, es decir:

$$E = \frac{1}{n} \sum_{n=1}^N e(n) \quad (40)$$

$$e(n) = \frac{1}{2} \sum_{n=1}^t (s(n) - y(n))^2 \quad (41)$$

Donde $s(n)$ es la salida patrón, $y(n)$ la salida obtenida de la red, t el número de neuronas de salida y N el número de patrones. El problema es no lineal y como tal, el problema de minimización de la función error se resuelve por técnicas de optimización no lineales que se basan en ajustar los parámetros siguiendo una determinada dirección.

En este método, la dirección elegida es la negativa del gradiente de la función error. Más adelante veremos que existen otros métodos que no se basan en esta dirección de cambio.

A partir de aquí existen dos opciones. Podemos cambiar los parámetros cada vez que introducimos el Patrón, o solamente cambiarlos cuando hayamos introducido todos los parámetros de entrenamiento por cada ciclo. En el primer caso, debemos minimizar $e(n)$ y en el segundo se minimiza la función E .

A continuación se presentará el desarrollo para el primer caso, pero la extensión al segundo es inmediata. De acuerdo a lo que hemos dicho antes, todos los pesos deben variar según la dirección del gradiente del error. Matemáticamente esto se expresa de la siguiente forma:

$$W(n) = W(n - 1) - \alpha \frac{\partial e(n)}{\partial W} \quad (42)$$

Por lo tanto el problema consiste en evaluar la derivada. El parámetro α es la tasa de aprendizaje que influye en la magnitud del desplazamiento en la superficie de la función error. A continuación se evalúa el valor del gradiente para los pesos de las conexiones de la última capa oculta a las neuronas de la capa de salida. Sea $W_{ji}^{c-1}(n)$ el peso de la conexión de la neurona j de la capa $C - 1$ a la neurona i de la capa de salida. El error $e(n)$ viene dado por la ecc. 42, y además este solo se ve afectado por $W_{ji}^{c-1}(n)$ en el error de la salida de la neurona i . Por tanto:

$$\frac{\partial e(n)}{\partial W_{ji}^{c-1}} = -(s_i(n) - y_i(n)) \frac{\partial y_i(n)}{\partial W_{ji}^{c-1}} \quad (43)$$

Por otro lado, la salida de la neurona i es igual a la suma de las entradas transformadas según su función de activación. Aplicando la regla de la cadena, y teniendo en cuenta que solo afecta a la entrada de la neurona i porque va multiplicando $W_{ji}^{c-1}(n)$ se tiene que:

$$\frac{\partial y_i(n)}{\partial W_{ji}^{c-1}} = f' \left(\sum_{j=1}^{n_{c-1}} W_{ji}^{c-1} a_j^{c-1} + \right) \quad (44)$$

4.4.2 Algoritmo de Levenberg – Marquardt

Este algoritmo es una modificación del método de Newton, fue diseñado para minimizar funciones que sean la suma de los cuadrados de otras funciones no lineales; es por ello que el algoritmo de Levenberg - Marquardt, tiene un excelente desempeño en el entrenamiento de redes neuronales donde el rendimiento de la red esté determinado por el error medio cuadrático.

El método de Newton para optimizar el rendimiento $e(x)$ es:

$$X_{k+1} = X_k - A_k^{-1} g_k \quad (45)$$

$$A_k \equiv \nabla^2 e(x)_{x=x_k} \quad g_k \equiv \nabla e(x)_{x=x_k} \quad (46)$$

Si asumimos que $e(x)$ es una suma de funciones cuadráticas:

$$e(x) = \sum_{i=1}^n v_i^2(x) = v^T(x)v(x) \quad (47)$$

El gradiente puede ser escrito entonces en forma matricial:

$$\nabla e(x) = 2J^T(x)v(x) \quad (48)$$

Donde $J(x)$ es la matriz Jacobiana.

Ajustando el método de Newton, obtenemos el algoritmo de Levenberg Marquardt;

$$x_{k+1} = x_k - [J^T(x_k)J(x_k) + \mu_k I]^{-1} J^T(x_k) v(x_k) \quad (49)$$

$$\Delta x_k = -[J^T(x_k)J(x_k) + \mu_k I]^{-1} J^T(x_k) v(x_k) \quad (50)$$

La nueva constante μ determina la tendencia el algoritmo, cuando μ_k se incrementa, este algoritmo se aproxima al algoritmo de pasos descendientes para gastos de aprendizaje muy pequeños; cuando μ_k se decrementa este algoritmo se convierte en el método de Gauss – Newton.

El algoritmo comienza con un valor pequeño para μ_k , por lo general 0.01, si en ese paso no se alcanza el valor para $e(x)$ entonces el paso es repetido con μ_k multiplicado por un factor $\xi > 1$. Si se ha escogido un valor pequeño de paso en la dirección de paso descendente, $e(x)$ debería decrecer. Si un paso produce un pequeño valor para $e(x)$, entonces el algoritmo tiende al método de Gauss - Newton, el que se supone garantiza una rápida convergencia. Este algoritmo genera un compromiso entre la velocidad del método de Gauss-Newton y la garantía de convergencia del método de paso descendiente.

Los elementos de la matriz Jacobiana necesarios en el algoritmo de Levenberg-Marquardt son de este estilo:

$$[J]_{h,l} = \frac{\partial e_{k,q}}{\partial x_1} \quad (51)$$

Donde x es el vector de parámetros de la red, que tiene la siguiente forma:

$$x^T = [x_1, x_2, \dots, x_n] = [w_{1,1}^1, w_{1,2}^1, \dots, w_{S^1,R}^1, b_1^1, \dots, b_{S^1}^1] \quad (52)$$

Capítulo V.

Red Neuronal de los parámetros B_{ob} , P_b , R_s y C_o para un aceite negro y volátil.

Generalidades

Para llevar a cabo este trabajo fue necesario identificar el tipo de aceite dependiendo de los grados API, la clasificación a usar se muestra en la siguiente tabla 5.1.

Tabla 5.1. Clasificación API de aceite negro y volátil.

Clasificación API según Méndez L. y J. Teyssier	
<i>Aceite negro</i>	< 35
<i>Aceite volátil</i>	35-57

Una vez clasificado el aceite por sus grados API y visualizados los parámetros a estimar, se discretizó el tipo de experimento a utilizar, para este caso los experimentos son: *Separación diferencial* y *separación flash* para los dos aceites, como se muestra en la tabla 5.2.

Tabla 5.2. Tipos de experimentos para aceite negro y volátil utilizados en la RNA.

Tipo de experimento y cantidad de muestras por cada red		
	Cantidad	Tipo de experimento
<i>Aceite negro</i>		
RNA_Bob (A. negro)	50	<i>Separación diferencial</i>
RNA_Co (A. negro)	105	<i>Separación flash</i>
RNA_Pb (A. negro)	50	<i>Separación diferencial</i>
RNA_Rs (A. negro)	250	<i>Separación diferencial</i>
<i>Aceite volátil</i>		
RNA_Bob (A. volátil)	55	<i>Separación diferencial</i>
RNA_Co (A. volátil)	272	<i>Separación flash</i>
RNA_Pb (A. volátil)	53	<i>Separación diferencial</i>
RNA_Rs (A. volátil)	289	<i>Separación diferencial</i>

Ya identificados los experimentos se organizó una base de datos para cada parámetro, esto con la finalidad de optimizar el manejo de la información. Una vez seleccionada la información se procedió a programar la red neuronal para cada uno de los elementos y/o parámetros.

Para programar la red neuronal de $X_{parámetro}$ es necesario cumplir con una serie de pasos y/o metodología siguiente:

1.-Recopilación de información; Se hizo un compendio de análisis PVT (Presión-Volumen-Temperatura), de aceite negro y volátil.

2.- Selección de información; En esta parte se analiza la información PVT a introducir, es decir se toman los PVT a utilizar para ver la consistencia y validación de los mismos, selección del tipo de aceite, para este caso se clasificó dependiendo de la gravedad API para construir una tabla y discretizar aceite negro y volátil.

3.- Revisión de experimentos; Ya conjunta la información se determinó el experimento a emplear y las propiedades físicas a estimar.

4.- Entrenamiento de la Red; De la muestra de datos obtenida se realizó una normalización para poder llevar a cabo la programación de cada parámetro, con la finalidad de que el ajuste sea adecuado con el mínimo de error, en donde la red es entrenada con valores de entrada y salida generando las instrucciones adecuadas como son, número de capas, neuronas en cada capa, función de activación y algoritmo de entrenamiento Levenberg-Marquardt. En esta parte se corrieron diversas simulaciones con estructuras distintas para analizar la confiabilidad y obtener el diseño óptimo para su aplicación.

Una vez obtenido el ajuste requerido es importante extraer los datos de los pesos sinápticos y bias (polarización) para introducirlos en la macro y llevar a cabo la programación.

5.-Pruebas de estimación; Ya complementada la macro, se realizan diversas simulaciones para visualizar el error mínimo, de tal manera que el analista introduzca sus datos para hacer sus comparativos.

5.1 Red Neuronal Artificial para la estimación de R_s de un aceite negro.

En la construcción de esta red se usaron 250 muestras de parámetros PVT de aceite negro, la función de activación usada en cada capa fue la función logsig.

5.1.1 Estructura de la red

- 1). Esta red consta de 4 entradas (*temperatura del yacimiento, presión de interés ($P < P_b$), densidad relativa del gas, densidad relativa del aceite*).
- 2). La salida de esta red es la relación de solubilidad (R_s)
- 3). La estructura consiste en 4 entradas (capa 1), 7 neuronas en la capa 2, 6 neuronas en la capa 3, 5 neuronas en la capa 4 y una neurona en la capa de salida.
- 4). El entrenamiento se realizó con el algoritmo de Levenberg-Marquardt.

La tabla 5.3 muestra el rango de validez desde el mínimo al máximo valor a utilizar de esta red.

Tabla 5.3. Rangos de validez de RNA para la estimación de R_s en aceite negro.

<u>Rango de validez</u>		
<u>Rs aceite negro</u>	<u>Mínimo</u>	<u>Máximo</u>
Temperatura (C)	59	160
Presión (kg/cm ²)	10.55	405
Densidad relativa del gas (aire=1)	0.08372	1.218
Densidad relativa del aceite.	0.47	0.8942
Rs (m ³ /m ³)	3.051	374.079

5.1.2 Algoritmo de RNA para la estimación de R_s en aceite negro.

1). Evaluar

$$n_i^1 = \sum_{j=1}^4 w_{ij}^1 x_j + b_i^1$$

$$a_i^1 = f^1(n_i^1), \text{ para } i = 1, 2, \dots, 7.$$

2). Evaluar

$$n_k^2 = \sum_{i=1}^7 w_{ki}^2 a_i^1 + b_k^2$$

$$a_k^2 = f^2(n_k^2), \text{ para } k = 1, 2, \dots, 6.$$

3). Evaluar

$$n_l^3 = \sum_{k=1}^6 w_{lk}^3 a_k^2 + b_l^3$$

$$a_l^3 = f^3(n_l^3), \text{ para } l = 1, 2, \dots, 5.$$

4). Evaluar

$$n_1^4 = \sum_{l=1}^5 w_{1l}^4 a_l^3 + b_1^4$$

$$a_1^4 = f^4(n_1^4)$$

$$R_s = a_1^4$$

Las Fig. 5.1 y 5.2 muestran las matrices de los pesos sinápticos y bias para estimación del parámetro R_s para aceite negro.

w1=	2.6278	-1.6687	-5.7179	0.7059			
	0.9788	-2.2358	-2.1787	0.4181			
	-10.9526	1.8587	-11.4669	-3.8501			
	-8.6269	-0.2023	7.1303	17.0892			
	-12.1144	-5.9710	-0.3291	8.5557			
	11.2873	0.1457	5.3368	3.0941			
-35.5880	-3.8953	-8.3034	29.4164				
w2=	-10.9582	11.5232	1.5853	-1.1850	3.2167	7.2543	-58.6377
	-28.4436	28.3441	-18.4531	-11.7494	-1.6248	-5.6101	1.5229
	-5.5853	11.7016	4.9809	2.8328	-12.7708	-11.5555	-4.0410
	7.0126	-21.4046	-4.1992	-2.5103	1.6666	-2.5376	0.7738
	15.6426	-26.2611	-11.2267	2.2598	-2.5686	-4.5386	2.1523
	-0.7330	4.3943	-0.0367	-4.8547	6.5688	-15.8918	8.8372
w3=	-0.4134	4.0976	1.3766	3.3036	-0.2957	5.9554	
	31.0166	-0.4679	-2.9786	-10.4304	-0.0916	-34.1819	
	23.9002	1.1322	11.7237	1.2480	4.3158	-27.8362	
	-5.3174	1.8333	7.4335	-10.6453	-3.8529	1.4469	
	-2.7137	-1.4618	-4.0394	12.0537	0.6834	-2.5236	
w4=	-2.3899	-13.2479	13.4572	-11.1270	3.8368		

Figura 5.1 Pesos sinápticos de RNA para la estimación de R_s en aceite negro.




Figura 5.2 Biais de RNA para la estimación de R_s en aceite negro.

5.1.3 Resultados

Se creó una función en Excel que estima el valor de R_s mediante una RNA, con la cual se compararon los datos reales vs los datos estimados por la red con los siguientes resultados, Fig.5.3.

F_AN_Rs(T,P,DrGas,DrAceite): Esta función recibe como entrada la temperatura del yacimientos, presión de interés ($P < P_b$), densidad relativa del gas, densidad relativa del aceite y tiene como salida la relación de solubilidad.

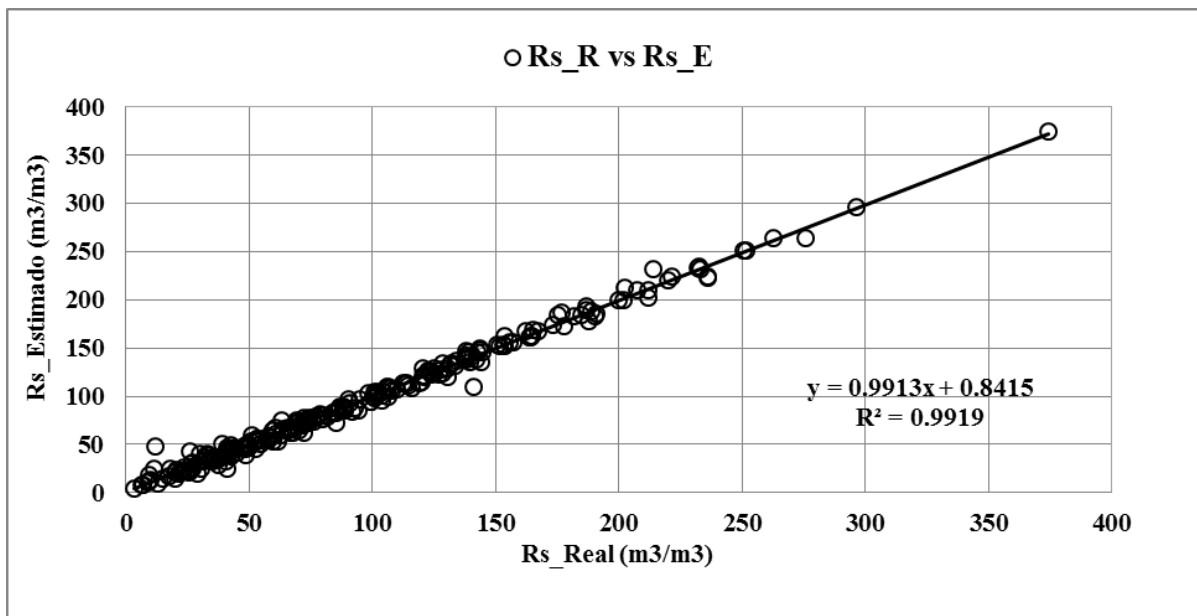


Figura 5.3 Comparación de R_s real vs R_s estimada por RNA para aceite negro.

5.2 Red Neuronal Artificial para la estimación de B_{ob} de un aceite negro.

En la construcción de esta red se usaron 50 muestras de parámetros PVT de aceite negro y la función de activación usada en cada capa fue la función *logsig*.

5.2.1 Estructura de la red

- 1). Esta red consta de 4 entradas (*temperatura del yacimiento, R_s para $P \geq P_b$, densidad relativa del gas, densidad relativa del aceite*).
- 2). La salida de esta red es el factor de volumen a P_b .
- 3). La estructura consiste en 4 entradas (capa 1), 4 neuronas en la capa 2, 3 neuronas en la capa 3 y una neurona en la capa de salida.
- 4). El entrenamiento se realizó con el algoritmo de Levenberg-Marquardt.

La tabla 5.4 muestra el rango de validez desde el mínimo al máximo valor a utilizar de esta red.

Tabla 5.4. Rangos de validez de RNA para la estimación de B_{ob} en aceite negro.

<u>Rango de validez</u>	Mínimo	Máximo
Temperatura (C)	59.91	174
Rsb (m3/m3)	47.7	679.6
Densidad relativa del gas (aire=1)	0.627	1.196
Densidad relativa del aceite.	0.3902	0.8742
Bob (m3/m3)	1.1556	3.571

5.2.2 Algoritmo de RNA para la estimación de B_{ob} en aceite negro.

1). Evaluar

$$n_i^1 = \sum_{j=1}^4 w_{ij}^1 x_j + b_i^1$$

$$a_i^1 = f^1(n_i^1), \text{ para } i = 1, 2, 3, 4.$$

2). Evaluar

$$n_k^2 = \sum_{i=1}^4 w_{ki}^2 a_i^1 + b_k^2$$

$$a_k^2 = f^2(n_k^2), \text{ para } k = 1,2,3.$$

3). Evaluar

$$n_1^3 = \sum_{k=1}^3 w_{1k}^3 a_k^2 + b_1^3$$

$$a_1^3 = f^3(n_1^3)$$

$$Bob = a_1^3$$

Las Fig. 5.4 y 5.5 muestran las matrices de los pesos sinápticos y bias para estimación del parámetro *Bob* para aceite negro.

w1=	-1.3806	17.5697	0.4746	-5.8548
	-1.9254	-6.1896	-3.8106	13.8517
	5.3952	-18.9434	-5.6289	4.6858
	2.1328	3.6170	4.5413	-15.6763
w2=	5.0646	4.1016	-2.2352	-1.7412
	-10.1451	3.9588	-9.0715	4.1669
	2.3836	-7.0566	3.5856	0.7418
w3=	-2.0193	-12.6302	2.6023	

Figura 5.4 Pesos sinápticos de RNA para la estimación de *Bob* en aceite negro.

b1=	-6.0617
	-5.9856
	8.8321
	7.9701
b2=	-8.4300
	7.4087
	3.9821
b3=	8.6291

Figura 5.5 Bias de RNA para la estimación de *Bob* en aceite negro.

5.2.3 Resultados

Se creó una función en Excel que evalúa el *Bob* con la cual se comparan los datos reales vs los datos estimados por la red con los siguientes resultados, Fig. 5.6.

F_AN_Bob(T,Rsb,DrGas,DrAceite): Esta función recibe como entrada la temperatura del yacimiento, Rsb , densidad relativa del gas, densidad relativa del aceite y tiene como salida el factor de volumen del aceite a Pb .

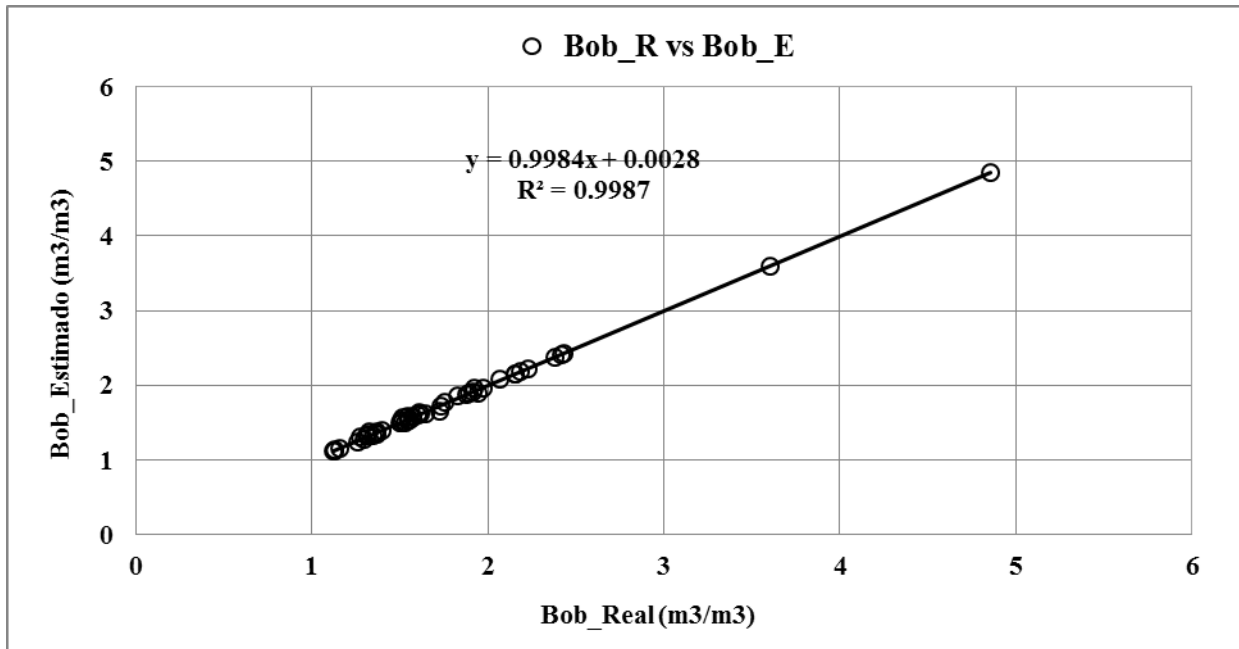


Figura 5.6 Comparación de Bob real vs Bob estimada por RNA para aceite negro.

5.3 Red Neuronal Artificial para la estimación de C_o de un aceite negro

En la construcción de esta red se usaron 105 muestras de parámetros PVT de aceite negro y la función de activación usada en cada capa fue la función *logsig*.

5.3.1 Estructura de la red

- 1). Esta red consta de 4 entradas (*presión de interés ($P > Pb$), temperatura del yacimiento, R_s para $P > Pb$, densidad relativa del aceite*).
- 2). La salida de esta red es la compresibilidad del aceite (C_o)
- 3). La estructura consiste en 4 entradas (capa 1), 7 neuronas en la capa 2, 6 neuronas en la capa 3, 5 neuronas en la capa 4 y una neurona en la capa de salida.

4). El entrenamiento se realizó con el algoritmo de Levenberg-Marquardt.

La tabla 5.5 muestra el rango de validez desde el mínimo al máximo valor a utilizar de esta red.

Tabla 5.5. Rangos de validez de RNA para la estimación de C_o en aceite negro.

Rango de validez	Mínimo	Máximo
Presión (kg/cm ²)	50	845
Temperatura (C)	59	160
Rs (m ³ /m ³)	11.01	670.29
Densidad relativa del aceite.	0.401	0.8631
C_o (1/kg/cm ²)	0.0001	0.00092

5.3.2 Algoritmo de RNA para la estimación de C_o en aceite negro.

1). Evaluar

$$n_i^1 = \sum_{j=1}^4 w_{ij}^1 x_j + b_i^1$$

$$a_i^1 = f^1(n_i^1), \text{ para } i = 1, 2, \dots, 7.$$

2). Evaluar

$$n_k^2 = \sum_{i=1}^7 w_{ki}^2 a_i^1 + b_k^2$$

$$a_k^2 = f^2(n_k^2), \text{ para } k = 1, 2, \dots, 6.$$

3). Evaluar

$$n_l^3 = \sum_{k=1}^6 w_{lk}^3 a_k^2 + b_l^3$$

$$a_l^3 = f^3(n_l^3), \text{ para } l = 1, 2, \dots, 5.$$

4). Evaluar

$$n_1^4 = \sum_{l=1}^5 w_{1l}^4 a_l^3 + b_1^4$$

$$a_1^4 = f^4(n_1^4)$$

$$C_o = a_1^4$$

Las Fig. 5.7 y 5.8 muestran las matrices de los pesos sinápticos y bias para estimación del parámetro C_o para aceite negro.

w1=	3.3594	1.0727	2.8370	-6.3280			
	12.9027	5.8802	-1.2358	3.9757			
	-9.0540	8.7693	3.4028	4.2602			
	5.9670	2.8460	9.0883	3.2888			
	-13.0258	-0.1631	8.1086	33.3375			
	-3.4647	13.7695	23.0823	-8.0484			
	-51.8002	22.2489	8.9991	3.8690			
w2=	1.8002	-10.7800	2.1725	2.1033	3.8938	2.8122	0.8981
	-3.0421	4.7055	2.4550	7.4548	-1.7213	-0.6377	-5.2908
	2.7158	-6.1445	-16.8024	15.6954	-32.0573	6.0520	40.9759
	-3.9933	-5.4023	18.8270	-2.1864	-6.9324	-9.0821	-0.0036
	-1.3252	-2.1920	-6.7946	-4.9103	7.3686	15.7131	-4.7435
	-4.3812	-12.4824	3.6386	-1.6004	0.3209	15.9463	4.8310
w3=	2.3220	2.5163	-2.3953	-2.4253	-1.1528	2.3943	
	6.9710	-10.9091	20.8094	19.9475	-19.7326	-4.0198	
	2.2122	-2.5448	11.9769	16.9507	5.7078	-16.1130	
	-9.3112	6.5736	-1.6411	2.9295	5.3588	-17.5621	
	3.4483	-2.8223	5.8093	0.6510	27.4454	-4.4817	
w4=	-14.6131	16.4434	-27.7557	21.1322	14.9205		

Figura 5.7 Pesos sinápticos de RNA para la estimación de C_o en aceite negro.

b1=	-6.4504	b2=	-0.7159
	-7.6732		-2.3631
	-4.3909		-3.9036
	-12.5009		3.5354
	-25.6212		-3.7842
	-0.6156		-5.3538
	-11.4901		
b3=	-0.1149	b4=	-3.5182
	1.8560		
	-6.5516		
	0.1656		
	-4.6213		

Figura 5.8 Bias de RNA para la estimación de C_o en aceite negro.

5.3.3 Resultados

Se creó una función en Excel que evalúa Co con la cual se comparan los datos reales vs los datos estimados por la red con los siguientes resultados, Fig. 5.9.

F_AN_Co(P,T,Rs,DrAceite): Esta función recibe como entrada la presión de interés $P > P_b$, temperatura del yacimiento, R_s a $P > P_b$, densidad relativa del aceite y tiene como salida la relación de solubilidad.

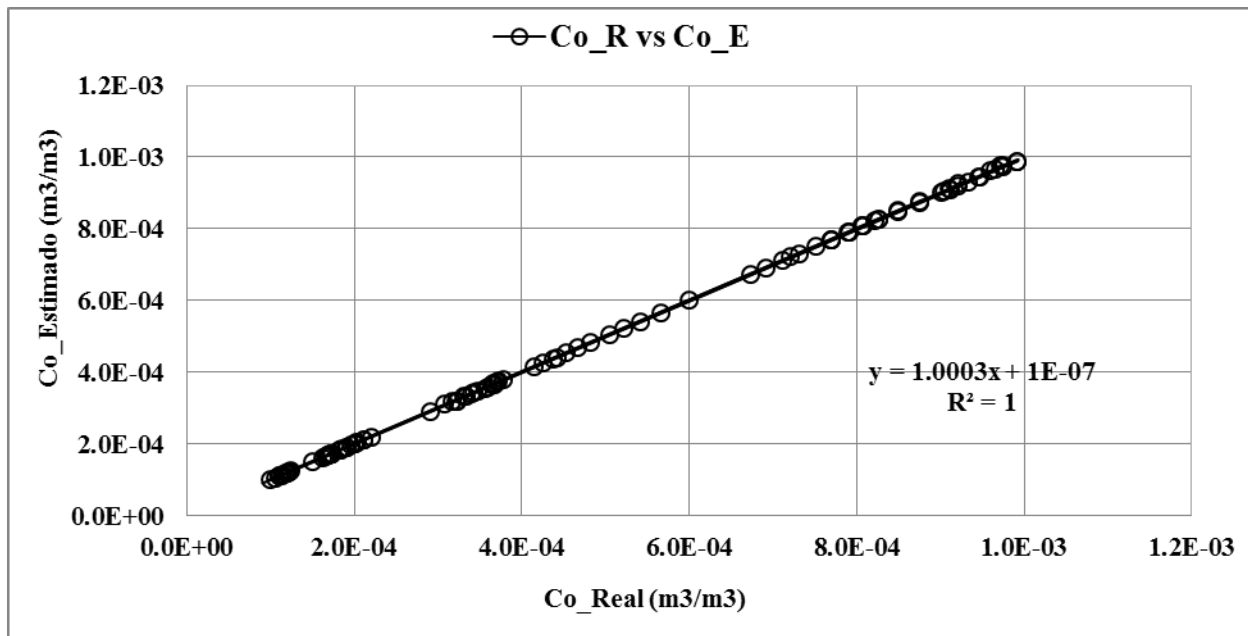


Figura 5.9 Comparación de Co real vs Co estimada por RNA para aceite negro.

5.4 Red Neuronal Artificial para la estimación de P_b de un aceite negro

En la construcción de esta red se usaron 50 muestras de parámetros PVT de aceite negro y la función de activación usada en cada capa fue la función *logsig*.

5.4.1 Estructura de la red

- 1). Esta red consta de 4 entradas (*temperatura del yacimiento, R_s para $P > P_b$, densidad relativa del gas, densidad relativa del aceite*).
- 2). La salida de esta red es la presión de burbuja (P_b)
- 3). La estructura consiste en 4 entradas (capa 1), 5 neuronas en la capa 2, 4 neuronas en la capa 3 y una neurona en la capa de salida.

4). El entrenamiento se realizó con el algoritmo de Levenberg-Marquardt.

La tabla 5.6 muestra el rango de validez desde el mínimo al máximo valor a utilizar de esta red.

Tabla 5.6. Rangos de validez de RNA para la estimación de Pb en aceite negro.

<u>Rango de validez</u>	Mínimo	Máximo
Temperatura (C)	58	160
Rsb (m3/m3)	38.17	670.29
Densidad relativa del gas (aire=1)	0.235	0.995
Densidad relativa del aceite.	0.3982	0.8492
Pb (kg/cm2)	75.2	411

5.4.2 Algoritmo de RNA para la estimación de Pb en aceite negro.

1). Evaluar

$$n_i^1 = \sum_{j=1}^4 w_{ij}^1 x_j + b_i^1$$

$$a_i^1 = f^1(n_i^1), \text{ para } i = 1,2,3,4,5.$$

2). Evaluar

$$n_k^2 = \sum_{i=1}^5 w_{ki}^2 a_i^1 + b_k^2$$

$$a_k^2 = f^2(n_k^2), \text{ para } k = 1,2,3,4.$$

3). Evaluar

$$n_1^3 = \sum_{k=1}^4 w_{1k}^3 a_k^2 + b_1^3$$

$$a_1^3 = f^3(n_1^3)$$

$$P_b = a_1^3$$

Las Fig. 5.10 y 5.11 muestran las matrices de los pesos sinápticos y bias para estimación del parámetro Pb para aceite negro.

W1=	8.0269	-12.2560	-0.3101	6.2854	
	19.5032	-42.2416	-17.6991	-4.0537	
	0.6216	-9.6676	0.2936	2.7925	
	-26.4966	19.9827	1.9665	19.9806	
	1.8741	-4.4128	-2.9270	-8.3817	
W2=	-0.5751	-8.3464	11.7367	4.4692	-6.6922
	8.1537	-2.0981	-6.4967	-3.1015	-2.1016
	-29.4555	2.7031	23.3910	-19.2866	15.8168
	9.6108	-2.9043	-6.9058	6.8459	-1.4775
W3=	-19.7901	-21.6925	13.8259	43.5715	

Figura 5.10 Pesos sinápticos de RNA para la estimación de Pb en aceite negro.

b1=	-6.7364
	20.0360
	0.1325
	-11.7183
	6.0579
b2=	-2.8066
	0.5515
	-3.7335
	2.7053
b3=	-26.3964

Figura 5.11 Bias de RNA para la estimación de Pb en aceite negro.

5.3.3 Resultados

Se creó una función en Excel que evalúa Pb con la cual se comparan los datos reales vs los datos estimados por la red con los siguientes resultados, Fig. 5.12.

F_AN_Pb(T,Rsb,DrGas,DrAceite): Esta función recibe como entrada la temperatura del yacimiento, R_s a $P > P_b$, densidad relativa del gas, densidad relativa del aceite y tiene como salida la presión de burbuja.

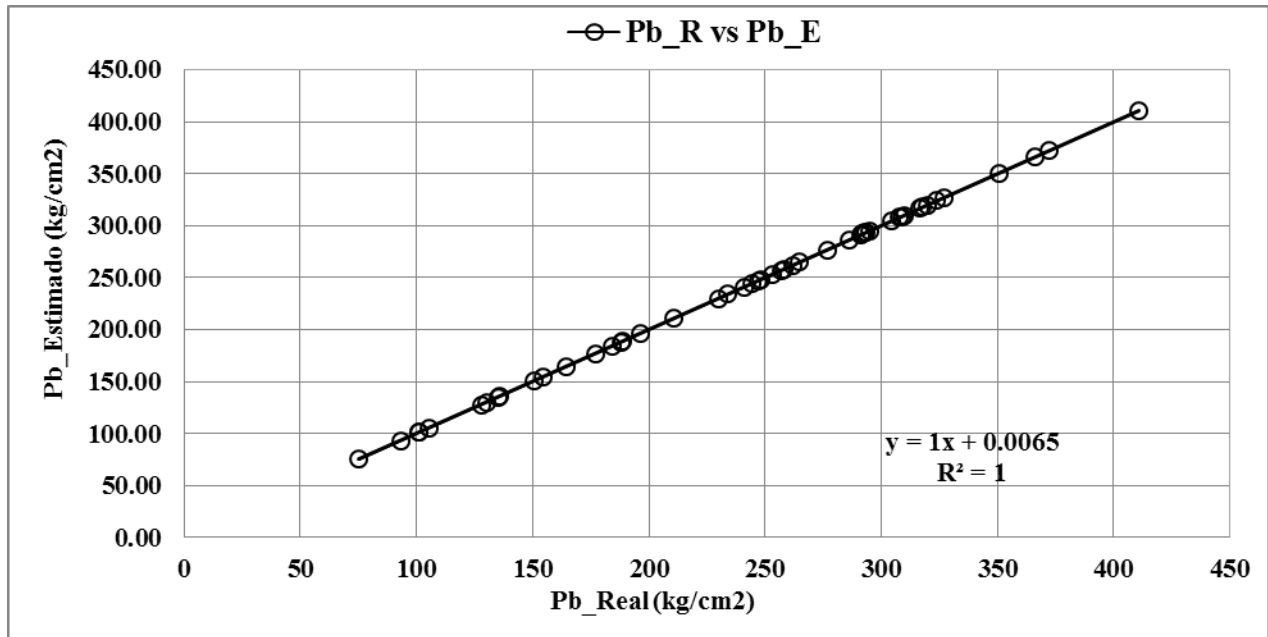


Figura 5.12 Comparación de Pb real vs Pb estimada por RNA para aceite negro.

5.5 Red Neuronal Artificial para la estimación de R_s de un aceite volátil

En la construcción de esta red se usaron 289 muestras de parámetros PVT de aceite volátil y la función de activación usada en cada capa fue la función *logsig*.

5.5.1 Estructura de la red

- 1). Esta red consta de 4 entradas (*temperatura del yacimiento, presión para $P \leq Pb$, densidad relativa del gas, densidad relativa del aceite*).
- 2). La salida de esta red es relación de solubilidad (R_s)
- 3). La estructura consiste en 4 entradas (capa 1), 7 neuronas en la capa 2, 6 neuronas en la capa 3, 5 neuronas en la capa 4 y una neurona en la capa de salida.
- 4). El entrenamiento se realizó con el algoritmo de Levenberg-Marquardt.

La tabla 5.7 muestra el rango de validez desde el mínimo al máximo valor a utilizar de esta red.

Tabla 5.7. Rangos de validez de RNA para la estimación de Pb en aceite negro.

Rango de validez		
	Mínimo	Máximo
Temperatura (C)	59.91	174
Presión (kg/cm2)	7	363
Densidad relativa del gas (aire=1)	0.0719	1.568
Densidad relativa del aceite.	0.2982	0.7845
Rs (m3/m3)	3.511	550

5.5.2 Algoritmo de RNA para la estimación de R_s en aceite volátil.

1). Evaluar

$$n_i^1 = \sum_{j=1}^4 w_{ij}^1 x_j + b_i^1$$

$$a_i^1 = f^1(n_i^1), \text{ para } i = 1, 2, \dots, 7.$$

2). Evaluar

$$n_k^2 = \sum_{i=1}^7 w_{ki}^2 a_i^1 + b_k^2$$

$$a_k^2 = f^2(n_k^2), \text{ para } k = 1, 2, \dots, 6.$$

3). Evaluar

$$n_l^3 = \sum_{k=1}^6 w_{lk}^3 a_k^2 + b_l^3$$

$$a_l^3 = f^3(n_l^3), \text{ para } l = 1, 2, \dots, 5.$$

4). Evaluar

$$n_1^4 = \sum_{l=1}^5 w_{1l}^4 a_l^3 + b_1^4$$

$$a_1^4 = f^4(n_1^4)$$

$$R_s = a_1^4$$

Las Fig. 5.13 y 5.14 muestran las matrices de los pesos sinápticos y bias para estimación del parámetro R_s para aceite volátil.

w1=	10.2269	-8.8054	6.7042	-26.4076		
	-7.6267	6.4277	-10.4029	24.3088		
	4.0946	-7.8465	6.3051	-18.6232		
	-7.5735	6.4576	-10.4651	24.5063		
	4.0466	-10.8469	4.1271	10.7956		
	-1.2943	12.4384	-13.0196	-10.1196		
	-53.4022	-9.5533	82.1101	-43.0824		
w2=	24.3956	533.8441	-14.1846	-525.0040	-6.8411	-33.7982
	20.8806	-208.4535	-40.2542	300.9733	-10.5023	-25.4587
	15.9585	-84.8046	-3.9294	115.5604	-0.3153	-16.3154
	2.7419	46.3826	-1.4932	-45.2152	-0.3956	-1.3426
	-4.1886	-125.7472	3.6408	125.5750	1.5387	4.4865
	24.7989	544.7870	-14.5042	-535.8899	-6.9477	-34.0769
w3=	124.0102	0.3361	-0.2768	248.3886	-59.5005	-118.8271
	43.6095	-0.0418	-0.4670	62.5681	6.3532	-46.7282
	-824.3994	2.2953	-0.2629	-3866.1438	287.6059	1014.7678
	76.7487	-126.3508	-2.9838	458.2592	142.8853	-68.4434
206.7204	0.1454	-0.8565	-118.0124	14.4564	-217.1070	
w4=	99.1786	182.5115	-63.3520	-34.6733	-65.7961	

Figura 5.13 Pesos sinápticos de RNA para la estimación de R_s en aceite volátil.

b1=	11.81204	b3=	-2.35334
	-11.85084		-0.18313
	10.77075		-0.99587
	-12.12204		113.66562
	-3.52262		-1.19520
	1.60449		
	21.96894		
b2=	-2.87603	b4=	-16.56277
	11.52773		
	-8.69217		
	-5.11360		
	-3.26574		
	-2.90039		

Figura 5.14 Bias de RNA para la estimación de R_s en aceite volátil.

5.5.3 Resultados

Se creó una función en Excel que evalúa R_s con la cual se comparan los datos reales vs los datos estimados por la red con los siguientes resultados, Fig. 5.15.

F_AV_Rs(T,P,DrGas,DrAceite): Esta función recibe como entrada la temperatura del yacimiento, presión de interés $P \leq Pb$, densidad relativa del gas, densidad relativa del aceite y tiene como salida la relación de solubilidad.

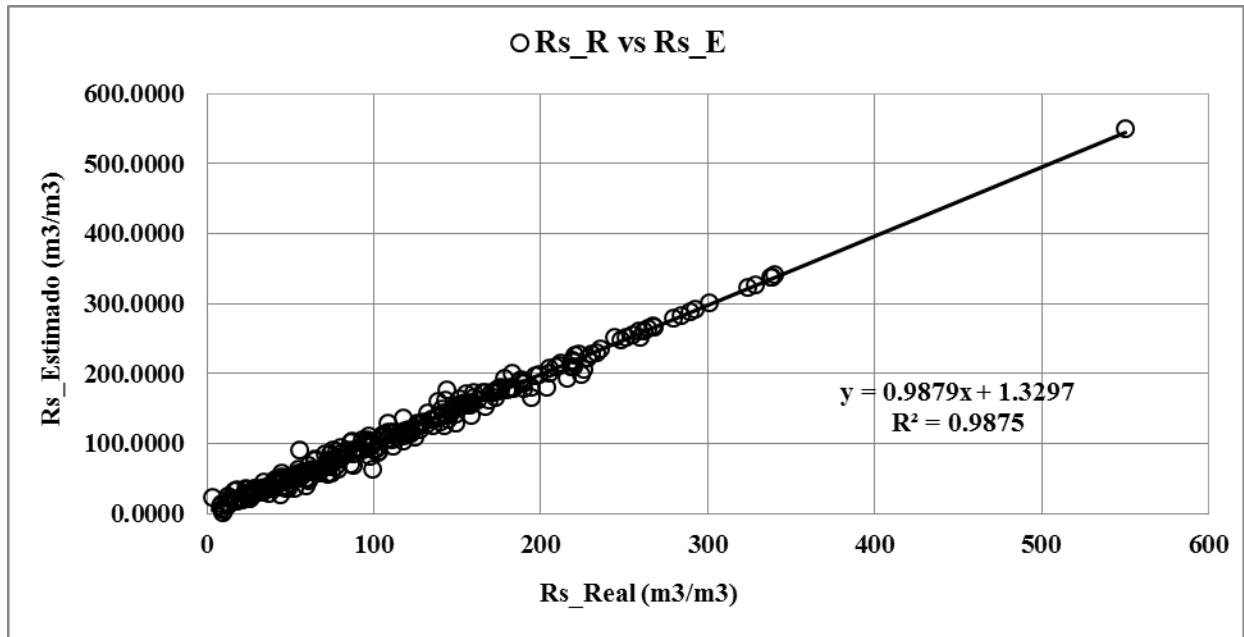


Figura 5.15. Comparación de R_s real vs R_s estimada por RNA para aceite volátil.

5.6 Red Neuronal Artificial para la estimación de B_{ob} de un aceite volátil

En la construcción de esta red se usaron 55 muestras de parámetros PVT de aceite negro y la función de activación usada en cada capa fue la función *logsig*.

5.6.1 Estructura de la red

- 1). Esta red consta de 4 entradas (*temperatura del yacimiento, R_s para presiones para $P \geq P_b$, densidad relativa del gas, densidad relativa del aceite*).
- 2). La salida de esta red es el factor de volumen del aceite (*B_{ob}*)
- 3). La estructura consiste en 4 entradas (capa 1), 6 neuronas en la capa 2, 5 neuronas en la capa 3 y una neurona en la capa de salida.
- 4). El entrenamiento se realizó con el algoritmo de Levenberg-Marquardt.

La tabla 5.8 muestra el rango de validez desde el mínimo al máximo valor a utilizar de esta red.

Tabla 5.8. Rangos de validez de RNA para la estimación de *Bob* en aceite volátil.

<u>Rango de validez</u>	Mínimo	Máximo
Temperatura (C)	59.91	174
Rsb (m3/m3)	47.7	679.6
Densidad relativa del gas (aire=1)	0.627	1.196
Densidad relativa del aceite.	0.3902	0.8742
Bob (m3/m3)	1.1556	3.571

5.6.2 Algoritmo de RNA para la estimación de *Bob* en aceite volátil.

1). Evaluar

$$n_i^1 = \sum_{j=1}^4 w_{ij}^1 x_j + b_i^1$$

$$a_i^1 = f^1(n_i^1), \text{ para } i = 1, 2, \dots, 6.$$

2). Evaluar

$$n_k^2 = \sum_{i=1}^6 w_{ki}^2 a_i^1 + b_k^2$$

$$a_k^2 = f^2(n_k^2), \text{ para } k = 1, 2, \dots, 5.$$

3). Evaluar

$$n_1^3 = \sum_{k=1}^5 w_{1k}^3 a_k^2 + b_1^3$$

$$a_1^3 = f^3(n_1^3)$$

$$B_{ob} = a_1^3$$

Las Fig. 5.16 y 5.17 muestran las matrices de los pesos sinápticos y bias para estimación del parámetro *Bob* para aceite volátil.

w1=	-5.0174	-1.1931	1.6698	4.1766		
	-6.9049	11.7395	-43.5334	7.5045		
	-5.5133	-8.5688	19.9912	0.7961		
	3.8921	-3.2021	-3.1924	-3.9584		
	10.9014	-8.9790	-6.8616	0.7406		
	1.5563	3.4637	11.5516	-0.3468		
w2=	-14.9570	20.3106	13.4829	-10.0067	10.2321	9.8800
	-6.7611	1.0006	-0.3425	3.8841	-0.5542	1.4241
	7.2394	2.5018	3.9338	-3.1885	6.1572	0.3220
	3.9094	-16.2948	0.3579	10.0861	7.0865	-5.5760
	6.3235	0.8951	1.2804	2.5945	1.0729	4.2552
w3=	-10.8014	7.3337	-23.2717	11.4871	3.9234	

Figura 5.16 Pesos sinápticos de RNA para la estimación de *Bob* en aceite volátil.

b1=	2.9041
	25.7247
	-4.9331
	7.4056
	-0.4738
	-9.6525
b2=	-17.9478
	4.0083
	-4.3286
	7.2868
	-2.2884
b3=	1.3361

Figura 5.17 Bías de RNA para la estimación de *Bob* en aceite volátil.

5.5.3 Resultados

Se creó una función en Excel que evalúa el *Bob* con la cual se comparan los datos reales vs los datos estimados por la red con los siguientes resultados, Fig. 5.18.

F_AV_Bob(T,Rsb,DrGas,DrAceite): Esta función recibe como entrada la temperatura del yacimiento, R_s a presiones $P \geq P_b$, densidad relativa del gas, densidad relativa del aceite y tiene como salida el factor de volumen de aceite a presión de burbujeo.




Figura 5.18 Comparación de *Bob* real vs *Bob* estimada por RNA para aceite volátil.

5.7 Red Neuronal Artificial para la estimación de C_o de un aceite volátil

En la construcción de esta red se usaron 272 muestras de parámetros PVT de aceite volátil y la función de activación usada en cada capa fue la función *logsig*.

5.7.1 Estructura de la red

- 1). Esta red consta de 4 entradas (*presión de interés $P > P_b$, temperatura del yacimiento, densidad relativa del gas, R_s a $P > P_b$, densidad relativa del aceite*).
- 2). La salida de esta red es la compresibilidad del aceite (C_o)
- 3). La estructura consiste en 4 entradas (capa 1), 7 neuronas en la capa 2, 6 neuronas en la capa 3, 5 neuronas en la capa 4 y una neurona en la capa de salida.
- 4). El entrenamiento se realizó con el algoritmo de Levenberg-Marquardt.

La tabla 5.9 muestra el rango de validez desde el mínimo al máximo valor a utilizar de esta red.

Tabla 5.9. Rangos de validez de RNA para la estimación de C_o en aceite volátil.

<u>Rango de validez</u>	Mínimo	Máximo
Presión (kg/cm ²)	47	984
Temperatura (C)	59.91	173
Rs (m ³ /m ³)	178.51	679.6
Densidad relativa del aceite.	0.3906	0.7146
C_o (1/kg/cm ²)	0.000134	0.0008605

5.7.2 Algoritmo de RNA para la estimación de C_o en aceite volátil.

1). Evaluar

$$n_i^1 = \sum_{j=1}^4 w_{ij}^1 x_j + b_i^1$$

$$a_i^1 = f^1(n_i^1), \text{ para } i = 1, 2, \dots, 7.$$

2). Evaluar

$$n_k^2 = \sum_{i=1}^7 w_{ki}^2 a_i^1 + b_k^2$$

$$a_k^2 = f^2(n_k^2), \text{ para } k = 1, 2, \dots, 6.$$

3). Evaluar

$$n_l^3 = \sum_{k=1}^6 w_{lk}^3 a_k^2 + b_l^3$$

$$a_l^3 = f^3(n_l^3), \text{ para } l = 1, 2, \dots, 5.$$

4). Evaluar

$$n_1^4 = \sum_{l=1}^5 w_{1l}^4 a_l^3 + b_1^4$$

$$a_1^4 = f^4(n_1^4)$$

$$C_o = a_1^4$$

Las Fig. 5.19 y 5.20 muestran las matrices de los pesos sinápticos y bias para estimación del parámetro C_o para aceite volátil.

w1=	-8.2597	7.5561	9.7653	15.9346		
	1.1299	5.1357	2.7092	17.5641		
	5.4416	-16.1567	-2.2235	18.7025		
	2.2881	5.9135	4.7917	11.0415		
	8.4742	2.9528	5.5744	-1.3543		
	2.3887	-18.1443	4.5583	26.5375		
	-1.9494	-39.4586	-15.8523	-18.7260		
w2=	1.3897	-0.3890	-4.2301	-1.2274	0.3608	-5.8785
	0.4709	-5.3029	-0.0006	2.4270	-0.0158	-0.9610
	-0.6117	-10.9766	-28.8146	0.6306	1.6607	34.3176
	-1.7209	5.2557	-1.5128	-1.4242	0.5953	0.3447
	-10.5086	-23.2535	0.3571	-2.3030	2.5596	-6.3910
	-2.1947	-21.2876	-0.4783	-4.9557	-1.6209	8.4654
w3=	3.4569	7.4194	-10.5538	-1.9431	-0.4849	14.2453
	-1.4428	2.3682	-27.2887	4.0198	-7.8805	-5.2884
	2.2818	-31.3145	36.6250	-0.9219	6.9388	12.2155
	2.1509	-2.9787	-7.4662	1.8817	17.0890	19.8264
	2.3490	-16.4362	22.8674	2.8722	2.5731	-25.4867
w4=	17.1223	9.0747	-6.4586	-2.1343	17.6044	

Figura 5.19 Pesos sinápticos de RNA para la estimación de C_o en aceite volátil.

b1=	-21.2295	b2=	-9.1308
	-24.0480		-2.5714
	-0.8376		-3.9903
	-3.2729		-9.4289
	-9.1182		7.4990
	-5.9448		6.6627
	52.7430		
b3=	-5.9571	b4=	-15.2612
	8.9372		
	-37.7993		
	-10.7602		
	8.7621		

Figura 5.20 Bías de RNA para la estimación de C_o en aceite volátil.

5.7.3 Resultados

Se creó una función en Excel que evalúa C_o con la cual se comparan los datos reales vs los datos estimados por la red con los siguientes resultados, Fig. 5.21.

F_AV_Co(P,T,Rs,DrAceite): Esta función recibe como entrada la presión para $P > P_b$, temperatura del yacimiento, R_s a $P > P_b$, densidad relativa del aceite y tiene como salida la compresibilidad del aceite.




Figura 5.21 Comparación de C_o real vs C_o estimada por RNA para aceite volátil.

5.8 Red Neuronal Artificial para la estimación de P_b de un aceite volátil

En la construcción de esta red se usaron 53 muestras de parámetros PVT de aceite volátil y la función de activación usada en cada capa fue la función *logsig*.

5.8.1 Estructura de la red

- 1). Esta red consta de 4 entradas (*temperatura del yacimiento, R_s a $P \geq P_b$, densidad relativa del gas, densidad relativa del aceite*).
- 2). La salida de esta red es el factor de volumen del aceite (P_b)
- 3). La estructura consiste en 4 entradas (capa 1), 6 neuronas en la capa 2, 5 neuronas en la capa 3 y una neurona en la capa de salida.
- 4). El entrenamiento se realizó con el algoritmo de Levenberg-Marquardt.

La tabla 5.10 muestra el rango de validez desde el mínimo al máximo valor a utilizar de esta red.

Tabla 5.10 Rangos de validez de RNA para la estimación de Pb en aceite volátil.

Rango de validez	Mínimo	Máximo
Temperatura (C)	60	174
Rsb (m3/m3)	47.7	679.6
Densidad relativa del gas (aire=1)	0.705	1.058
Densidad relativa del aceite.	0.39	0.8742
Pb (kg/cm2)	122.4	399.4

5.8.2 Algoritmo de RNA para la estimación de Pb en aceite volátil.

1). Evaluar

$$n_i^1 = \sum_{j=1}^4 w_{ij}^1 x_j + b_i^1$$

$$a_i^1 = f^1(n_i^1), \text{ para } i = 1, 2, \dots, 6.$$

2). Evaluar

$$n_k^2 = \sum_{i=1}^6 w_{ki}^2 a_i^1 + b_k^2$$

$$a_k^2 = f^2(n_k^2), \text{ para } k = 1, 2, \dots, 5.$$

3). Evaluar

$$n_1^3 = \sum_{k=1}^5 w_{1k}^3 a_k^2 + b_1^3$$

$$a_1^3 = f^3(n_1^3)$$

$$P_b = a_1^3$$

Las Fig. 5.22 y 5.23 muestran las matrices de los pesos sinápticos y bias para estimación del parámetro Pb para aceite volátil.

w1=	-22.6243	4.6281	5.3203	-9.2834		
	-6.3700	-11.6817	-6.2688	-23.6164		
	4.9549	-18.7819	24.6658	6.3311		
	-13.5428	-13.8009	32.9339	30.6981		
	2.4851	-5.6134	-7.0823	-26.1875		
	-13.9000	-0.3390	-13.3672	4.9675		
w2=	-2.1532	-3.2824	0.6926	-1.9482	2.2918	6.9426
	-16.1488	1.9785	1.6877	17.5410	26.2827	5.7841
	-13.2232	-23.8819	-50.7348	12.4100	26.9925	10.9302
	-11.9783	-1.8399	-1.6579	2.7797	-1.2070	11.1601
	9.2819	-19.1805	-10.1220	3.2308	-6.0590	-9.5309
w3=	-15.4551	-10.6497	20.5790	13.5316	-11.2357	

Figura 5.22 Pesos sinápticos de RNA para la estimación de Pb en aceite volátil.

b1=	14.0923
	31.1998
	-21.8000
	-19.4914
	19.8060
	16.5825
b2=	1.6673
	-18.7243
	-2.3671
	-5.0463
b3=	7.8840
	12.7225

Figura 5.23 Bias de RNA para la estimación de Pb en aceite volátil.

5.8.3 Resultados

Se creó una función en Excel que evalúa Pb con la cual se comparan los datos reales vs los datos estimados por la red con los siguientes resultados, Fig. 5.24.

F_AV_Pb(T,Rsb,DrGas,DrAceite): Esta función recibe como entrada la temperatura del yacimiento, R_s a $P > P_b$, densidad relativa del gas, densidad relativa del aceite y tiene como salida la presión de burbuja.




Figura 5.24 Comparación de P_b real vs P_b estimada por RNA para aceite volátil.

Conclusiones y recomendaciones

El uso de las redes neuronales es efectivo siempre y cuando sea utilizado de manera adecuada, tomando en cuenta lo siguiente:

- 1.- Tipo de aceite a analizar y región.
- 2.- Información debidamente validada.
- 3.- Rangos de validez de cada parámetro de entrada.
- 4.- Entrenamiento adecuado de la red para que exista una congruencia entre los datos de entrada con la salida estimada.
- 5.- Es necesario hacer ensayos del comportamiento del número de capas y neuronas a utilizar para entrenar la red y obtener el mejor ajuste, es decir con el mínimo error (error medio cuadrático).
- 6.- Comparar parámetro real vs estimado.
- 7.- Se deduce que mediante una Red Neuronal Artificial (RNA), entrenada con información PVT validada, es posible estimar la presión de burbuja, relación solubilidad, compresibilidad del aceite y factor de volumen del aceite a la presión de burbuja, a partir de información básica de pozo, por lo que se cumple el objetivo de la tesis.
- 8.- Los resultados son satisfactorios ya que se ajustan en gran medida a cada parámetro y el error que se presenta es de $1 * 10^{-4}$.
- 9.- Es recomendable usar datos validados; en caso de que al validar se obtengan pocos valores por el control de calidad del PVT se pueden usar los datos duros y posteriormente validar cada parámetro, esto porque al validar los PVT's regularmente hay inconsistencias de tal manera que no pasan todas las pruebas de validación.
- 10.- Al no disponer de información experimental pueden usarse correlaciones para determinar las propiedades físicas de los fluidos, sin embargo estas correlaciones están basadas en campos de

otros países por lo que al hacer uso de redes con campos de México se tendrá la certeza de que los parámetros están dentro de los rangos de validez y el valor obtenido tiene un margen mínimo de error.

11.- Se presentan las arquitecturas, pesos sinápticos y bias de las redes con el objetivo de que el usuario pueda reproducir en otro lenguaje.

12.- Para el caso práctico del uso de los simuladores numéricos se pueden obtener una serie de datos obtenidos de las redes por ejemplo viscosidad, compresibilidad, etc. Haciendo una combinación de las redes vs simulador, es decir que a partir del parámetro obtenido de la red (Co) se genere un conjunto de presiones.

13.- Con la red neuronal se generan un conjunto de datos $(P, Co(P))$ y $(P, Co(P))$.

Bibliografía

- 1 A. Datta-Gupta, D.W. Vasco, J.C.S Long. Junio 1997. "On the sensitivity and spatial resolution of transient pressure and tracer data for heterogeneity characterization". Paper SPE-30589-Pa. <http://dx.doi.org/10.2118/30589-pa>. volume 12.
- 2 A.E. Hoffman, J.S. Crump, and C.R. Hocott "Equilibrium Constants for a Gas-Condensate System". SPE-219-G. <http://dx.doi.org/10.2118/219-G>.
- 3 A.O. Kumoluyi. 1994. "Higher-Order Neural Networks in Petroleum Engineering". Paper SPE-27905-MS. <http://dx.doi.org/10.2118/27905-MS>.
- 4 Adel M. Elsharkawy. 1998. "Modeling the Properties of Crude Oil and Gas Systems Using RBF Network". Paper SPE-49961-MS. <http://dx.doi.org/10.2118/49961-MS>.
- 5 Ævdal Geir, Trond Mannseth, Erlend H. Vefring. 2002. "Near-Well Reservoir Monitoring Through Ensemble Kalman Filter". Paper SPE-75235-MS. <http://dx.doi.org/10.2118/75235-MS>.
- 6 Ali Danesh. 1998. "PVT and phase behavior of petroleum reservoir fluids". Volume 47. Elsevier. X, XIV. ISBN-13: 978-0-444-82196-6.
- 7 Almeahiddeb, " R.A., 1997: "Improved PVT correlations for UAE Crude Oils," presented at the Middle East Oil Conference and Exhibition held in Manam, Bahrain. Paper SPE 37691 .
- 8 Al-Shammasi, A.A., 1999: "Bubble point pressure and oil formation volume factor correlations." Presented at the Middle East Oil Show held in Bahrain, Paper SPE 53185.
- 9 Al-Zahaby A., El-Banbi A and Sayyoub M, h., 2012: "Guidelines for selecting Appropriate PVT correlation for Black Oils" .Presented at the North Africa Technical conference and exhibition Cairo, Egypt. Paper SPE 150650.
- 10 Avitua y Vargas. 2014. "Validación de muestreos de fluidos petroleros para su representatividad al análisis y simulación PVT". Tesis . UNAM. México, D.F.
- 11 C.S. Kabir and N.J. Young. 2001. "Handling Production-Data Uncertainty in History Matching: The Meren Reservoir Case Study". Paper SPE-71621-MS. <http://dx.doi.org/10.2118/71621-MS>.
- 12 Casacuberta J.M., Grandbastien M.A. 2012. "Plant transposable elements". ISBN 978-3-642-31841-2.

- 13 Castillo F. 2005. "Validación de análisis PVT composicionales". Tesis . UNAM. México, D.F.
- 14 Curtis Hayes Whitson and| Stein Borre Torp. 1981 "Evaluating Constant Volume Depletion Data". SPE-10067-MS. <http://dx.doi.org/10.2118/10067-MS>.
- 15 Dake, L. P. (1998). "Fundamentals of Reservoir Engineering". 17th Edition. Elsevier. Chapter 1.
- 16 De Ghetto, G., et al., 1994: "Reliability Analysis on PVT Correlations," Presented at the European Petroleum Conference held in London, U.K. Paper SPE 28904.
- 17 Díaz C. y Pedraza J. 2012. "Análisis de sensibilidades para correlaciones PVT: Aplicación a aceites negros". Tesis. Universidad Industrial de Santander. Bucaramanga, Colombia.
- 18 Dominique Bourdet , Alain C. Gringarten. 1980. "Determination Of Fissure Volume And Block Size In Fractured Reservoirs By Type-Curve Analysis". Paper SPE-9293-MS. <http://dx.doi.org/10.2118/9293-MS>.
- 19 Drohm, J.K, Trengove, R.D.; Goldthorpe, W.H. 1988 "On the Quality of data from Standard Gas-Condensate PVT Experiments", Paper SPE 17768.
- 20 E.A. Osman ,O.A. Abdel-Wahhab y M.A. Al-Marhoun .2001. "Prediction of Oil PVT Properties Using Neural Networks". Paper SPE-68233-MS. <http://dx.doi.org/10.2118/68233-MS>.
- 21 El-Sayed A. Osman y Muhammad Ali Al-Marhoun . 2005. "Artificial Neural Networks Models for Predicting PVT Properties of Oil Field Brines". SPE-93765-MS. <http://dx.doi.org/10.2118/93765-MS>.
- 22 Eyton, D.G.P. 1987. "Practical Limitations in obtainin PVT data for gas condensate Systems", presentado por el "fifth Middle East Show", Manama, Bahrain. Paper SPE 15765.
- 23 Fashard,F.F., Leblanc, J.L. and Garber, J. D., 1996:"Empirical PVT Correlations for colombian crude oil".Presented at the Fouth Latin American and Caribbean Pet. Eng. Conf.held Port-of Spain, Trinidad & Tobago. Paper SPE 36105.
- 24 Fatemeh Alimadadi , Amin Fakhri ,Diako Farooghi , Hossein Sadati. 2011. "Using a Committee Machine With Artificial Neural Networks To Predict PVT Properties of Iran Crude Oil". Paper SPE- 141165-PA. <http://dx.doi.org/10.2118/141165-PA>.
- 25 Fawzi M Guehria, Leslie G Thompson, Albert C Reynolds, et al. 1990. "A robust algorithm for determining hydrocarbon pvt properties using a generalized eos". In CIM/SPE International Technical Meeting. Society of Petroleum Engineers.

- 26 González Y. 2014. “Análisis, desarrollo, selección y calibración de correlaciones PVT de aceite saturado para campos petroleros de México”. Tesis. UNAM. México, D.F.
- Hussam M. Goda, Eissa M. El-M Shokir, Khaled A. Fattah y Mohamed H. Sayyoub.
27 2003.” Prediction of the PVT Data using Neural Network Computing Theory”. Paper SPE-85650-MS. <http://dx.doi.org/10.2118/85650-MS>.
- Jose L. Bashbush et al. 1981. “A method to determine k-values from laboratory data
28 and its applications”. In SPE annual Technical conference and exhibition, society of petroleum engineers, IX, 116. SPE 10127.
- Julius U. Akpabio, Emmanuel E. Udofia and Michael Ogbu. 2014. "PVT Fluid
29 Characterization and Consistency Check for Retrograde Condensate Reservoir Modeling". SPE-172359-MS.
- K.H. Coats & G.T. Smart . 1986. "Application of a Regression-Based EOS PVT
30 Program to Laboratory Data". SPE-11197-PA. <http://dx.doi.org/10.2118/11197-PA>.
- Khan, M.S.; Hatamian, H. 1991 “Improved Method of compositional analysis of liquid at
31 high-pressure condition in PVT Study of gas condensate”, Artículo SPE 21429.
- Labedi, R. M., 1990. “ Use of production Data to estimate the saturation pressure,
32 solution GOR and Chemical composition of reservoir fluids,” Presented at the Latin America Pet. Held in Rio de Janeiro. Paper SPE 21164.
- Laurent Didier Alessio, Laurent Marc Bourdon, Spencer Coca. 2005 “Experimental
33 Design as a Framework for Multiple Realisation History Matching: F6 Further Development Studies”. Paper Artículo SPE-93164-MS. <http://dx.doi.org/10.2118/93164-MS>.
- M.F. Briones y G.A. Rojas . 1994. “Application of Neural Networks in the Prediction
34 of Reservoir Hydrocarbon Mixture Composition From Production Data”. Paper SPE-28598-MS. <http://dx.doi.org/10.2118/28598-MS>.
- M.F. Briones , G.A. Rojas , J.A. Moreno, O. Hidalgo. 1994. “Thermodynamic
35 Characterization of Volatile Hydrocarbon Reservoirs by Neuronal Networks”. Paper SPE-27027-MS. <http://dx.doi.org/10.2118/27027-MS>.
- Marcano Z. et al. 2009-2010. “Isolation of invasive strains of neisseria meningitides,
36 Serogroups B and Y, in Cumana, 2009-2010”. ISSN 00755222.
- McCain, W.D. Jr. (1989). The Properties of Petroleum Fluids (2da ed.). Tulsa, OK:
37 Pennwell Books. Capítulo 7.
- McCain, W.D., 2002 “Analysis of black oil PVT reports revisited,” Presented at the
38 SPE Annual technical conference and Exhibition, San Antonio Texas. Paper SPE 77386.

- 39 Miloslav Pekar, Ivan Samohy'l. 2014. "The Thermodynamics of Linear Fluids and Fluid Mixtures". DOI 10.1007/978-3-319-02514-8.
- 40 Mirta Cordoba De Galacho, Néstor Galacho. 2008. "Redes Neuronales Artificiales (RNA) en las geociencias e ingeniería de yacimientos de petróleo y gas". N. 686970.
- 41 N. Varotsis , V. Gaganis, J. Nighswander y P. Guieze.1999. "A Novel Non-Iterative Method for the Prediction of the PVT Behavior of Reservoir Fluids". Paper SPE-56745-MS. <http://dx.doi.org/10.2118/56745-MS>.
- 42 Osman, Wahhab and Al-marhoun (2001). "Prediction of oil PVT properties using neural networks".Spe-68233.
- 43 Paris, M. 2009. "Fundamentos de Ingeniería de Yacimientos". ISBN: 978-980-12-3048-9.
- 44 Pedro Ponce Cruz. 2010. " Inteligencia artificial con aplicaciones a la ingeniería". ISBN: 978-607-7854-83-8. Pags. 25-26.
- 45 Pedro Ponce Cruz. 2010. " Inteligencia artificial con aplicaciones a la ingeniería". ISBN: 978-607-7854-83-8. Pags. 3-4.
- 46 Pedro Ponce Cruz. 2010. " Inteligencia artificial con aplicaciones a la ingeniería". ISBN: 978-607-7854-83-8. Pags. 7-10.
- 47 Petrosky, G.E. Jr. And Farshad, F. F., 1993 "Pressure- Volumen-Temperatura Correlations for Gulf of México," Presented at the 68th Annual technical conference and exhibition, Houston, Texas. Paper SPE 26644.
- 48 R.B. Gharbi and A.M. Elsharkawy. 1997. "Neural Network Model for Estimating The PVT Properties of Middle East Crude Oils". Paper SPE-37695-MS. <http://dx.doi.org/10.2118/37695-MS>.
- 49 Reyes M. 2015. "Comportamiento PVT de aceites pesados y su efecto en la hidrodinámica del flujo en oleogasoductos". Tesis . UNAM. México, D.F.
- 50 Ridha B. Gharbi and Adel M. Elsharkawy. 1997. "Universal Neural Network Based Model for Estimating The PVT Properties of Crude Oil Systems". Paper SPE-38099-MS. <http://dx.doi.org/10.2118/38099-MS>.
- 51 Ridha B.C. Gharbi (Kuwait U.)| Adel M. Elsharkawy (Kuwait U.). 1999. "Neural Network Model for Estimating the PVT Properties of Middle East Crude Oils". Paper SPE-56850-PA. <http://dx.doi.org/10.2118/56850-PA>.

- 52 Ruijian Li, A.C. Reynolds, D.S. Oliver. 2001. "History Matching of Three-Phase Flow Production Data", Paper SPE -66351-MS. <http://dx.doi.org/10.2118/66351-MS>.
- 53 S.A. Khan ,M.A. Al-Marhoun, S.O. Duffuaa y S.A. Abu-Khamsin .1987. "Viscosity Correlations for Saudi Arabian Crude Oils". Paper SPE 15720-MS. <http://dx.doi.org/10.2118/15720-MS>.
- 54 Samaniego F., Bashbush J.L., León G.A., Mazariegos U.C., Corona B.A., Castillo P.P.F. (2004). "On the validation of PVT compositional laboratory experiments". SPE n° 91505.
- 55 Trengove, R.D., Hann, J.H y States, J.R.1991. "The impact of pvt Dta Quality on hydrocarbon Recovery Predictions", Artículo SPE. 22988.
- 56 W.T. Peake, M. Abadah, L. Skander. 2005. "Uncertainty Assessment using Experimental Design, Minagish Oolite Reservoir". Paper SPE-91820-MS. <http://dx.doi.org/10.2118/91820-MS>.
- 57 Whitson, C. H. y Torp, S. B. (1983, Marzo). Evaluating Constant-Volume Depletion Data. (Documento No. 10067). Texas: SPE.