



INSTITUTO TECNOLÓGICO SUPERIOR DE MISANTLA

DISEÑO DE UN SOFTWARE A PARTIR DE REDES NEURONALES ARTIFICIALES (RNA) PARA CALCULAR EL FACTOR VOLUMÉTRICO Y LA VISCOSIDAD DE UN ACEITE

TESIS

PARA OBTENER EL TÍTULO DE:
INGENIERO PETROLERO

P R E S E N T A

**ALEXANDRA MONSERRAT GONZÁLEZ
LAGUNES**

ASESOR PRINCIPAL: DR. DAVID REYES GONZÁLEZ
COASESOR: ING. FRANCISCO JAVIER FERNÁNDEZ
DOMÍNGUEZ

MISANTLA, VERACRUZ

FEBRERO, 2024



INSTITUTO TECNOLÓGICO SUPERIOR DE MISANTLA
AUTORIZACIÓN DE IMPRESIÓN DE TRABAJO DE TITULACIÓN

FECHA: 26 DE FEBRERO DEL 2024
ASUNTO: AUTORIZACIÓN DE IMPRESIÓN

Por medio de la presente hago constar que el (la) C:

GONZALEZ LAGUNES ALEXANDRA MONSERRAT

Pasante de la carrera de **INGENIERÍA PETROLERA** con no. de Control **192T0767** ha cumplido satisfactoriamente con lo estipulado por el **Manual de Procedimientos para la Obtención del Título Profesional de Licenciatura** bajo la opción **Titulación Integral (TESIS PROFESIONAL)**

Por tal motivo se **AUTORIZA** la impresión del tema titulado:

“DISEÑO DE UN SOFTWARE A PARTIR DE REDES NEURONALES ARTIFICIALES (RNA) PARA CALCULAR EL FACTOR VOLUMÉTRICO Y LA VISCOSIDAD DE UN ACEITE”

Dándose un plazo no mayor de un mes de la expedición de la presente a la solicitud del Acto de Recepción para la obtención del Título Profesional.

ATENTAMENTE

LIC. JANETH LÓPEZ CARDEÑA
COORDINADORA DE ESTUDIOS PROFESIONALES



Archivo.

Gracias a los que se fueron y dejaron el deseo de ser mejor, a los que perduran y me mantienen viva; sobre todo, a los que hicieron esto posible y aportaron más que conocimiento.

Para mí, como prueba de subsistencia y recuerdo de ser fiel partidaria a la idea:

“No hay placer en tener nada a su manera, solo en tenerlo como se lo merece”

– Jane Austen.

RESUMEN

La mayoría de cálculos en ingeniería petrolera requiere datos precisos de propiedades como la viscosidad y el factor volumétrico para una variedad de aplicaciones críticas como pruebas de pozos, cálculos de materiales y estimaciones de reservas; sin embargo, las herramientas convencionales utilizadas para estos cálculos presentan limitaciones significativas debido a que no son aplicables universalmente y a que son un tanto costosas, lo que conduce a grandes errores cuando se aplican a diferentes entornos, más cuando no hay personal especializado disponible en los laboratorios.

Ante estos desafíos, surge la necesidad de explorar enfoques alternativos más precisos y eficientes. Las redes neuronales artificiales se han presentado como una solución prometedora debido a su capacidad para captar la no linealidad de los sistemas y adaptarse a medida que se disponen de más datos. Estas redes tienen la ventaja sobre las técnicas convencionales de regresión lineal y no lineal, ya que pueden ajustarse con mayor flexibilidad y precisión.

En un sector donde la precisión en la estimación de propiedades como el factor volumétrico y la viscosidad es esencial, las redes neuronales ofrecen una herramienta poderosa para superar desafíos complejos por lo que este proyecto busca aprovechar esta tecnología emergente para desarrollar un software que pueda calcular con mayor precisión el factor volumétrico y la viscosidad del petróleo. Para ello, se analizarán propuestas existentes sobre el uso de redes neuronales en la industria petrolera y se recopilarán datos experimentales para validar los resultados del software. El diseño del software se basará en esta información recopilada y se evaluará su capacidad para producir resultados precisos y confiables.

ÍNDICE

INTRODUCCIÓN	1
CAPÍTULO 1. GENERALIDADES DEL PROYECTO	3
1.1 Planteamiento del problema	3
1.2 Justificación	4
1.3 Objetivos	5
1.3.1 Objetivo general	5
1.3.2 Objetivos específicos	5
1.4 Hipótesis	6
1.5 Metodología	6
1.6 Alcances y limitaciones	7
1.6.1 Alcances	7
1.6.2 Limitaciones	7
CAPÍTULO 2. MARCO TEÓRICO Y ESTADO DEL ARTE	8
2.1 Marco teórico	8
2.1.1 Fluidos petroleros	8
2.1.2 Principales propiedades del petróleo	11
2.1.3 Medición y análisis de las propiedades del petróleo	17
2.1.4 Inteligencia Artificial	42

2.2 Estado del arte	60
2.2.1 Modelos de Redes Neuronales aplicados en la Ingeniería Petrolera para calcular las propiedades PVT de un aceite	60
CAPÍTULO 3. PROCEDIMIENTO	66
3.1 Familiarización y aprendizaje con Python	66
3.1.1 Librerías	67
3.1.2 Funciones de activación	68
3.1.3 Algoritmos de práctica	71
3.2 Generación de base de datos (dataset)	75
3.2.1 Adquisición de datos	75
3.2.2 Análisis de datos	76
3.3 Generación del modelo	78
3.3.1 Especificaciones técnicas	78
3.3.2 Red Neuronal para viscosidad	79
3.3.3 Red Neuronal para factor volumétrico	81
3.4 Propuesta de software para su ejecución	84
CAPÍTULO 4. RESULTADOS	87
4.1 Modelo para viscosidad	87
4.1.1 Resultados para el dataset de entrenamiento y el dataset de validación	87

4.1.2 Resultados de la estimación de la viscosidad para un aceite bajo saturado.	89
4.2 Modelo para factor volumétrico	90
4.2.1 Resultados para el dataset de entrenamiento y el dataset de validación	90
4.2.2 Resultados de la estimación del factor volumétrico para un aceite bajo saturado	93
4.3 Software diseñado	94
CONCLUSIONES	97
BIBLIOGRAFÍA.....	98
ANEXOS.....	103
a) Base de datos de un aceite bajo saturado para la viscosidad	103
b) Base de datos de un aceite bajo saturado para el factor volumétrico	104

ÍNDICE DE FIGURAS

Figura 2. 1. Diagrama de fase del aceite negro (Ahmed, 2007).	8
Figura 2. 2. Diagrama de fase del aceite volátil (Ahmed, 2007).	9
Figura 2. 3. Diagrama de fase del gas seco (Ahmed, 2007).....	10
Figura 2. 4. Diagrama de fase del gas retrógrado o condensado (Ahmed, 2007).....	11
Figura 2. 5. Diagrama de fase del gas húmedo (Ahmed, 2007).	11
Figura 2. 6. Representación gráfica de la prueba CCE (Ramirez, 2015).	19

Figura 2. 7. Representación gráfica de la prueba DL (Ramirez, 2015).	20
Figura 2. 8. Representación gráfica de la prueba CVD (Ramirez, 2015).	21
Figura 2. 9. Representación del flujo del crudo a través de separadores hasta el tanque de almacenamiento (Ramirez, 2015).	23
Figura 2. 10. Clasificación de los modelos de Machine Learning (Java T point, 2021). 44	
Figura 2. 11. Tipos de aprendizaje en inteligencia artificial (Beunza, 2020).	45
Figura 2. 12. Estructura general de una Red Neuronal Artificial (ATRIA INNOVATION, 2019)	49
Figura 2. 13. Estructura de una red neuronal biológica (MANUAL MSD, 2022).	50
Figura 2. 14. Estructura de una Red Neuronal Monocapa (Castro, 2006).	52
Figura 2. 15. Estructura de una Red Neuronal Multicapa (Castro, 2006).	54
Figura 2. 16. Representación del procesamiento de una Red Neuronal Convolutacional (MathWorks, 2022).	55
Figura 2. 17. Estructura de un nodo de una Red Neuronal Recurrente (Guru99, 2022).	57
Figura 2. 18. Estructura de una capa formada por los nodos de una RNN (Jordi Torres.AI, 2019).	58
Figura 2. 19. Estructura de una Red Neuronal Base Radial (Colmenares, s. f.).	59
Figura 2. 20. Comparación de la curva Bo prevista del petróleo en el yacimiento con la generada con PVT Expert (Varotsis, 1999).	61
Figura 2. 21. Comparación de la viscosidad establecida con los resultados de la red neuronal utilizada por Hajizadeth (Hajizadeh, 2007).	62

Figura 2. 22. Comparación de la precisión estadística de las correlaciones y la RNN utilizada por Ikiensikimama y Azubuike (Ikiensikimama & Azubuike, 2012).	63
Figura 2. 23. Comparación de la curva Bo generada por la RNA propuesta y algunas correlaciones convencionales (Hernández, 2017).....	64
Figura 2. 24. Comparación de la Rs establecida con la calculada por IntelliPVT (Oladipo & Jonathan, 2020).....	65
Figura 3. 1. Libros citados para la elaboración del modelo de red neuronal.	66
Figura 3. 2. Gráfica de la función sigmoide (Rubiales, 2020).	68
Figura 3. 3. Gráfica de la función tangente hiperbólica (Rubiales, 2020).....	69
Figura 3. 4. Gráfica de la función RELU (Rubiales, 2020).	70
Figura 3. 5. Ejemplos de cada conjunto seleccionados por la CNN (Mueller, 2021).	72
Figura 3. 6. Reporte de correos recibidos por la Red Bayesiana (Mueller, 2021).	73
Figura 3. 7. Gráfico de los datos predichos vs la regresión lineal, los valores para “w” y “b” generados por la regresión y el cálculo de “y” (Martínez, 2018).....	74
Figura 3. 8. Gráficas de caja para los datos del factor volumétrico.	76
Figura 3. 9. Gráficas de caja para los datos de viscosidad.....	77
Figura 3. 10. Histogramas para los datos de factor volumétrico.	77
Figura 3. 11. Histogramas para los datos de viscosidad.	78
Figura 3. 12. Interfaz propuesta para la ejecución de los modelos de Redes Neuronales Artificiales generados.....	85

Figura 3. 13. Ejecución de la selección de un archivo "excel" para cargarlo al software.	86
Figura 3. 14. Carga de datos en el software propuesto.	86
Figura 4. 1. Margen de error entre los datos generados (puntos azules) y los datos reales (línea naranja) para viscosidad.	88
Figura 4. 2. Comparación de los resultados obtenidos por la red neuronal generada (línea roja) y los datos reales con los que se entrenó el modelo (línea azul).	88
Figura 4. 3. Comparación de los resultados obtenidos por la red neuronal generada (línea roja) y los datos reales con los que se validó el modelo (línea azul).	89
Figura 4. 4. Gráfica comparativa de los valores de la viscosidad obtenidos por un reporte PVT y por el modelo de RNA desarrollado.	90
Figura 4. 5. Margen de error entre los datos generados (puntos azules) y los datos reales (línea naranja) para factor volumétrico.	91
Figura 4. 6. Comparación de los resultados obtenidos por la red neuronal generada (línea roja) y los datos reales con los que se entrenó el modelo (línea azul).	92
Figura 4. 7. Comparación de los resultados obtenidos por la red neuronal generada (línea roja) y los datos reales con los que se validó el modelo (línea azul).	92
Figura 4. 8. Gráfica comparativa de los valores del factor volumétrico obtenidos por un reporte PVT, por el modelo de RNA desarrollado y por la correlación de Standing (1981).	94
Figura 4. 9. Carga de datos y cálculo de la viscosidad.	95
Figura 4. 10. Carga de datos y cálculo del factor volumétrico.	95

Figura 4. 11. Cálculo de valores individuales para la viscosidad y el factor volumétrico.	96
--	----

ÍNDICE DE TABLAS

Tabla 4. 1. Valores estadísticos para la base de datos de factor volumétrico.	75
Tabla 4. 2. Valores estadísticos para la base de datos de la viscosidad.	75
Tabla 4. 3. Descripción general del modelo de red neuronal para viscosidad.	79
Tabla 4. 4. Descripción general del modelo de red neuronal para el factor volumétrico.	81
Tabla 4. 5. Resultados de las bases de datos para entrenamiento y validación del modelo para viscosidad.	87
Tabla 4. 6. Resultados de las bases de datos para entrenamiento y validación del modelo para factor volumétrico.	91
Tabla anexo a) Base de datos para viscosidad (Al-Marhoun, 1996).	103
Tabla anexo b) Base de datos para factor volumétrico (Al-Marhoun, 1996).	104

INTRODUCCIÓN

El análisis del comportamiento PVT (presión, volumen y temperatura) de los hidrocarburos se ha proclamado como una herramienta de gran importancia dentro de la industria petrolera, lo que ha promovido el constante desarrollo y actualización del mismo.

A lo largo del tiempo diversos autores se han dedicado a desarrollar fórmulas que permiten obtener dichos valores, ya sea para un cálculo de un aceite en general o para un tipo de aceite en específico; sin embargo, los métodos convencionales han mostrado limitaciones significativas, como inaplicabilidad en diferentes tipos de crudo, altos márgenes de error y costos asociados a pruebas de laboratorio, esto derivó la inquietud de explorar más herramientas que pudieran cubrir estas problemáticas como lo hace la Inteligencia Artificial (IA).

En la actualidad, la IA está presente en la mayoría de lados, campos y ámbitos, por lo que su migración al área de ingeniería no ha sido un problema, y gracias a la libertad de desarrollo y su amigabilidad con diversos tipos de sistemas, se optó por el uso de una de ellas para cubrir las necesidades mencionadas anteriormente: las Redes Neuronales Artificiales (RNA). Este proyecto acoge esas problemáticas y las cataloga como de mayor importancia por resolver y tiene como objetivo diseñar un software utilizando Redes Neuronales Artificiales para calcular el factor volumétrico y la viscosidad de un aceite como inicio e introducción a esta tecnología. Además, pretende sumarse a los trabajos confirmando que la implementación de esta inteligencia es eficaz, capaz y confiable como lo han mencionado diversos autores citados a lo largo de la investigación previa.

La idea de esta propuesta surgió de una ardua investigación y el deseo de aportar un poco más al campo de la industria petrolera por parte de Varotsis y su equipo en 1999, quienes se han enfocado a desarrollar métodos computacionales para predecir el comportamiento PVT de los fluidos con el fin de mejorar su derivación, ellos crearon un modelo propio denominado PVT Expert capaz de derivar las propiedades PVT de un aceite y gas condensado a partir de una RNA confirmando que el error calculado del

modelo es menor al generado cuando se implementan ecuaciones de estado; y por parte de Hernández que en 2017 propuso dos modelos de redes neuronales alimentados a partir de datos de pozos mexicanos para que fueran más compatibles con los tipos de aceite que se producen en el país, finalmente comparó sus resultados con otros modelos empíricos teniendo como conclusión que los modelos en donde se utilizaron las redes neuronales muestran mayor exactitud por lo que se ajustaba mejor a la curva real del fluido. Dicha motivación se ha extendido hasta hoy y se ha proclamado en una sola hipótesis: la implementación de Redes Neuronales Artificiales proporciona resultados más precisos y reduce el margen de error en el cálculo de propiedades PVT en comparación a las correlaciones convencionales.

A lo largo de este proyecto se encontrarán descritos los fundamentos de este tema en el capítulo 1, los cuales fueron primordiales para definir la finalidad y causa del trabajo; para poder llegar a la misma conclusión que los autores sumergidos en este ámbito, fue necesario analizar la información respectiva a la idea y familiarizarse con los métodos convencionales para el cálculo de propiedades PVT, proceso el cual se encuentra descrito en el capítulo 2. Posteriormente fue necesario recopilar y filtrar datos de propiedades PVT de un aceite y el desarrollo de una herramienta que hiciera fácil la manipulación de estos datos, por lo que se realizó la propuesta de un software que resolviera el inconveniente a lo largo del capítulo 3.

Finalmente, las propuestas de los modelos fueron agradables y cumplieron el objetivo principal del proyecto demostrando la facilidad y flexibilidad de la aplicación de redes neuronales en los cálculos de propiedades PVT de un aceite; sin embargo, se generó una limitante al no contar con datos suficientes para el entrenamiento de la red, se obtuvieron errores cuadráticos de 0.9831 para factor volumétrico y 0.9956 para viscosidad, pero para rangos de aplicabilidad de 1-3 para B_o y de 1-30cp en viscosidad.

CAPÍTULO 1. GENERALIDADES DEL PROYECTO

1.1 Planteamiento del problema

Los cálculos de ingeniería de yacimientos requieren datos de viscosidad, factor volumétrico y demás propiedades para poder derivar con mayor facilidad las características del fluido y poder realizar pruebas de pozos, cálculos de materiales, estimaciones de reservas, simulaciones numéricas, etc., que son indispensables para un buen aprovechamiento del pozo, pero esto se ha visto un poco afectado debido a diversos inconvenientes tanto con la obtención de datos, así como el cálculo mediante un software. Los autores citados anteriormente mencionan sus principales razones por las cuales diseñaron su propio modelo:

- Correlaciones no aplicables: algunos autores mencionan en sus trabajos de investigación que algunos de los modelos PVT clásicos presentan inconvenientes porque solo son precisos dentro de condiciones específicas del tipo de crudo y de sus propiedades y esto no permite aplicarlos en diferentes zonas en donde se tengan diferentes tipos de hidrocarburo lo que provoca que los softwares no den datos confiables ni cercanos a ser reales; por ejemplo, la correlación de Standing se desarrolló sobre la base de diferentes petróleos crudos del estado de California, y la correlación de AL-Marhoun se desarrolló para los petróleos de Oriente Medio, aunque estas correlaciones mostraron un rendimiento eficaz para predecir las propiedades PVT, el uso de estas correlaciones en lugares diferentes mostraron enormes errores. Esto ha llevado a analizar otras correlaciones y hacer mejoras en ellas para que se puedan adaptar mejor y los datos tengan menor margen de error.
- Gran rango de error: debido a que algunas muestras obtenidas no son confiables y en laboratorio no cuentan con personal especializado para realizarlas de manera adecuada, se han encontrado con diversos problemas a la hora de la obtención de los datos finales ya sea que tengan un margen de error mayor al promedio o que por no implementar una correlación adecuada se obtengan datos lejanos a los reales.

- Alto costo: dentro de la ingeniería, los cálculos PVT son importantes para obtener: estimación de reserva, balance de materia, diseño de instalaciones superficiales, recuperación mejorada, simulación de yacimiento, etc. Idealmente estas propiedades deberían de ser determinadas mediante estudios de laboratorios, sin embargo, estas mediciones algunas veces no están disponibles o son muy costosos.

Se sabe que la mayoría de las correlaciones que se ocupan mayormente para el análisis PVT están desarrolladas con técnicas de regresión lineal y no lineal o técnicas gráficas que tienen mayores complejidades tanto como inexactitudes, es por esto que surge la inquietud de desarrollar un software implementando redes neuronales artificiales debido a que estas tienen ventaja sobre las correlaciones convencionales ya que tienen grandes grados de libertad para ajustar demás parámetros y captan la no linealidad de los sistemas de una mejor manera que los métodos de regresión. También, son superiores a los modelos de regresión en el sentido de que pueden seguir refinándose cuando se dispone de datos adicionales por lo que mejora su precisión de predicción; en cambio, con los modelos no lineales o de regresión lineal es complicado de modificar (Ikiensikimama y Azubuike, 2012).

Con base en lo mencionado anteriormente, cabe resaltar que este trabajo se crea a partir de ideas de otros autores sobre la mayor eficiencia que tienen las redes neuronales y el cómo pueden proporcionar datos más precisos al utilizarlas para calcular las propiedades de un fluido, por ende, se plantea utilizarlas para crear un software que permita obtener los datos del factor volumétrico y la viscosidad de un aceite como base inicial.

1.2 Justificación

El análisis del comportamiento PVT (presión, volumen y temperatura) de los hidrocarburos se ha proclamado como una herramienta de gran importancia dentro de la industria petrolera. El análisis PVT es un conjunto de pruebas experimentales que permiten determinar las propiedades características de un fluido en el yacimiento, el comportamiento de fase y los cambios en la composición a lo largo de la vida útil del

yacimiento mediante la variación de la presión, el volumen y de la temperatura; los cuales son los principales factores que gobiernan el comportamiento volumétrico de los fluidos desde el yacimiento hasta las instalaciones de superficie (Bujowicz, 1988).

Debido a la importancia del análisis PVT dentro de la industria petrolera, este trabajo se creó pensando en las dificultades que existen para llevar a cabo estos análisis, específicamente para obtener los valores de viscosidad, los cuales nos sirven para saber la calidad del aceite; y del factor volumétrico, el cual nos refleja la capacidad del aceite en condiciones de producción. Una segunda consideración es el error que puede surgir al realizar los cálculos utilizando correlaciones ya existentes ya que, generalmente, estas utilizan datos de yacimientos que no son similares a los del aceite que se quiere analizar y modelar por lo que los resultados obtenidos no logran ser lo suficientemente exactos ni precisos; debido a esto, algunos cálculos como el de densidad y factor volumétrico podrían verse afectados y arrojar datos erróneos de otras propiedades ligados a estos.

La implementación de una Red Neuronal Artificial es una alternativa con mayor grado de confianza en los cálculos de viscosidad y del factor volumétrico reduciendo el margen de error que existe al utilizar correlaciones ya existentes.

1.3 Objetivos

1.3.1 Objetivo general

- Calcular el factor volumétrico y la viscosidad del aceite utilizando Redes Neuronales Artificiales (RNA) por medio de un software para la obtención de cálculos con menor margen de error.

1.3.2 Objetivos específicos

- Identificar algunas propuestas existentes sobre la implementación de Redes Neuronales Artificiales para el análisis de las propiedades de los fluidos contenidos en un yacimiento de aceite.

- Recopilar datos resultantes de correlaciones convencionales para hacer una comparativa con los nuevos resultados.
- Diseñar un software de cálculo para el factor volumétrico de un aceite y su viscosidad utilizando una red neuronal artificial.
- Comprobar la capacidad de modelado del software desarrollado, utilizando los datos totales de las propiedades PVT obtenidas.

1.4 Hipótesis

- La implementación de Redes Neuronales Artificiales proporciona resultados más precisos y reduce el margen de error en el cálculo de propiedades PVT en comparación a las correlaciones convencionales, específicamente el cálculo de la viscosidad y del factor volumétrico del aceite.

1.5 Metodología

- Identificación de algunas propuestas existentes sobre la implementación de Redes Neuronales Artificiales para el análisis de las propiedades de los fluidos contenidos en un yacimiento de aceite.

Se analiza información que trate sobre el uso de las Redes Neuronales Artificiales en la Industria Petrolera específicamente para el cálculo de las propiedades de un aceite contenido en un yacimiento.

- Recopilación de datos resultantes de correlaciones convencionales para hacer una comparativa con los nuevos resultados.

Se obtienen datos de reportes PVT o experimentales que sean resultados de la implementación de correlaciones convencionales para el cálculo del factor volumétrico y la viscosidad de un aceite para que la red sea diseñada a partir de una base de datos.

- Diseño de un software que calcule el factor volumétrico de un aceite y su viscosidad utilizando una red neuronal artificial.

Se diseña un software mediante la información obtenida que permita calcular el factor volumétrico y la viscosidad de un aceite mediante la alimentación de una base de datos que contenga las propiedades del fluido a analizar.

- Comprobación de la capacidad de modelado del software desarrollado, utilizando los datos totales de las propiedades PVT obtenidas.

Se verifica que el software desarrollado sea capaz de calcular el factor volumétrico y la viscosidad del aceite a partir de la base de datos comparándolos con los datos de referencia para así, definir su eficiencia y el grado de error de los resultados.

1.6 Alcances y limitaciones

1.6.1 Alcances

- Con la investigación previa de este trabajo se identificarán las deficiencias que existen al hacer los cálculos de las propiedades PVT de un aceite mediante los modelos matemáticos convencionales y los procedimientos experimentales.
- Se desarrollará un software que realice los cálculos de las propiedades PVT de un aceite de manera más eficiente y exacta.

1.6.2 Limitaciones

- El software desarrollado abarcará el cálculo del factor volumétrico y la viscosidad del fluido a estudiar.
- Los valores del factor volumétrico y la viscosidad serán calculados a partir de datos ya existentes en artículos, tesis o informes de investigación, para la estructuración, entrenamiento y prueba de la red neuronal utilizada.

CAPÍTULO 2. MARCO TEÓRICO Y ESTADO DEL ARTE

Como parte de la investigación previa, este capítulo se centra en recopilar la información necesaria para la comprensión de los temas relacionados directa e indirectamente con las propiedades de los fluidos y su cálculo, así como a las Redes Neuronales Artificiales.

2.1 Marco teórico

2.1.1 Fluidos petroleros

Dentro del campo petrolero, lo más importante y fundamental es la presencia de yacimientos. Un yacimiento se define como aquella formación en donde se puede encontrar minerales, gas o aceite de manera natural debido a los procesos de transformación de la materia orgánica, por el incremento de la temperatura o por procesos de acción bacteriana.

A los yacimientos se les puede clasificar por el tipo de fluido que se encuentre en ellos, por lo que encontramos:

a) De aceite negro





Figura 2. 1. Diagrama de fase del aceite negro (Ahmed, 2007).

- Con una GOR (relación gas-aceite) varía entre 200 a 700 scf/STB.

- b) De aceite volátil



- c) De gas seco

- Con contenido de C₇₊ menor al 0.7%.
- Con una producción de condensados menor a 3 STB/MMscf.

- Con una GOR (relación gas-aceite) superior a 100.000 scf/STB.
- Con condiciones de separador dentro del rango de presión y temperatura en la zona de fase gaseosa como se ve en la Figura 2. 3.




Figura 2. 3. Diagrama de fase del gas seco (Ahmed, 2007).

d) De gas retrógrado o condensado

- Con una gravedad API en condensados superior a 50°.
- Con una GOR (relación gas-aceite) entre 8 000 – 70 000 scf/STB.
- Y color blanco traslúcido a condiciones de tanque.
- Con condiciones de separador dentro del rango de presión y temperatura en la zona de dos fases como se ve en la Figura 2. 4.




Figura 2. 4. Diagrama de fase del gas retrógrado o condensado (Ahmed, 2007).

e) De gas húmedo

- Con una GOR (relación gas-aceite) entre a 60.000 – 100 000 scf/STB.
- Con una gravedad API de condensados a condiciones de tanque superior a 60°.
- Con condiciones de separador dentro del rango de presión y temperatura en la zona de dos fases como se ve en la Figura 2. 5.




Figura 2. 5. Diagrama de fase del gas húmedo (Ahmed, 2007).

2.1.2 Principales propiedades del petróleo

Sabemos que el petróleo es una mezcla compleja consistente que se caracteriza por contener hidrocarburo además de sulfuro, oxígeno, nitrógeno y entre otros componentes

por lo que sus propiedades físicas y químicas son fundamentales para realizar cálculos dentro de la industria petrolera. Es importante conocer que estas propiedades cambian dependiendo de la concentración de hidrocarburos, de la presencia de otros componentes e incluso dependiendo las variaciones de presión y temperatura.

a) Densidad

La densidad de un aceite se define como la masa de una unidad de volumen del crudo a una presión y temperatura específica. Usualmente es expresada en libras sobre pies cúbicos (lb/ft³) y, dependiendo el tipo de aceite, esta va a variar; por ejemplo: para aceite volátil ronda en 30 lb/ft³ mientras que para un aceite pesado ronda en 60 lb/ft³.

La densidad del aceite puede ser determinada a partir de:

- La gravedad específica del aceite y el gas.
- La relación gas-aceite.
- El factor volumétrico de formación del aceite.

Expresándose como en la Ecuación 2. 1:

$$\rho_o = \frac{62.42796\gamma_o + 0.0136\gamma_g R_s}{\beta_o}$$

Ecuación 2. 1. Ecuación para calcular la densidad de un aceite a partir de propiedades PVT (Ramirez, 2015).

Donde:

$$\rho_o = \text{Densidad del aceite, } \frac{lb}{ft^3}$$

$$\gamma_o = \text{Gravedad específica del aceite}$$

$$\gamma_g = \text{Gravedad específica del gas}$$

$$R_s = \text{Relación de solubilidad gas – aceite, } \frac{SCF}{STB}$$

$$\beta_o = \text{Factor volumétrico de formación del aceite, } \frac{bbl}{STB}$$

b) Viscosidad

La viscosidad es definida como la resistencia interna del fluido a fluir y es una de las propiedades físicas del petróleo más importantes debido a que es implementada para controlar los fluidos contenidos dentro de los poros de la roca y a través de tuberías. Esta va muy de la mano con la temperatura, la presión y el tamaño de las moléculas de la mezcla, se suele medir en centipoise (Cp).

Dependiendo de la presión, la viscosidad del aceite se puede clasificar en 3 categorías con cálculos propios.

Viscosidad para aceites muertos

Se define como la viscosidad a presión atmosférica y a temperatura del yacimiento. Puede ser calculada mediante las correlaciones propuestas por Beal, Glasso y Beggs-Robinson (Ecuación 2. 2).

$$\mu_{od} = 0.32 + \frac{18(10^7)}{API^{4.53}} \left(\frac{360}{T - 260} \right)^A$$

Ecuación 2. 2. Ecuación para calcular la viscosidad de un aceite muerto a partir de la correlación de Beal (Ahmed, 2016).

Donde:

$$A = 10^{0.42 + \left(\frac{8.33}{API} \right)}$$

μ_{od} = Viscosidad del aceite muerto a una P de 14.7 psia y a Ty, Cp

T = Temperatura, °R

Viscosidad para aceites saturados

Se define como la viscosidad a cualquier presión menor o igual al punto de burbuja. Puede ser calculada a partir de las correlaciones de Chew-Connally (Ecuación 2. 3.) y Beggs-Robinson.

$$\mu_{ob} = (10)^a (\mu_{od})^b$$

Ecuación 2. 3. Ecuación para calcular la viscosidad de un aceite saturado a partir de la correlación Chew-Connally (Ahmed, 2016).

Donde:

μ_{od} = Viscosidad del aceite muerto, Cp

μ_{ob} = Viscosidad para aceites saturados, Cp

$$a = R_s [2.2(10^{-7})R_s - 7.4(10^{-4})]$$

$$b = 0.68(10)^c + 0.25(10)^d + 0.062(10)^e$$

$$c = -0.0000862R_s$$

$$d = -0.0011R_s$$

$$e = -0.00374R_s$$

$$R_s = \text{Relación de solubilidad gas - aceite, } \frac{SCF}{STB}$$

Viscosidad para aceites no saturados

Se define como la viscosidad a presiones por encima del punto de burbuja y a temperatura de yacimiento. Se calcula a partir de las correlaciones de Beal, Khan (Ecuación 2. 4) y Vásquez-Beggs:

$$\mu_o = \mu_{ob} \exp [9.6(10^{-6})(p - p_b)]$$

Ecuación 2. 4. Ecuación para calcular la viscosidad de un aceite no saturado a partir de la correlación de Khan (Ahmed, 2016).

Donde:

μ_o = Viscosidad del aceite no saturado, Cp

μ_{ob} = Viscosidad del aceite saturado, Cp

p = Presión, psia

c) Gravedad específica

La gravedad específica del aceite se define como la relación entre la densidad del aceite y el agua a la misma temperatura y presión. Se puede calcular mediante la Ecuación 2. 5:

$$\gamma_o = \frac{\rho_o}{\rho_w}$$

Ecuación 2. 5. Fórmula convencional para calcular la gravedad específica de un aceite (Ahmed, 2016).

Donde:

$$\rho_o = \text{Densidad del aceite}, \frac{lb}{ft^3}$$

$$\rho_w = \text{Densidad del agua}, \frac{lb}{ft^3}$$

$$\gamma_o = \text{Gravedad específica del aceite}$$

Aunque esta manera se usa ampliamente en la industria, el Instituto Americano del Petróleo (API por sus siglas en inglés) estableció otra manera de medir la gravedad específica: en grados API (Ecuación 2. 6):

$$API = \frac{141.5}{\gamma_o} - 131.5$$

Ecuación 2. 6. Fórmula para calcular la gravedad específica del aceite en grados API (Ahmed, 2016).

Donde:

$$\gamma_o = \text{Gravedad específica del aceite}$$

d) Relación de solubilidad gas-aceite

Esta propiedad está definida por la cantidad de gas que pueda liberar el aceite durante el proceso de transportación desde las condiciones de yacimiento hasta las condiciones de superficie. Los volúmenes de los fluidos son determinados a condiciones estándar y se mide en pies cúbicos estándar por barril del tanque de almacenamiento (scf/STB). Se determina mediante la Ecuación 2. 7:

$$R_s = \frac{\text{Volumen de gas producido en superficie a condiciones estándar}}{\text{Volumen de aceite producido a condiciones estándar}}$$

Ecuación 2. 7. Ecuación para calcular la relación gas-aceite (Ramirez, 2015).

Donde:

$$R_s = \text{Relación gas – aceite, } \frac{\text{scf}}{\text{STB}}$$

$$V_g = \text{Volumen de gas en superficie a c. e., scf}$$

$$V_o = \text{Volumen de aceite a c. e., STB}$$

e) Factor volumétrico de formación del aceite

Se define como la relación entre el volumen de aceite más el gas en solución a la temperatura y presión a condiciones del yacimiento al volumen a condiciones estándar. Esto debido a que el volumen de aceite que entra a los tanques de almacenamiento es menor al volumen que fluye en el pozo desde el yacimiento. Esta se expresa como en la Ecuación 2. 8:

$$B_o = \frac{\text{Volumen de aceite + gas en solución a condiciones de yacimiento } (V_o)_{p,T}}{\text{Volumen de aceite introducido al tanque de almacenamiento a c. e. } (V_o)_{sc}}$$

Ecuación 2. 8. Ecuación para calcular el factor volumétrico de formación del aceite (McCain, 1990).

Donde:

$$B_o = \text{Factor volumétrico del aceite, } \frac{\text{bbl}}{\text{STB}}$$

$$(V_o)_{p,T} = \text{Volumen de aceite mas gas en solución a c. y., bbl}$$

$$(V_o)_{sc} = \text{Volumen de aceite introducido en tanque a c. e., STB}$$

f) Punto de burbuja

La presión de punto de burbuja se define como la presión más alta a la que se libera la primera burbuja de gas en un aceite. Es de las propiedades más importantes y puede ser medida de manera experimental para obtener datos de un yacimiento, aunque se

debe tener otras propiedades ya estimadas previamente, generalmente son: relación de solubilidad del gas-aceite, gravedad del aceite y del gas, gravedad API, temperatura y densidad. Esta característica se puede calcular mediante las correlaciones de Standing (Ecuación 2. 9), Vasquez-Beggs y Glaso.

$$p_b = 18.2[(R_s/\gamma_g)^{0.83}(10)^a - 1.4]$$

Ecuación 2. 9. Ecuación para calcular la presión del punto de burbuja a partir de la correlación de Standing (*Ahmed, 2016*).

Donde:

p_b = Presión de punto de burbuja, psia

R_s = Solubilidad del gas, $\frac{scf}{STB}$

T = Temperatura, °R

$a = 0.00091(T - 460) - 0.0125API$

2.1.3 Medición y análisis de las propiedades del petróleo

Las mediciones realizadas al fluido tienen el fin de poder caracterizarlo para así realizar diversos cálculos que dependen de él como la elección de la instrumentación en los separadores o simplemente para el cálculo de otras propiedades mediante correlaciones convencionales. Algunas se pueden llevar a cabo en laboratorios y otras a partir de cálculos que relacionan las propiedades PVT del fluido para obtener una en específico.

a) Experimentos

Este tipo de pruebas se debe llevar a cabo en laboratorios con los regímenes necesarios, los resultados de estas pruebas se describen en los reportes PVT. Estas pruebas son realizadas con el fin de obtener una mejora en la calidad en las actividades operativas de campo.

Prueba de Expansión a Composición Constante (CCE)

Es una prueba de liberación instantánea en donde una muestra se somete a procesos de expansión a una temperatura constante y a presiones variables. Esta prueba también es conocida como liberación flash, vaporización flash o expansión a composición constante, prueba de presión y temperatura, entre otros. Originalmente se desarrolló para ser aplicada en mezclas de gas condensado, pero también sirve para analizar emulsiones de aceite teniendo como finalidad identificar cómo interactúa la mezcla a los cambios de presión y temperatura en el yacimiento. Con la prueba CCE es posible identificar de manera experimental:

- Presión de saturación: punto de burbuja para aceites y punto de rocío para gases a condiciones de yacimiento.
- Coeficientes de compresibilidad isotérmica de fluidos en estados monofásicos.
- Estimación del volumen total de hidrocarburos.

Para realizarla se siguen los siguientes pasos:

1. Se toma una muestra de la mezcla en el yacimiento y se coloca en una celda PVT llamada Windowed PVT cell manteniendo la presión y temperatura original con un sistema hidráulico(t_1) (Figura 2. 6).
2. Se registra el volumen inicial y se inicia la muestra.
3. La presión se reduce incrementando el volumen de la celda manteniendo una temperatura constante. Lo que forma el sistema hidráulico es la implementación de mercurio por lo que este se reduce conforme aumenta el volumen de la celda PVT(t_2).
4. La mezcla se equilibra mediante agitación y se registra junto con las condiciones a las que se está sometiendo la prueba.
5. Se repiten los pasos 3 y 4 hasta obtener la presión de saturación(t_3).




Figura 2. 6. Representación gráfica de la prueba CCE (Ramirez, 2015).

Prueba de Liberación Diferencial (LD)

Esta prueba solo se lleva a cabo en aceites y se considera como la mejor para describir la separación de fases dentro del yacimiento cuando declina la presión. Con esta prueba se pueden obtener propiedades como:

- El fenómeno de encogimiento por presión aplicada al aceite.
- Densidad remanente para cada presión.
- El factor volumétrico de formación del gas y del aceite.
- La relación gas-aceite.
- Factor de compresibilidad del gas.
- La gravedad específica.

Para realizarla se siguen los siguientes pasos:

1. Se toma una muestra extraída del yacimiento con condiciones iniciales y se coloca en una celda PVT(t₁). La diferencia es que la celda tiene un tope. La muestra se estabiliza por medio de agitación a una presión teórica (Figura 2. 7).
2. Se registra el volumen inicial.
3. Se reduce la presión en 10-15 etapas a temperatura constante lo que provoca el incremento de volumen en la celda(t₂).

4. Una vez alcanzado las fases de equilibrio, se retira el gas liberado a presión constante (t_3), en esta etapa se mide el volumen remanente y se registran los datos.
5. Se repiten los pasos 3 y 4 hasta finalizar la prueba.
6. Por último, el aceite contenido en la celda se pasa condiciones estándar, posteriormente se mide el volumen remanente y el factor volumétrico.




Figura 2. 7. Representación gráfica de la prueba DL (Ramírez, 2015).

Agotamiento a Volumen Constante (CVD)

Es una gran herramienta para estudiar los yacimientos de gas condensado y de aceite volátil ya que permite recrear el comportamiento del fluido en el yacimiento. También es llamada como estudio de depleción o de agotamiento. A partir de esta prueba se pueden conocer las variaciones composicionales de los fluidos, así como también:

- Volumen de gas producido acumulado.
- Saturación del gas o líquido.
- Factor de compresibilidad del gas.
- La composición a diferentes parámetros de presión y temperatura.

La prueba se realiza de la manera siguiente:

1. Se toma una muestra extraída del yacimiento de composición conocida y se coloca en una celda PVT(t_1). La diferencia es que la celda tiene un tope. La muestra se estabiliza por medio de agitación a temperatura de yacimiento y a presión de saturación. Se registran los datos y se somete al sistema hidráulico.
2. Se calcula el factor de compresibilidad del gas (Figura 2. 8).
3. La presión se reduce conforme a los niveles deseados manteniendo la temperatura, por lo que el volumen de la muestra aumenta(t_2).
4. Se equilibra la mezcla por agitación en cada etapa de la prueba y luego se extrae una porción de la mezcla a través de la válvula a T y P constantes hasta a alcanzar el volumen inicial de la prueba (t_3 y t_4).
5. El volumen retirado previamente es analizado en laboratorio y se calcula el factor de compresibilidad de las dos fases.
6. Se mide el volumen retrógrado debido a que representa la saturación de condensados.
7. Se repiten los pasos del 3-6 dependiendo a qué presión se requieran los datos.




Figura 2. 8. Representación gráfica de la prueba CVD (Ramirez, 2015).

Separación Multietapa (Pruebas de Separador)

Esta prueba es muy útil para simular el comportamiento de los fluidos al momento de fluir en el separador hasta el tanque de almacenamiento. Generalmente, el comportamiento del fluido se ve influenciado por las formas de operación y sus condiciones por lo que esta simulación ayuda a predecir un comportamiento futuro o al menos acercarse. Tiene

como objetivo proporcionar la información necesaria de la reacción del fluido para poder crear las mejores condiciones para su traslado. Como la prueba implica a los separadores y los tanques, esta se debe recrear para cada uno por separado a condiciones de superficie. A partir de esta medición, también se puede obtener:

- El factor volumétrico de formación al punto de burbuja.
- La solubilidad del gas al punto de burbuja.

La realización de la prueba se define de la siguiente forma:

1. Se extrae una muestra del hidrocarburo a condiciones de yacimiento y se coloca en una celda PVT a presión de saturación. Se estabiliza y se registra el volumen.
2. Posteriormente se desplaza la muestra a través de una válvula conectada a la primera cámara del separador ajustada al vacío de manera intermitente hasta llegar a todas las cámaras del separador. Durante este paso se ajusta la presión y la temperatura conforme se hayan propuesto en el estudio.
3. Se desplaza la muestra a través del separador dándole paso por válvulas a una presión constante.
4. Comienza la separación de los fluidos, se separa primero la parte líquida hasta el nivel deseado.
5. Se extrae lo que quedó en el separador, que es la parte gaseosa a través de una manguera y por vacío.
6. Se mide el gas liberado de cada etapa para calcular la gravedad específica y el volumen.
7. Se mide el volumen remanente y se determina el factor volumétrico del aceite y la solubilidad del gas a presión de saturación.
8. El procedimiento se repite para diferentes condiciones de separación (Figura 2.9).




Figura 2. 9. Representación del flujo del crudo a través de separadores hasta el tanque de almacenamiento (Ramirez, 2015).

b) Correlaciones

Densidad

- Standing (1981)

Standing propuso en 1981 una correlación empírica para estimar las propiedades PVT en función de la solubilidad del gas, la gravedad específica en tanque y en solución, y a temperatura de yacimiento como se ve en la Ecuación 2. 10.

$$\rho_o = \frac{62.4\gamma_o + 0.0136R_s\gamma_g}{0.972 + 0.000147 \left[R_s \left(\frac{\gamma_g}{\gamma_o} \right)^{0.05} + 1.25(T - 460) \right]^2}$$

Ecuación 2. 10. Correlación de Standing para densidad (Ahmed, 2016).

Donde:

γ_o = Gravedad específica del aceite en el tanque de almacenamiento, $\frac{60^\circ}{60^\circ}$

γ_g = Gravedad específica del gas

R_s = Solubilidad del gas, $\frac{scf}{STB}$

ρ_o = Densidad del aceite, $\frac{lb}{ft^3}$

Viscosidad de un aceite muerto

- Beal (1946)

Beal estableció una correlación gráfica en función de la temperatura y los grados API del crudo (Ecuación 2. 11).

$$\mu_{od} = 0.32 + \frac{18(10^7)}{API^{4.53}} \left(\frac{360}{T - 260} \right)^A$$

Ecuación 2. 11. Correlación de Beal para Viscosidad (Ahmed, 2016).

Donde:

$$A = 10^{0.42 + \left(\frac{8.33}{API} \right)}$$

μ_{od} = Viscosidad del aceite muerto a una P de 14.7 psia y a Ty, Cp

T = Temperatura, °R

- Beggs-Robinson (1975)

Ellos establecieron una correlación empírica expresada matemáticamente como en la Ecuación 2. 12:

$$\mu_{od} = 10^{A(T-460)^{-1.163}} - 1$$

Ecuación 2. 12. Correlación de Beggs-Robinson para aceites muertos (Ahmed, 2016).

Donde:

$$A = 10^{3.0324 - 0.02023 API}$$

T = Temperatura, °R

- Glaso (1980)

Glaso propuso una generalización matemática computacional expresada como Ecuación 2. 13:

$$\mu_{od} = [3.141(10^{10})](T - 460)^{-3.444}[\log(API)]^A$$

Ecuación 2. 13. Correlación de Glaso para aceites muertos (Ahmed, 2016).

Donde:

$T = \text{Temperatura}, ^\circ R$

$$A = 10.313[\log(T - 460)] - 36.447$$

- Dindoruk-Christman (2001)

Establecen que, en la literatura, las correlaciones para la viscosidad de un aceite muerto son funciones de la gravedad API y la temperatura, por lo que propusieron la siguiente Ecuación 2. 14:

$$\mu_{oD} = \frac{a_3 T^{a_4} (\log API)^A}{a_5 p_{bp}^{a_6} + a_7 R_{sbp}^{a_8}}$$

Ecuación 2. 14. Correlación de Dindoruk-Christman para aceites muertos (Ahmed, 2016).

Donde:

$$A = a_1 \log T + a_2$$

$$a_3 = -1.023451(10^{-2})$$

$$a_4 = 6.600358(10^{-1})$$

$$a_5 = 1.075080(10^{-3})$$

$$a_6 = 1$$

$$a_7 = -2.191172(10^{-5})$$

$$a_8 = -1.660981(10^{-2})$$

$T = \text{Temperatura}, ^\circ F$

$R_s = \text{Relación de solubilidad gas - aceite}, \frac{SCF}{STB}$

Viscosidad de un aceite saturado

- Chew-Connally (1959)

Ellos presentaron una correlación gráfica para expresar la reducción de la viscosidad debido a la solubilidad del gas (Ecuación 2. 15):

$$\mu_{ob} = (10)^a(\mu_{od})^b$$

Ecuación 2. 15. Correlación de Chew-Connally para aceites saturados (Ahmed, 2016).

Donde:

μ_{od} = Viscosidad del aceite muerto, Cp

μ_{ob} = Viscosidad para aceites saturados, Cp

$a = R_s[2.2(10^{-7})R_s - 7.4(10^{-4})]$

$b = 0.68(10)^c + 0.25(10)^d + 0.062(10)^e$

$c = -0.0000862R_s$

$d = -0.0011R_s$

$e = -0.00374R_s$

$R_s = \text{Relación de solubilidad gas - aceite, } \frac{SCF}{STB}$

- Beggs-Robinson (1975)

Ellos propusieron una expresión matemática empírica expresada como (Ecuación 2. 16):

$$\mu_{ob} = a(\mu_{od})^b$$

Ecuación 2. 16. Correlación de Beggs-Robinson para aceites saturados (Ahmed, 2016).

Donde:

$a = 10.715(R_s + 100)^{-0.515}$

$b = 5.44(R_s + 150)^{-0.338}$

μ_{od} = Viscosidad del aceite muerto, Cp

- Abu-Khamsin y Al-Marhoun (1991)

Establecen que la viscosidad se relaciona bien con la densidad del aceite saturado, por lo que propusieron la Ecuación 2. 17:

$$\ln (\mu_{ob}) = 8.484462\rho_{ob}^4 - 2.652294$$

Ecuación 2. 17. Correlación de Abu-Khamsin and Al-Marhoun para aceites saturados (*Ahmed, 2016*).

Donde:

$$\rho_{ob} = \text{Densidad de un aceite saturado}, \frac{g}{cm^3}$$

- Dindoruk y Christman (2001)

Plantean que, en la literatura, las correlaciones para la viscosidad de un aceite saturado requieren del uso de la viscosidad de un aceite muerto. Ellos propusieron la Ecuación 2. 18 a partir de los datos obtenidos.

$$\mu_{obp} = A(\mu_{oD})^B$$

Ecuación 2. 18. Correlación de Dindoruk-Christman para aceites saturados (*Ahmed, 2016*).

Donde A se define como:

$$A = \frac{a_1}{\exp(a_2 R_s)} + \frac{a_3 R_s^{a_4}}{\exp(a_5 R_s)}$$

Y B se define como:

$$B = \frac{a_6}{\exp(a_7 R_s)} + \frac{a_8 R_s^{a_9}}{\exp(a_{10} R_s)}$$

Donde:

$$a_1 = 1$$

$$a_2 = 4.740729(10^{-4})$$

$$a_3 = -1.023451(10^{-2})$$

$$a_4 = 6.600358(10^{-1})$$

$$a_5 = 1.075080(10^{-3})$$

$$a_6 = 1$$

$$a_7 = -2.191172(10^{-5})$$

$$a_8 = -1.660981(10^{-2})$$

$$a_9 = 4.233179(10^{-1})$$

$$a_{10} = -2.273945(10^{-4})$$

$$T = \text{Temperatura}, ^\circ F$$

$$R_s = \text{Relación de solubilidad gas - aceite}, \frac{SCF}{STB}$$

Viscosidad de un aceite bajo saturado

- Beal (1946)

Se basó en 52 mediciones de viscosidad y presentó una ecuación en donde plasmó la variación de la viscosidad de un aceite bajo saturado con relación a la presión (Ecuación 2. 19):

$$\mu_o = \mu_{ob} + 0.001(p - p_o)[0.024\mu_{ob}^{1.6} + 0.038\mu_{ob}^{0.56}]$$

Ecuación 2. 19. Correlación de Beal para aceites bajo saturados (Ahmed, 2016).

Donde:

μ_o = Viscosidad del aceite bajo saturado a una presión, Cp

μ_{ob} = Viscosidad del aceite a condiciones de presión de burbuja, Cp

p = Presión, psia

Con un error del 2.7% para la ecuación.

- Khan (1987)

Estimó la Ecuación 2. 20:

$$\mu_o = \mu_{ob} \exp [9.6(10^{-6})(p - p_b)]$$

Ecuación 2. 20. Correlación de Khan para aceites bajo saturados (Ahmed, 2016).

Donde:

μ_o = Viscosidad del aceite no saturado, Cp

μ_{ob} = Viscosidad del aceite saturado, Cp

p = Presión, psia

- Vásquez-Beggs (1980)

Propusieron una expresión matemática simple para estimar la viscosidad de un aceite cuando se encuentra por encima del punto de burbuja utilizando 3593 puntos de información. Propusieron la (Ecuación 2. 21):

$$\mu_o = \mu_{ob} \left(\frac{p}{p_b} \right)^m$$

Ecuación 2. 21. Correlación de Vásquez-Beggs para aceites bajo saturados (Ahmed, 2016).

Donde:

$$m = 2.6p^{1.187}10^A$$

$$A = -3.9(10^{-5})p - 5$$

- Dindoruk y Christman (2001)

Plasmaron una nueva correlación para obtener la viscosidad de un aceite bajo saturado, la ecuación que dio el mejor resultado utilizando análisis de regresión fue (Ecuación 2. 22):

$$\mu_o = \mu_{obp} + a_6(p - p_{bp})10^A$$

Ecuación 2. 22. Correlación de Dindoruk y Christman para aceites bajo saturados (Ahmed, 2016).

Donde A se define como:

$$A = a_1 + a_2 \log \mu_{obp} + a_3 \log R_s + a_4 \mu_{obp} \log R_s + a_5 (p - p_{bp})$$

Donde:

$$a_1 = 0.776644115$$

$$a_2 = 0.987658646$$

$$a_3 = -0.190564677$$

$$a_4 = 0.009147711$$

$$a_5 = -0.000019111$$

$$a_6 = 0.000063340$$

$p = \text{Presión, psi}$

$R_s = \text{Relación de solubilidad gas - aceite, } \frac{SCF}{STB}$

Punto de burbuja

- Standing (1947)

Propuso una ecuación gráfica a partir de la solubilidad del gas, gravedad específica y la temperatura del yacimiento (Ecuación 2. 23):

$$p_b = 18.2[(R_s/\gamma_g)^{0.83}(10)^a - 1.4]$$

Ecuación 2. 23. Correlación de Standing para Pb (Ahmed, 2016).

Donde:

$p_b = \text{Presión de punto de burbuja, psia}$

$R_s = \text{Solubilidad del gas, } \frac{scf}{STB}$

$T = \text{Temperatura, } ^\circ R$

$$a = 0.00091(T - 460) - 0.0125API$$

- Vásquez-Beggs

Ellos establecieron la correlación (Ecuación 2. 24):

$$p_b = \left[\left(C_1 \frac{R_s}{\gamma_{gs}} \right) (10)^a \right]^{C_2}$$

Ecuación 2. 24. Correlación de Vásquez-Beggs para Pb (Ahmed, 2016).

Donde:

$T = \text{Temperatura, } ^\circ R$

$\gamma_{gs} = \text{Gravedad específica del gas}$

$$a = C_3 \left(\frac{API}{T} \right)$$

$C_3 = 27.624 \text{ si } API \leq 30; 56.18 \text{ si } API > 30$

$C_2 = 10.914328 \text{ si } API \leq 30; 0.84246 \text{ si } API > 30$

$C_1 = -11.172 \text{ si } API \leq 30; -10.393 \text{ si } API > 30$

- Glaso (1980)

Propuso la siguiente expresión (Ecuación 2. 25):

$$\log(p_b) = 1.7669 + 1.7447 \log(A) - 0.302218 [\log(A)]^2$$

Ecuación 2. 25. Correlación de Glaso para Pb (Ahmed, 2016).

Donde:

$$A = \left(\frac{R_s}{\gamma_g} \right)^2 \left[\frac{(T - 460)^{0.172}}{(API)^{0.989}} \right]$$

$\gamma_{gs} = \text{Gravedad específica promedio de los gases superficiales}$

$R_s = \text{Solubilidad del gas, } \frac{scf}{STB}$

$T = \text{Temperatura, } ^\circ R$

Factor volumétrico de formación del aceite

- Vázquez y Beggs (1980)

Propusieron una relación en función de la relación gas-aceite, gravedad específica y la temperatura (Ecuación 2. 26).

$$B_o = 1.0 + C_1 R_s + (T - 520) \left(\frac{API}{\gamma_{gs}} \right) [C_2 + C_3 R_s]$$

Ecuación 2. 26. Correlación de Vázquez y Beggs para Bo (Ahmed, 2016).

γ_{gs} se define como:

$$\gamma_{gs} = \gamma_g [1 + 5.912(10^{-5})(API)(T_{sep} - 460) \log \left(\frac{P_{sep}}{114.7} \right)]$$

Donde:

$R_s = \text{Solubilidad del gas, } \frac{scf}{STB}$

$T = \text{Temperatura, } R^\circ$

$\gamma_{gs} = \text{Gravedad específica del gas}$

$\gamma_g = \text{Gravedad específica de la solución de gas}$

$C_1 = 4.677 \times 10^{-4}$ si $API \leq 30$; 4.670×10^{-4} si $API > 30$

$C_2 = 1.751 \times 10^{-5}$ si $API \leq 30$; 1.100×10^{-5} si $API > 30$

$C_3 = -1.811 \times 10^{-8}$ si $API \leq 30$; 1.337×10^{-9} si $API > 30$

Con un error promedio del 4.7% para la correlación.

- Glaso (1980)

Propuso la siguiente expresión (Ecuación 2. 27):

$$B_o = 1.0 + 10^A$$

Ecuación 2. 27. Correlación de Glaso para Bo (Ahmed, 2016).

“A” se define como:

$$A = -6.58511 + 2.91329 \log B_{ob} - 0.27683 (\log B_{ob})^2$$

Y B_{ob} es un número de correlación definido por:

$$B_{ob} = R_s \left(\frac{\gamma_g}{\gamma_o} \right)^{0.526} + 0.968(T - 460)$$

Donde:

$T = \text{Temperatura}, R^\circ$

$\gamma_o = \text{Gravedad específica del aceite}, \frac{60^\circ}{60^\circ}$

$\gamma_g = \text{Gravedad específica de la solución de gas}$

$R_s = \text{Solubilidad del gas}, \frac{scf}{STB}$

Con un error promedio de -0.43% a una desviación estándar de 2.18% para la correlación.

- Standing (1981)

Standing presentó una correlación gráfica que relaciona la solubilidad del gas, la gravedad específica y la temperatura en yacimiento (Ecuación 2. 28):

$$B_o = 0.9759 + 0.000120 \left[R_s \left(\frac{\gamma_g}{\gamma_o} \right)^{0.5} + 1.25(T - 460) \right]^{1.2}$$

Ecuación 2. 28. Correlación de Standing para Bo (Ahmed, 2016).

Donde:

$T = \text{Temperatura}, ^\circ R$

$\gamma_o = \text{Gravedad específica del aceite}, \frac{60^\circ}{60^\circ}$

$\gamma_g = \text{Gravedad específica de la solución de gas}$

$$R_s = \text{Solubilidad del gas}, \frac{scf}{STB}$$

Con un error promedio del 1.2% para la correlación.

- Abdul-Majeed y Salman (1988)

Propusieron una ecuación basada en regresión múltiple no lineal a partir de 420 datos experimentales obtenidos de 119 mezclas diferentes de aceite y gas (Ecuación 2. 29).

$$B_o = 0.9657876 + 4.8141 \times 10^5 F - 6.8987 \times 10^{-10} F^2 + 7.73 \times 10^{-4} T$$

Ecuación 2. 29. Correlación de Abdul-Majeed y Salman para Bo (Abdul-Majeed & Salman, 1988).

“F” se define como:

$$F = R_s^{1.2} G_{ag}^{-0.147} G_{ao}^{-5.222}$$

Donde:

$T = \text{Temperatura}, R^\circ$

$G_{ag} = \text{Gravedad específica del gas}$

$G_{ao} = \text{Gravedad específica del aceite}$

$$R_s = \text{Solubilidad del gas}, \frac{scf}{STB}$$

Mostrando un error promedio y una desviación estándar menor al 10% y menor que las correlaciones de Standing, Vásquez, Glaso y Al-Marhoun.

- Al-Marhoun (1988)

Estableció la Ecuación 2. 30:

$$B_o = 0.497069 + 0.000862963T + 0.00182594F + 0.00000318099F^2$$

Ecuación 2. 30. Correlación de Marhoun para Bo (Ahmed, 2016).

“F” se define como:

$$F = R_s^a \gamma_g^b \gamma_o^c$$

Donde:

$$\gamma_o = \text{Gravedad específica del aceite}, \frac{60^\circ}{60^\circ}$$

$$\gamma_g = \text{Gravedad específica de la solución de gas}$$

$$R_s = \text{Solubilidad del gas}, \frac{\text{scf}}{\text{STB}}$$

$$a = 0.742390$$

$$b = 0.323294$$

$$c = -1.202040$$

- Dokla y Osman (1992)

Presentaron una ecuación para el factor volumétrico del aceite a condiciones del punto de burbuja a partir del método de regresión (Ecuación 2. 31).

$$B_{ob} = 0.431935 \times 10^{-2} + 0.156667 \times 10^{-2} T + 0.139775 \times 10^{-2} M + 0.380525 \times 10^{-5} M^2$$

Ecuación 2. 31. Correlación de Dokla y Osman para Bob (Dokla & Osman, 1992).

“M” se define como:

$$M = R 0.773572 \gamma_g * 0.404020 \gamma_o - 0.882605$$

Donde:

$$T = \text{Temperatura}, R^\circ$$

$$\gamma_o = \text{Gravedad específica del aceite}, \frac{60^\circ}{60^\circ}$$

$$\gamma_g = \text{Gravedad específica de la solución de gas}$$

- Petrosky y Farshad (1993)

Propusieron una ecuación similar a la de Standing (Ecuación 2. 32):

$$B_o = 1.0113 + 7.2046(10^{-5})A$$

Ecuación 2. 32. Correlación de Petrosky y Farshad para Bo (Ahmed, 2016).

“A” se define como:

$$A = \left[R_s^{0.3738} \left(\frac{\gamma_g^{0.2914}}{\gamma_o^{0.6265}} \right) + 0.24626(T - 460)^{0.5371} \right]^{3.0936}$$

Donde:

$T = \text{Temperatura}, R^\circ$

$\gamma_o = \text{Gravedad específica del aceite}, \frac{60^\circ}{60^\circ}$

$\gamma_g = \text{Gravedad específica de la solución de gas}$

$R_s = \text{Solubilidad del gas}, \frac{scf}{STB}$

- Hematti y Kharrat (2007)

Propusieron una ecuación para el factor volumétrico de un aceite a condiciones de presión de burbuja implementando un análisis de regresión múltiple no lineal a partir de 287 datos experimentales (Ecuación 2. 33).

$$B_{ob} = 1.0 + 10^A$$

Ecuación 2. 33. Correlación de Hemmati y Kharrat para Bob (Hemmati & Kharrat, 2007).

“A” se define como:

$$A = -4.6862 + 1.5959 \log B_{ob*} - 0.0566 (\log B_{ob*})^2$$

Y B_{ob*} se define como un número de correlación por la siguiente ecuación:

$$B_{ob*} = R_s \left(\frac{\gamma_g}{\gamma_o} \right)^{0.5946} + 1.7439T$$

Donde:

$T = \text{Temperatura}, R^\circ$

$\gamma_o = \text{Gravedad específica del aceite}, \frac{60^\circ}{60^\circ}$

$\gamma_g = \text{Gravedad específica de la solución de gas}$

$R_s = \text{Solubilidad del gas}, \frac{scf}{STB}$

Con un error promedio de 0.07% con una desviación estándar de 1.71% para esta correlación.

- Adeeyo (2018)

Propuso una correlación para calcular el factor volumétrico de un aceite a condiciones de presión de burbuja a partir de dos algoritmos: Levenberg-Marquardt y reflexión (Ecuación 2. 34).

$$B_{ob*} = 1 + AR_s BT API^{\frac{1}{2}}$$

Ecuación 2. 34. Correlación de Adeeyo para Bo (Adeeyo, 2018).

Donde:

$A = 0.0128833346979703$

$B = 0.0000302759123496261$

$T = \text{Temperatura}, R^\circ$

$R_s = \text{Solubilidad del gas}, \frac{scf}{STB}$

Relación de solubilidad de gas-aceite

- Standing (1947)

Propuso la siguiente ecuación (Ecuación 2. 35):

$$R_s = Y_g \left[\left(\frac{P}{18.2} + 1.4 \right) 10^x \right]^{1.2048}$$

Ecuación 2. 35. Correlación de Standing para Rs (Ahmed, 2016).

Donde:

$$x = 0.0123API - 0.00091(T - 460)$$

$$R_s = \text{Solubilidad del gas, } \frac{\text{scf}}{\text{STB}}$$

γ_g = Gravedad específica de la solución de gas

T = Temperatura, °R

p = Presión de yacimiento, psia

- Marhoun (1988)

Estableció la Ecuación 2. 36:

$$R_s = [aY_g^b Y_o^c T^d P]^e$$

Ecuación 2. 36. Correlación de Marhoun para Rs (Ahmed, 2016).

Donde:

Y_g = Gravedad específica del gas

Y_o = Gravedad específica del tanque de aceite

T = Temperatura, °R

$$a = 185.843208$$

$$b = 1.877840$$

$$c = -3.1437$$

$$d = -1.32657$$

$$e = 1.39844$$

c) Ecuaciones de estado

Las ecuaciones de estado son expresiones analíticas que relacionan la presión, la temperatura y el volumen, estas son esenciales para determinar el volumen y las fases de los fluidos petroleros dentro del yacimiento, predecir propiedades como la presión a punto de burbuja, presión de vapor, así como para predecir el comportamiento en superficie al momento de ser sometidos a separación de fases y demás procesos de simulación de propiedades PVT.

Generalmente, las ecuaciones de estado solo necesitan las propiedades críticas y el factor acéntrico de los componentes. La EOS más conocida es la ecuación del gas ideal (Ecuación 2. 37):

$$p = \frac{RT}{V}$$

Ecuación 2. 37. Ecuación del Gas Ideal (Ahmed, 2016).

Donde:

$V = \text{Volumen por 1 mol de gas, } \frac{ft^3}{mol}$

$T = \text{Temperatura, } ^\circ R$

$R = \text{Constante del gas}$

Van Der Waals

En 1873 Van Der Waals trató de eliminar dos suposiciones:

- El volumen de las moléculas es insignificante en comparación con el volumen total y la distancia de las moléculas.
- No hay fuerzas entre las moléculas.

Por lo que, para eliminar la primera suposición, estableció que las moléculas de gas ocupan una fracción significativa dentro del volumen a presiones más altas, entonces añadió una variable “b” a la Ecuación 2. 38:

$$p = \frac{RT}{V - b}$$

Ecuación 2. 38. Primera modificación de Van Der Waals a la Ecuación del Gas Ideal (Ahmed, 2016).

Donde “b” denota un covolumen.

Para eliminar la segunda suposición, estableció que faltaba un término correctivo para tener en cuenta las fuerzas de atracción entre moléculas, entonces introdujo la variable “a” y una resta en relación al volumen (Ecuación 2. 39):

$$p = \frac{RT}{V - b} - \frac{a}{V^2}$$

Ecuación 2. 39. Segunda modificación de Van Der Waals a la Ec. del Gas Ideal (Ahmed, 2016).

Quedando “b” como parámetro de repulsión y “a” como parámetro de atracción (Ecuación 2. 40):

$$a = 0.421875 \left(\frac{R^2 T_c^2}{p_c} \right) \quad b = 0.125 \left(\frac{RT_c}{p_c} \right)$$

Ecuación 2. 40. Parámetros de la Ecuación de Van Der Waals (Ahmed, 2016).

Donde:

$$R = \text{Constante del gas}, 10.77 \frac{\text{psia ft}^3}{\text{lb mol } ^\circ\text{R}}$$

$$p_c = \text{Presión crítica, psia}$$

$$T_c = \text{Temperatura crítica, } ^\circ\text{R}$$

Redlich-Kwong

En 1949, Redlich-Kwong observaron que la modificación que había realizado Van Der Waals para refutar la segunda suposición no consideraba la temperatura como un factor que influyese en las fuerzas de atracción en las moléculas por lo que establecieron que una modificación mejoraba las predicciones (Ecuación 2. 41):

$$p = \frac{RT}{V - b} - \frac{a}{V(V + b)\sqrt{T}}$$

Ecuación 2. 41. Modificación a la Ecuación de Van Der por Redlich y Kwong (Ahmed, 2016).

Quedando “b” como parámetro de repulsión y “a” como parámetros nuevos de atracción (Ecuación 2. 42):

$$a = 0.42747 \left(\frac{R^2 T_c^{2.5}}{p_c} \right) \quad b = 0.08664 \left(\frac{RT_c}{p_c} \right)$$

Ecuación 2. 42. Parámetros de la Ecuación de Redlich-Kwong (Ahmed, 2016).

Donde:

$$TR = \text{Constante del gas}, 10.77 \frac{\text{psia ft}^3}{\text{lb mol } ^\circ R}$$

p_c = Presión crítica, psia

T_c = Temperatura crítica, °R

Soave-Redlich-Kwong

En 1972, Soave aportó una de las más importantes modificaciones en las ecuaciones de estado. Él consideró que la ecuación de Redlich-Kwong aun no consideraba la temperatura de manera correcta por lo que la modificó agregando un término que depende de la temperatura quedando la Ecuación 2. 43:

$$p = \frac{RT}{V - b} - \frac{a\alpha(T)}{V(V + b)}$$

Ecuación 2. 43. Modificación de la Ecuación de Redlich-Kwong por Soave (Ahmed, 2016).

En donde $\alpha(T)$ se define por la Ecuación 2. 44:

$$\alpha(T) = \left[1 + m \left(1 - \sqrt{\frac{T}{T_c}} \right) \right]^2 \quad o \quad \alpha(T) = \left[1 + m(1 - \sqrt{T_r}) \right]^2$$

Ecuación 2. 44. Parámetro de la Ecuación de Soave-Redlich-Kwong (*Ahmed, 2016*).

Misma que $\alpha(T) = 1$ cuando la $T_r = 1$, esto es $\alpha(T = T_c) = 1$ cuando $\frac{T}{T_c} = 1$.

Y $m = 0.480 + 1.74\omega - 0.17\omega^2$ siendo ω el factor acéntrico de la sustancia.

También los valores de “a” y “b” son modificados en la Ecuación 2. 45:

$$a = 0.42747 \left(\frac{R^2 T_c^2}{p_c} \right) \quad b = 0.08664 \left(\frac{R T_c}{p_c} \right)$$

Ecuación 2. 45. Parámetros de la Ec. de Soave-Redlich-Kwong (*Ahmed, 2016*).

Donde:

$$R = \text{Constante del gas, } 10.77 \frac{\text{psia ft}^3}{\text{lb mol } ^\circ R}$$

$p_c = \text{Presión crítica, psia}$

$T_c = \text{Temperatura crítica, } ^\circ R$

2.1.4 Inteligencia Artificial

La Inteligencia Artificial (IA) surgió a partir del desarrollo de tecnologías que permiten a los sistemas informáticos imitar o simular la inteligencia humana. De manera puntual, se define como la capacidad de los sistemas para realizar tareas e indicaciones que se creían capaces de hacer solo con intervención humana como el reconocimiento de voz, el procesamiento del lenguaje, toma de decisiones, aprendizaje e incluso la resolución e identificación de problemas.

La IA se basa en algoritmos y modelos matemáticos que permiten a las computadoras procesar grandes cantidades de datos, reconocer patrones y aprender a partir de estos. Estos algoritmos pueden utilizar diferentes enfoques como el aprendizaje automático

(Machine Learning), en donde las computadoras aprenden mediante retroalimentación; y el aprendizaje profundo (Deep Learning), que imita las funciones del cerebro.

La IA se aplica en diversos campos para realizar desde tareas rutinarias hasta la toma de decisiones complejas.

a) Conceptos Generales

- Algoritmo: es una implementación de la arquitectura de red neuronal popular y adaptable para el aprendizaje automático.
- Aprendizaje: en redes neuronales es la modificación del comportamiento de la red resultante de la aplicación sucesiva de estímulos.
- Función de activación: es la que activa los pesos de una neurona según el resultado. Esto permite introducir la no linealidad en las redes neuronales.
- Variable: característica, cualidad o propiedad observada que puede adquirir diferentes valores y es susceptible de ser cuantificada o medida en una investigación.
- Input: es la capa de entrada en donde estarán todas nuestras entradas o datos de entrenamiento, estos contarán con pesos que permitirán expresar su importancia.
- Hidden: es la capa oculta, puede estar conformada a su vez por una o varias capas y el número de capas dependerá de qué tan sofisticado queremos nuestro modelo.
- Output: es la capa de salida, puede contar con una o varias neuronas y dependerá del número de características que se desean llegar a predecir.
- Nodo o neurona: es la unidad básica de la red neuronal que se utiliza para crear y entrenar la red. Estos se organizan por capas pasando de ser módulos a algoritmos.
- Entrenamiento: es el proceso de aprendizaje de comportamientos que permitan destacar características de los objetos que se están tomando como input en la red.
- Pérdida: es la penalidad por una predicción incorrecta del modelo de red neuronal.

b) Machine Learning

El Machine Learning (ML), también conocido como aprendizaje automático, es una rama de la Inteligencia Artificial (IA) que proporciona a las computadoras la capacidad de identificar patrones utilizando algoritmos. Estos son previamente entrenados con una gran cantidad de datos con el fin de elaborar predicciones. Gracias a su funcionamiento, la tecnología actual puede realizar tareas específicas de manera autónoma sin la necesidad de ser programados fijamente. Además, ofrece la ventaja de poder modificarlos para mejorarlos y dar resultados más precisos y exactos sin necesitar de la intervención humana directa. Dependiendo de su aplicabilidad y relación con los datos se clasificará en diferentes modelos como los de la Figura 2. 10.




Figura 2. 10. Clasificación de los modelos de Machine Learning (Java T point, 2021).

Tipos de algoritmos

El proceso fundamental de esta inteligencia implica el análisis de datos y la extracción de patrones. El Machine Learning utiliza algoritmos en donde se necesitan datos de entrada para entrenar a los modelos y así desarrollar la capacidad de realizar análisis predictivos y la toma de decisiones. La idea de la que parten estos algoritmos es que se puede aprender a partir de ejemplos pasados, se utiliza esta experiencia y se genera un vínculo que se aplica automáticamente al ingresar los mismos parámetros.

Existen diferentes enfoques o algoritmos para crear una inteligencia artificial dependiendo de lo que se va a analizar Figura 2. 11.




Figura 2. 11. Tipos de aprendizaje en inteligencia artificial (Beunza, 2020).

- El aprendizaje supervisado: Enfocado a la tarea. Este se caracteriza por la presencia de un agente externo o supervisor que determina la respuesta que debe generar la red a partir de los datos de entrada. Tiene la ventaja de que, si los resultados no son los deseados, el supervisor podrá modificar la estructura o procesamiento de la red hasta obtener los resultados exactos o cercanos.
- De refuerzo: enfocado al aprendizaje. En este algoritmo el modelo aprende mediante la interacción con el entorno, configurándose para reaccionar ante cualquier situación.
- No supervisado: enfocado a los datos. Este tipo de aprendizaje también es conocido como auto-supervisado el cual no necesita de un agente externo que monitoree el proceso de la red ni para ajustar los parámetros entre las conexiones de sus nodos por lo que son capaces de organizarse de manera autónoma. Las RNA con este aprendizaje pueden encontrar las características, irregularidades, similitudes de cada dato que se le introduzca por lo que dependen totalmente de su estructura.

c) Redes Neuronales Artificiales

Historia

Algo que siempre ha inspirado a las personas para desarrollar nuevos caminos en la realización de cálculos matemáticos es la obtención de datos cada vez más y más certeros, exactos y reales por lo que, con el paso de los años, se han desarrollado diversos métodos para poder estar cerca de estos. El sentido de la curiosidad también ha sido aliado de quienes han avanzado en la ciencia ya que este ha permitido que las personas mantengan la idea de “¿qué pasará si...?” por largos periodos de tiempo logrando avances inimaginables en todas las ramas de la ciencia y en la sociedad. Como resultado de este don ha surgido la inquietud de igualar, o siquiera acercar, la tecnología con la obra más perfecta y capaz de todos los tiempos: el cerebro humano.

El cerebro humano se ha caracterizado como el dispositivo de almacenamiento y reconocimiento más grande de todos los tiempos llevando a la sociedad a indagar acerca de su funcionamiento, su estructura, la interacción entre sus componentes y la manera en la que arroja resultados después de haber recolectado datos empíricos o después de haber pasado por una serie de análisis de datos exactos. Por ende, diversos autores han estado tratando de replicar su estructura mediante la computación para así poder obtener los resultados más cercanos a la realidad y generar cálculos más precisos con mínimos rangos de error. Actualmente, esto se ha alcanzado con la creación de las Redes Neuronales Artificiales (RNA), este atractivo método es un nuevo modelo de procesamiento de información inspirado en la manera en la que el cerebro procesa la información, como son similares a las redes neuronales biológicas, son adecuadas para resolver problemáticas a las cuales las herramientas computacionales convencionales no pueden dar solución.

Los sistemas de cómputo tradicionales procesan la información de manera secuencial, es decir, consisten por lo general de un solo procesador que manipula instrucciones y datos que se localizan en la memoria, el procesador lee y ejecuta cada una de las instrucciones en la memoria por lo que todo sucede en una sola secuencia de operaciones; en cambio, las RNA no ejecutan instrucciones, responden en paralelo a las

entradas que se les presenta por ende, el resultado no se almacena en una posición de memoria (Castro, 2006).

Debido a la eficiencia de los procesos llevados a cabo por medio de Redes Neuronales Artificiales, se han considerado como alternativas a los métodos de computación clásicos para obtener los mejores resultados deseados. En 1936, Alan Turing fue el primero en estudiar el cerebro y considerarlo como una manera de procesamiento aplicado a la computación.

Sin embargo, un neurofisiólogo y un matemático (Warren McCulloch y Walter Pitts) lanzaron la primera teoría del funcionamiento de las neuronas, haciendo un modelo de red neuronal simple utilizando circuitos eléctricos datando como la primera Red Neuronal Artificial desarrollada. Esta consistía en una suma de las señales de entrada, multiplicadas por unos valores de pesos escogidos aleatoriamente. La entrada total era comparada con un valor preestablecido para determinar la salida de la red. Si en la comparación, la suma de las entradas multiplicadas por los pesos era mayor o igual que el valor preestablecido, la salida de la red era uno; en caso contrario la salida era cero (Castro, 2006).

En 1957, el psicólogo Frank Rosenblatt comenzó el desarrollo del Perceptrón el cual es uno de los modelos más antiguos de RNA que se utilizan en la actualidad para el reconocimiento de patrones debido a que es capaz de reconocer patrones que no se le habían presentado anteriormente. Rosenblatt descubrió que la conectividad entre las redes biológicas tiene un alto porcentaje de aleatoriedad y afirmó que la herramienta que más aplicaba era la teoría de probabilidades. Como consecuencia de su estudio, creó el fotoperceptrón, este era un dispositivo que respondía a señales ópticas imitando el funcionamiento del ojo humano que, aunque era un dispositivo de aprendizaje, inicialmente no era capaz de distinguir tramas visuales, pero mediante un proceso de aprendizaje era capaz de hacer.

Rosenblatt pudo demostrar que el perceptrón era capaz de clasificar tramas visuales correctamente, en lo que él denominaba un entorno diferenciado, en el cual cada clase

estaba formada por tramas visuales que eran similares unas a otras en algún sentido refutando el análisis de McCulloch y Pitts, en el cual dictaban que se empleaba lógica simbólica para analizar estructuras bastante idealizadas (Castro, 2006).

Actualmente, hay diversos trabajos de investigación que se han realizado y publicado en diversos campos con la finalidad de mejorar la capacidad de respuesta y simulación a sus problemáticas permitiendo que numerosas empresas nos den mejores servicios, así como la solución a conflictos en donde, por razonamiento, se obtienen resultados basados en la experiencia previa o que requieran un entrenamiento de reconocimiento y aprendizaje.

Elementos y características de una RNA

Como sabemos, el cerebro recopila toda la información mediante el proceso de sinapsis; este es llevado a cabo gracias a la conexión de las dendritas de billones de neuronas que envían la información recibida entre sí hasta generar una definición, una interpretación, un dato numérico o una experiencia en concreto como resultado final de todo el análisis previo por lo que una manera de poder replicar su funcionamiento es mediante una red neuronal artificial (RNA), la cual simula el procesamiento de la información biológico y su estructura. Esta inteligencia artificial se basa en un proceso de aprendizaje profundo donde se utilizan nodos interconectados simulando la estructura de la sinapsis de un cerebro real, la red aprende a partir de la examinación de los datos cargados generando un registro o predicción en donde si se va por una predicción incorrecta, la red replantea el proceso, se ajusta y mejora la predicción repitiendo este proceso hasta tener un dato de salida más exacto y preciso. Dentro de los elementos que componen una red neuronal artificial básica están (Figura 2. 12)

- Capa de entrada: en donde se recopila toda la información obtenida del mundo real como números o descripciones de un objeto. Dentro de esta capa se ubican los nodos de entrada en donde cada uno procesa, analiza y clasifica la información para pasarla a la siguiente capa.

- Capa oculta: puede ser una sola capa o varias capas ocultas que toman la información de la capa de entrada o de otras mismas para analizarla y filtrarla antes de pasarla a la siguiente capa o a la capa de salida.
- Capa de salida: esta última capa proporciona el resultado final de todo el procesamiento de datos previamente realizados por las capas anteriores, esta capa de salida solo tendrá un resultado ya sea que defina algo particular o de un dato cercano a la realidad.




Figura 2. 12. Estructura general de una Red Neuronal Artificial (ATRIA INNOVATION, 2019)

Como se ha mencionado anteriormente, el cerebro se rige por billones de neuronas interconectadas por lo que estos componentes emulan la función de los elementos para el procesamiento de la información del cerebro (Figura 2. 13) como:

- Dendritas
- Axón
- Sinapsis
- Neuronas receptoras
- Neuronas transmisoras




Figura 2. 13. Estructura de una red neuronal biológica (MANUAL MSD, 2022).

Dando como resultado la obtención de características esenciales como:

- Aprendizaje adaptativo: el aprendizaje adaptativo es de las capacidades más impactantes de las redes neuronales artificiales debido a que aprenden de manera ilustrativa, analizando imágenes gráficas o descriptivas, a diferenciar patrones auto ajustándose conforme se integre cada dato de entrada para que al final se obtengan resultados específicos.
- Auto-organización: debido a la capacidad de adaptación de las RNA, estas también tienen la capacidad de organizar la información mediante los filtrados y reajustes automáticos que generan provocando la generalización, la cual es la facultad de las redes neuronales de responder apropiadamente cuando se les presentan datos o situaciones a las que no había sido expuesta anteriormente (Matich, 2001).
- Tolerancia a fallos: otra maravilla de las redes neuronales es su capacidad de tomar los errores como parte del aprendizaje y entrenamiento por lo que son los primeros métodos computacionales en presentar una capacidad inherente a fallos. Las redes pueden aprender a reconocer patrones con ruido, distorsionados o incompletos. Esta es una tolerancia a fallos respecto a los datos y pueden seguir realizando su función (con cierta degradación) aunque se destruya parte de la red. La razón por la que las redes neuronales son tolerantes a los fallos es que tienen

su información distribuida en las conexiones entre neuronas, existiendo cierto grado de redundancia en este tipo de almacenamiento (Matich, 2001).

- Operación en tiempo real: dentro de las mayores necesidades de cualquier área de aplicación está la manera de respuesta de los datos y cómo se da dicho resultado por lo que implementar una inteligencia artificial es una manera de dar eficacia a esa obtención.
- Fácil inserción: el propósito de una red neuronal puede ser solamente llegar a una tarea en específico, así como también reconocer múltiples patrones gracias a una interconexión entre redes, esto se puede lograr con las herramientas computacionales existentes entrenándola, verificándola e implementándola rápidamente eliminando cualquier impedimento para implementar las redes en cualquier campo.

Mismas que son aplicadas a diversos campos de la ciencia y demás áreas partiendo desde la experiencia.

Clasificación de Redes Neuronales Artificiales (RNA) según la topología de red

- Red Neuronal Monocapa – Perceptrón Simple

El perceptrón es de las RNA más básicas existentes desde hace 50 años y de los modelos más sencillos, es clasificada como una red de propagación hacia adelante sin capas ocultas por lo que se denomina monocapa, además tiene una función de activador fuerte simétrico. La red puede contener varias neuronas, pero estas deben estar en un solo nivel y tener la misma función. Para poder operar, las entradas pueden ser binarias o continuas, aunque la salida siempre será binaria. El valor de salida de una neurona es uno cuando la suma de sus entradas multiplicadas por sus pesos sinápticos es mayor que cero, en caso contrario su salida es cero (Castro, 2006).

Este modelo asocia patrones a partir de arreglos de valores numéricos continuos durante el proceso de aprendizaje para asociarlos con los datos de salida y así arrojar los patrones más cercanos.

Debido a que este modelo solamente está formado por una capa, tiene una limitada capacidad para el reconocimiento de patrones más complejos porque, de ser introducidos más datos de entrenamiento, sería necesario implementar un mayor número de capas para realizar un filtrado y desarrollar un patrón más específico.

La estructura de la Red Neuronal Monocapa se muestra en la Figura 2. 14 en donde se logra apreciar una capa de salida de “m” neuronas y de “n” entradas a la red. Cada dato de entrada “X” pasa por cada neurona en donde se suman, se ajustan conforme la red va aprendiendo y se determinan los valores de salida “O”.




Figura 2. 14. Estructura de una Red Neuronal Monocapa (Castro, 2006).

La red tiene parte de un aprendizaje supervisado por lo que necesita conocer los valores esperados para cada una de las entradas presentadas (Castro, 2006), pero el entrenamiento del perceptrón es muy sencillo y básico; este consiste en realizar una suma de las entradas multiplicadas por su peso sináptico y en la detección del umbral que mejor haga que la entrada se ajuste a la salida, para poder llegar a estas variables se debe seguir un proceso adaptativo, el proceso inicia con valores aleatorios que se van modificando con cada lectura generando datos de salida generales.

El perceptrón aprende de manera iterativa, se expone a un conjunto de pares entrada-salida y los pesos de la red son ajustados de forma que, al final del entrenamiento, se

obtengan las salidas esperadas para cada una de estas entradas siguiendo los siguientes pasos (Calvo, Perceptrón – Red neuronal, 2018):

1. Inicializar pesos y umbrales
2. Bucle: hasta que el resultado de pesos sea aceptable para todos los ejemplos
 - 2.1 Leer valores de entrada
 - 2.2 Calcular error
 - 2.3 Actualizar pesos según el error
 - 2.3.1 Actualizar pesos de entradas
 - 2.3.2 Actualizar el umbral

El modelo monocapa solo es capaz de representar funciones lineales debido a que no dispone de capas ocultas como por ejemplo el perceptrón multicapa (Calvo, Perceptrón – Red neuronal, 2018).

- Red Neuronal Multicapa – Perceptrón Multicapa

El primer modelo de Red Neuronal Multicapa fue desarrollado por Paul Werbos en 1974, pero no fue aceptado hasta mediados de los 80 cuando los psicólogos David Rumelhart y James McClelland publicaron el libro “Parallel Distributed Processing Group” en 1986 el cual hizo que las investigaciones en el ámbito de las redes neuronales aumentaran utilizando mayormente el modelo multicapa de Werbos.

La Red Neuronal Multicapa se basa en la estructura de un perceptrón multicapa, que al igual que el perceptrón simple, es una red de propagación hacia adelante. Se puede afirmar que este modelo es una generalización de la Red Neuronal Monocapa, la multicapa contiene dos o más capas de neuronas capaces de tener como función de activación sigmoideal logarítmica, sigmoideal tangente hiperbólica o lineal; mientras que la monocapa solo es capaz de clasificar entradas linealmente separables, esto dio como resultado el desarrollo de un nuevo algoritmo de aprendizaje para que el perceptrón multicapa pudiera funcionar.

La estructura de esta red es un poco más extensa que la anterior, el perceptrón multicapa está formado por: un vector de “n” entradas, este se selecciona conforme a la cantidad de entradas y salidas de la red; las capas ocultas, las cuales pueden tener cualquier número de neuronas, pero todas deben tener la misma función de activación; por último, la capa de “m” salidas. Cada dato de entrada “X” pasa por cada componente de las capas, analizándolos y dando los resultados por las salidas “O” como se muestra en la Figura 2. 15.




Figura 2. 15. Estructura de una Red Neuronal Multicapa (Castro, 2006).

La red perceptrón multicapa tiene una forma de entrenamiento supervisado a partir del algoritmo de retropropagación por lo que también se le conoce como Red de Retropropagación o de Propagación Hacia Atrás. Cuando se habla de una red de retropropagación, se hace referencia al tipo de aprendizaje y no a la forma de propagación de las señales durante su funcionamiento. La retropropagación consiste en propagar el error hacia atrás durante el entrenamiento, es decir, de la capa de salida hacia la capa de entrada, pasando por las capas ocultas (Castro, 2006).

Una de las grandes ventajas del perceptrón multicapa es que esta red aprovecha la naturaleza paralela de las redes neuronales para reducir el tiempo requerido por un procesador secuencial, para determinar la salida adecuada a partir de una entrada (Castro, 2006).

- Red Neuronal Convolutacional (CNN)

La primera CNN fue desarrollada en 1980 por un investigador llamado Yann LeCun, misma que lleva su apellido, esta red era capaz de reconocer dígitos a mano (manuscritos), posteriormente su utilidad de fue ampliando hasta ser utilizada en bancos y postales debido a que hacía más fácil la tarea de leer dígitos a mano.

La Red Neuronal Convolutacional también es conocida como ConvNet, la característica más notoria es que utiliza el tipo de aprendizaje profundo o deep learning, este aprende directamente de los datos para analizar imágenes o cualquier otra tarea de visión artificial. A diferencia de las redes anteriores, esta toma imágenes como datos de entrada por lo que clasifica y diferencia las imágenes como resultados en la capa de salida. Una CNN consta de decenas a cientos de capas que aprenden a diferenciar cada característica de las imágenes introducidas.

Al igual que otras redes, una CNN está formada por una capa de entrada, capas ocultas y una capa de salida, pero la salida de cada imagen convolucionada se emplea como entrada para la siguiente capa como se puede ver de manera gráfica en la Figura 2. 16 el dato de entrada va pasando por convoluciones y el resultado pasa por las convoluciones de la siguiente capa reduciendo las características analizadas hasta poder llegar a una clasificación:




Figura 2. 16. Representación del procesamiento de una Red Neuronal Convolutacional (MathWorks, 2022).

Este modelo tiene 3 capas frecuentes:

- Capa convolucional: es el bloque de construcción principal de CNN donde ocurre la mayoría de los cálculos. Necesita menos componentes, como datos de entrada, un mapa de características y un filtro (Pathak, 2022). Las CNN pueden tener varias capas convolucionales para así formar una estructura jerárquica para que las entradas de imagen se transformen en datos numéricos permitiéndole a la red comprender y clasificar los patrones.
- Capa de agrupación: se utilizan para reducir las dimensiones y se denominan reducción de resolución. Reduce los parámetros utilizados en la entrada. La operación de agrupación puede mover un filtro sobre la entrada completa como la capa convolucional, pero carece de pesos (Pathak, 2022). La agrupación puede ser de dos tipos: promedio, en donde se calcula un valor promedio y se transmite a la salida; y la máxima, en donde se determina el valor máximo enviándolo a la capa de salida.
- Capa totalmente conectada (FC): todos los nodos de una capa de salida están directamente conectados al nodo de la capa anterior en una capa totalmente conectada. Clasifica una imagen en función de las características extraídas a través de capas anteriores junto con sus filtros (Pathak, 2022).

Dentro de las ventajas de la implementación de este tipo de red está que ofrece una mayor precisión a la hora de trabajar con muchos datos o con reconocimiento de imágenes, voz y videos en tiempo real debido a que dan resultados más precisos que otras redes en donde no utilizan convolución.

- Red Neuronal Recurrente (RNN)

Las Redes Neuronales Recurrentes fueron introducidas en 1980, pero habían sido difíciles de entrenar debido a la falta de tecnología, con el paso de los años no solo se ha vuelto más accesible, sino que se ha popularizado su implementación en la industria.

Las RNN son un modelo con aprendizaje profundo como las Convolucionales, están basadas en los trabajos de David Rumelhart en 1986 y son conocidas por su capacidad de procesar y obtener información a partir de datos secuenciales como videos, la

subtitulación, procesamiento de lenguaje, análisis de sonidos, etc. Esta, en lugar de tener una función de activación que actúa en una sola dirección, tiene una función que le permite regresar a los datos de alimentación permitiendo formar ciclos creando una entrada y una salida para sí misma como se muestra en la Figura 2. 17.




Figura 2. 17. Estructura de un nodo de una Red Neuronal Recurrente (Guru99, 2022).

Las redes neuronales recurrentes basan su funcionamiento en el procesamiento de secuencias de información, agregando al cómputo de cada elemento de la secuencia, el resultado del análisis del elemento anterior. Es decir, el resultado final de una RNN será una función que agregará el procesamiento de todos los elementos de la secuencia (Arana, 2021). Las RNN generalmente aumentan la arquitectura de red multicapa convencional con la adición de ciclos que conectan nodos adyacentes o pasos de tiempo, estos ciclos constituyen la memoria interna de la red que se utiliza para evaluar las propiedades del dato actual con respecto a los datos del pasado inmediato (Arana, 2021). Cada neurona recibe la entrada de una capa anterior para poder crear toda una red con respecto al tiempo, en la Figura 2. 18 se representa la unión de cada nodo. En total cada nodo recibe dos entradas y proporciona una salida que es la próxima entrada del siguiente nodo.




Figura 2. 18. Estructura de una capa formada por los nodos de una RNN (Jordi Torres.AI, 2019).

Este tipo de modelo ha aumentado la capacidad de reconocimiento de las redes; sin embargo, traen consigo un problema llamado “Short-term memory” que deriva del desvanecimiento por lo que la red desarrolla una complicación al recordar información pasada, para resolver este problema es necesario configurar los patrones para que la red sea capaz de recordar a largo plazo.

- Redes de Base Radial (RBF)

En 1988, Broomhead y Lowe hacen la introducción de un nuevo método que sustituía al del perceptrón multicapa que se basaba en una función no lineal: las Redes de Base Radial. Este modelo novedoso se diferencia tanto en las capas de entrada como en las capas de salida en comparación con los modelos de RNA anteriormente descritos, pero mantienen los mismos elementos básicos: la capa de entrada, las capas ocultas y la capa de salida. Al igual que las anteriores, pueden utilizarse para realizar predicciones y clasificar datos; también, mantienen las mismas conexiones unidireccionales, pero lo que las diferencia de las otras es que tiene una función Gaussiana como función de activación.

Las neuronas de la capa de salida de las redes de base radial simplemente realizan una combinación lineal de las activaciones de las neuronas ocultas; la capa de entrada la componen un conjunto de neuronas que reciben las señales del exterior, transmitiéndolas a la siguiente capa sin realizar ningún procesamiento sobre dichas señales (Cevallos, 2008). Posteriormente, los nodos de la capa oculta contienen una función base

radial, reciben las señales de la capa de entrada, los procesan y los mandan a la capa de salida realizando una función lineal continua (Figura 2. 19).




Figura 2. 19. Estructura de una Red Neuronal Base Radial (Colmenares, s. f.).

El proceso de aprendizaje de este tipo de modelos puede ser de dos tipos:

- Híbrido: se implementa primero una fase no supervisada, los centros de las funciones de base radial se determinan mediante un algoritmo de clasificación no supervisado que permita dividir el espacio de patrones de entrada en clases (Cevallos, 2008). A partir de esto, número de clases será el número de neuronas ocultas en la RBF. Después, se implementa la fase supervisada en donde se pretende minimizar el error entre el valor de salida de la red y el valor de salida esperado siguiendo métodos como el de mínimos cuadrados o de la pseudoinversa.
- Totalmente supervisado: se sigue una serie de pasos con el fin de que todos los parámetros de la red como amplitudes, pesos y umbrales sean modificados mediante ecuaciones hasta conseguir la convergencia y todos los errores se estabilicen.

2.2 Estado del arte

2.2.1 Modelos de Redes Neuronales aplicados en la Ingeniería Petrolera para calcular las propiedades PVT de un aceite

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

Existen diversas ramas que pertenecen a la inteligencia artificial y una de ellas es redes neuronales. La aplicación de las redes neuronales artificiales dentro de la industria petrolera ha tenido un impacto positivo para la obtención de valores más certeros, aunque no se han podido implementar en todos los cálculos para simular las propiedades de los fluidos contenidos dentro de un yacimiento.

Varotsis et al. (1999) plantean que en las últimas décadas se han enfocado a desarrollar métodos computacionales para predecir el comportamiento PVT de los fluidos en los yacimientos a partir de dos enfoques principales: el primero implica el desarrollo de nuevas correlaciones para proporcionar predicciones de las propiedades del fluido; y el segundo, el uso de modelos de ecuaciones de estado, ambos con el fin de mejorar la derivación del conjunto completo de las propiedades físicas que describen el comportamiento PVT. Afirmaron que la aplicación de las RNA se ha popularizado para resolver problemas de ingeniería petrolera en los campos de caracterización de yacimientos, terminación y cementación de pozos, registro de pozos, simulación de yacimientos y de propiedades PVT por lo que crearon un modelo propio denominado PVT Expert que es capaz de derivar las propiedades PVT de un aceite y gas condensado incluyendo la masa constante, la liberación diferencial, la viscosidad, el agotamiento de volumen constante y estudios de separación independiente. Este modelo utilizó mediciones clave que pueden realizarse rápidamente en el laboratorio o en el lugar del pozo como entrada de la RNA; la red se entrenó con una base de datos de estudios PVT

de más de 650 fluidos de yacimientos procedentes de todo el mundo indicando como resultado un error relativo del 0.5% al 2.5% considerado menor que el proporcionado por los modelos de Ecuación de Estado (EOS) (Figura 2. 20), además de ofrecer la mejora en la precisión continua al seguir enriqueciendo su base de datos.




Figura 2. 20. Comparación de la curva Bo prevista del petróleo en el yacimiento con la generada con PVT Expert (Varotsis, 1999).

Hajizadeh (2007) plantea que la información precisa sobre el comportamiento de las fases y las propiedades de los fluidos es un elemento esencial para la gestión adecuada de los yacimientos de petróleo porque permiten evaluar escenarios de producción, optimizar la producción del yacimiento y los esquemas IOR, así como maximizar la recuperación final y optimizar la economía de la producción del pozo. Consideró que la viscosidad es la propiedad más importante de un crudo debido a que influye en el flujo del aceite a través de las rocas porosas y de las tuberías y, que se necesita un método práctico para poder predecirla a pesar de la complejidad de la composición del crudo. A partir de esto, logró obtener un modelo que predice los datos de viscosidad de un aceite utilizando redes neuronales con un enfoque de lógica difusa, logrando que éste pueda predecir y modelar los datos con éxito. La predicción de este se realizó con 54 puntos de datos para entrenamiento y 20 puntos de datos para validación, se enfocó en 4 parámetros de entrada (la presión, la temperatura, la relación gas-aceite y la densidad del aceite) y un parámetro de salida (la viscosidad), todos adaptados a informes PVT

iraníes con un sistema de lógica difusa Takagi-Sugeno y una salida múltiple MISO obteniendo un error medio en la fase de validación de 0.13474 Cp confirmando que la red neuronal desarrollada es adecuada para los problemas de ajuste estático (Figura 2. 21).




Figura 2. 21. Comparación de la viscosidad establecida con los resultados de la red neuronal utilizada por Hajizadeh (Hajizadeh, 2007).

Ikiensikimama & Azubuike (2012), mencionan que las propiedades de los fluidos son cálculos muy importantes dentro de la ingeniería, pero han existido inconvenientes como el costo elevado o la no disponibilidad de datos para realizar el cálculo, por lo que una red neuronal es capaz de abordar la inexactitud de las correlaciones empíricas utilizadas para predecir el cálculo del factor de volumen de la formación de petróleo. Ellos hicieron uso de 802 datos, divididos aleatoriamente donde el 60% se utilizó para entrenamiento, un 20% para validación y 20% para la prueba, superando así a las correlaciones empíricas obteniendo parámetros estadísticos con un rango mínimo de 0.855. El modelo RNA entrenado se probó con 160 puntos de datos que no se utilizaron previamente durante el entrenamiento y la validación. Estos datos fueron seleccionados aleatoriamente por la herramienta MATLAB para comprobar la precisión y estabilidad del

modelo. El rendimiento del modelo RNA se comparó con los datos de campo y con las predicciones de otras correlaciones empíricas como Standing (1947), Glaso (1980), Al-Marhoun (1988), Petrosky y Farshad (1993), Obomanu y Okpobiri (1987) e Ikiensikimama (2009) (Figura 2. 22).




Figura 2. 22. Comparación de la precisión estadística de las correlaciones y la RNN utilizada por Ikiensikimama y Azubuiké (Ikiensikimama & Azubuiké, 2012).

Hernández (2017), nos plantea que hay una gran cantidad de publicaciones que demuestran la efectividad de una red neuronal artificial en la predicción de dos principales propiedades y valores puntuales. Sin embargo, actualmente se desconoce las posibles publicaciones relacionadas a la generación completa del comportamiento de una propiedad del PVT por lo que desarrolló 5 modelos de redes neuronales para generar el comportamiento del factor de volumen del aceite para zonas saturadas y bajo saturadas, utilizaron 12 reportes PVT de los yacimientos de México para generar dos modelos de redes neuronales: zona saturada y bajo saturada; posteriormente, comparó con otros modelos empíricos (Figura 2. 23) teniendo como conclusión que los modelos en donde se utilizaron las redes neuronales muestran mayor exactitud por lo que se ajusta mejor a la curva real del fluido, pero también observaron que la red solo se podía aplicar en un rango muy pequeño por la cantidad de datos utilizados.




Figura 2. 23. Comparación de la curva B_o generada por la RNA propuesta y algunas correlaciones convencionales (Hernández, 2017).

También Oladipo & Jonathan (2020), nos afirman que los modelos convencionales desarrollados para calcular propiedades PVT no son eficientes para todo tipo de hidrocarburo, sino que, dependen de condiciones específicas o simplemente se ven limitados por la poca capacidad computacional lo que genera inconvenientes al momento de hacer los cálculos con variables distintas. Esta problemática los llevó a desarrollar una RNA llamada IntelliPVT, esta herramienta computacional fue alimentada por datos PVT de petróleo provenientes del Golfo de Guinea, Oriente Medio, California, Mar del Norte, Alaska y Etiopía superando a las correlaciones PVT convencionales debido a que ofrece mejores resultados, aunque el crudo no esté relacionado con las características de la región (Figura 2. 24). También, el modelo reduce los costes adicionales ya que no es necesario incluir los datos de la composición química del petróleo obteniendo un rango de error cuadrático entre 0.91-0.99 y una velocidad de cálculo elevada en comparación a otros modelos. Los autores concluyeron que la implementación de nuevos algoritmos basados en las redes neuronales da resultados más precisos, una implementación más rápida y la posibilidad de aplicarlos a todo tipo de crudos incluso a los más pesados por

lo que se obtendrá una mejor caracterización del suelo y una mejor gestión de los yacimientos.




Figura 2. 24. Comparación de la R_s establecida con la calculada por IntelliPVT (Oladipo & Jonathan, 2020).

Recopilando lo anterior, se ha observado que el progreso que han tenido las herramientas para calcular propiedades PVT ha sido beneficioso para el campo petrolero, aunque hay ciertos datos que aún no se atreven a tocar por la complejidad de su comportamiento experimental y tratamiento matemático. Sin embargo, el diseño de una red neuronal, así como su implementación, no se descarta como posibilidad de que se puedan calcular estas propiedades con mayor detalle y exactitud.

CAPÍTULO 3. PROCEDIMIENTO

En este capítulo se desarrollará la metodología de manera extensa, partiendo de la familiarización con el tema a desarrollar y los requerimientos para llevarlo a la práctica, así como la exploración de los datos recopilados y la arquitectura de los modelos y el software propuestos.

3.1 Familiarización y aprendizaje con Python

Como introducción al modelo se leyeron artículos y libros que describieran lo necesario para poder iniciar a programar en Python. Entre los libros destacan: “Python Machine Learning by example” por Yuxi Hayden Liu y “Machine Learning for dummies a Wiley Brand” por John Paul Mueller y Luca Massaron, que contienen lo necesario para comprender el tema de Machine Learning (Figura 3. 1).




Figura 3. 1. Libros citados para la elaboración del modelo de red neuronal.

A partir de esto, se seleccionaron los parámetros necesarios para poder iniciar el desarrollo del código de la red neuronal.

3.1.1 Librerías

- Pandas: es una librería de código abierto enfocada al análisis y manejo flexible de datos con estructura unidimensional o bidimensional. Representa los datos en forma de tabla, lo cual permite el manejo sencillo de los conjuntos creados, permitiendo las operaciones entre columnas o datos, la búsqueda y filtrado, el tratamiento, la integración e incluso la transformación de datos (Mora, 2023).
- Matplotlib: es una librería enfocada a la creación de gráficos para la interpretación y visualización de datos en 2D. Está construida sobre Numpy y se integra fácilmente con otras librerías como Pandas (Mora, 2023).
- Scikit-learn: ampliamente utilizada en el ámbito del Machine Learning. Esta aporta métodos para el preprocesado y transformación de datos para el entrenamiento de algoritmos de inteligencia artificial, así como el entrenamiento y la evaluación de los modelos de manera sencilla (Mora, 2023).
- Numpy: es una librería usual para la ciencia de datos, debido a que permite el cálculo orientado a matrices. Ofrece un nuevo objeto “array”, el cual es una estructura de matrices n-dimensionales, que permite un almacenamiento interno en memoria para un manejo eficaz; y, la posibilidad de llamar funciones de forma vectorizada (Mora, 2023).
- TensorFlow: está enfocada al cálculo numérico, la cual hace uso por debajo de grafos acíclicos dirigidos (DAG) para representar las operaciones y el cómo suceden al momento de ejecutar procesos complejos. Es ampliamente utilizada en problemas de inteligencia artificial permitiendo que las operaciones sean independientes del código subyacente mediante el uso de grafos, lo cual hace que sean portables y editables en otros formatos (Mora, 2023).
- Keras: está diseñada para trabajar en conjunto a TensorFlow, está enfocada en simplificar el desarrollo de algoritmos de Machine Learning minimizando el número de acciones requeridas para la creación de los códigos por el usuario (Mora, 2023).

3.1.2 Funciones de activación

En redes neuronales artificiales, una función de activación es una función matemática que se aplica a la salida de cada neurona en una capa para introducir no linealidades en el modelo. Estas funciones son esenciales para que la red neuronal pueda aprender patrones y relaciones más complejas en los datos.

Algunas de las funciones más comunes son:

- Sigmoide (logística: “sigmoid”)

Produce una salida en el rango de 0 a 1, lo que la hace adecuada para problemas de clasificación binaria. Es útil cuando se necesita una probabilidad de pertenencia a una clase. Se define como (Ecuación 3. 1 y Figura 3. 2):

$$\sigma(x) = \frac{1}{1 + e^{-x}}$$

Ecuación 3. 1. Definición de la función sigmoide (*Rubiales, 2020*).




Figura 3. 2. Gráfica de la función sigmoide (*Rubiales, 2020*).

- Tangente hiperbólica (“tanh”)

Similar a la función sigmoide, pero produce una salida en el rango -1 a 1. Es útil en problemas de clasificación y regresión ya que es derivable y continua. A diferencia de la función sigmoide, esta tiene media de 0 y desviación típica de 1. Se define como (Ecuación 3. 2 y Figura 3. 3):

$$\tanh(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}}$$

Ecuación 3. 2. Definición de la función tangente hiperbólica (Rubiales, 2020).




Figura 3. 3. Gráfica de la función tangente hiperbólica (Rubiales, 2020).

- Rectified Linear Unit (“ReLU”)

Es de las más eficientes y va de 0 a $+\infty$. Esta función devuelve x para valores positivos y 0 para valores negativos, es comúnmente utilizada en las capas ocultas para problemas de clasificación y regresión. Se define como (Ecuación 3. 3 y Figura 3. 4)

$$f(x) = \max(0, x)$$

Ecuación 3. 3. Definición de la función RELU (Rubiales, 2020).




Figura 3. 4. Gráfica de la función RELU (Rubiales, 2020).

- Softmax:

Esta función es comúnmente utilizada en la capa de salida de los modelos de clasificación multiclase, convierte un vector de números reales en una distribución de probabilidad. Se define como (Ecuación 3. 4):

$$s(y_i) = \frac{e^{y_i}}{\sum_{j=1}^J e^{y_j}}$$

Ecuación 3. 4. Definición de la función softmax (Rubiales, 2020).

- Gaussian Error Linear Unit (“GELU”)

Es conocida por su comportamiento suavizado y es efectiva solo para algunas arquitecturas de red. Generalmente se utiliza en conjunto de otras funciones como RELU y sus atributos se deben a la inclusión de la función tangente hiperbólica y la operación de multiplicación. Tiene un rango de salida desde 0 a $+\infty$ y se implementa en las capas ocultas para problemas de clasificación y regresión. Se define como (Ecuación 3. 5):

$$GELU(x) = 0.5x(1 + \tanh\left(\sqrt{\frac{2}{\pi}}(x + 0.044715x^3)\right))$$

Ecuación 3. 5. Definición de la función GELU (Rubiales, 2020).

- Softplus

Se utiliza comúnmente en las capas ocultas de la red y tiene un rango de salida de 0 a $+\infty$. Esta es una versión suavizada de la función ReLu. Se define como (Ecuación 3. 6):

$$softplus(x) = \ln(1 + e^x)$$

Ecuación 3. 6. Definición de la función softplus (Rubiales, 2020).

3.1.3 Algoritmos de práctica

Para la introducción de las redes neuronales se realizaron ejemplos básicos obtenidos de los libros previamente mencionados con la finalidad de comprender mejor la estructura y la interacción de todos sus elementos básicos, tales como:

- Red Neuronal Convolutacional (CNN)

Este ejemplo utiliza una base de datos ya establecida que comprende 60000 datos de entrenamiento y 10000 de prueba (<https://github.com/zalandoresearch/fashion-mnist>), el modelo da como ejemplo una imagen de 28 x 28 píxeles que representa un artículo de diez grupos de prendas de vestir (Mueller, 2021).

```
from tensorflow import keras
import matplotlib.pyplot as plt

loader = keras.datasets.fashion_mnist.load_data
(x_train, y_train), (x_test, y_test) = loader()
class_names = {0: 'T-shirt/top', 1: 'Trouser',
                2: 'Pullover', 3: 'Dress', 4: 'Coat',
                5: 'Sandal', 6: 'Shirt', 7: 'Sneaker',
                8: 'Bag',
                9: 'Ankle boot'}
fig, ax = plt.subplots(5, 5, figsize=(10, 10), dpi=90)
```

```

for i in range(25):
    plt.subplot(5,5,i+1)
    plt.imshow(x_train[i], cmap=plt.cm.binary)
    plt.xticks([])
    plt.yticks([])
    plt.grid(False)
    plt.xlabel(class_names[y_train[i]])
plt.show()
num_classes = 10
x_train = (x_train / 255.).reshape(-1, 28, 28, 1)
x_test = (x_test / 255.).reshape(-1, 28, 28, 1)
model = keras.models.Sequential()
model.add(keras.layers.Input(shape=(28, 28, 1)))
model.add(keras.layers.Conv2D(filters=32, kernel_size=(3, 3), activation='relu'))
model.add(keras.layers.Conv2D(64, (3, 3), activation='relu'))
model.add(keras.layers.MaxPooling2D(pool_size=(2, 2)))
model.add(keras.layers.Flatten())
model.add(keras.layers.Dense(32, activation='relu'))
model.add(keras.layers.Dropout(0.2))
model.add(keras.layers.Dense(num_classes, activation='softmax'))
model.compile(optimizer='adam', loss='sparse_categorical_crossentropy', metrics=['acc'])
model.summary()
model.fit(x_train, y_train, batch_size=64, epochs=11, verbose=1, validation_split=0.2)
score = model.evaluate(x_test, y_test, verbose=0)
print(f'Accuracy on test set: {score[1]:0.3}')

```



Figura 3. 5. Ejemplos de cada conjunto seleccionados por la CNN (Mueller, 2021).

- Red Bayesiana

Este ejemplo usa una base de datos precargada de 4601 emails con spam y no spam (<https://github.com/lmassaron/datasets/>), el código clasifica los emails y los agrupa en las dos categorías anteriores (Mueller, 2021).

```
import pandas as pd
from sklearn.model_selection import cross_val_predict
from sklearn.naive_bayes import BernoulliNB
from sklearn.metrics import classification_report
filename = 'https://github.com/lmassaron/datasets/'
filename += 'releases/download/1.0/spam.feather'
spam = pd.read_feather(filename)
X = spam.iloc[:, :-1]
y = spam.iloc[:, -1]
nb = BernoulliNB()
preds = cross_val_predict(nb, X, y, cv=5, n_jobs=-1)
cr = classification_report(y_true=y, y_pred=preds, target_names=['non spam', 'spam'])
print(cr)
```

	precision	recall	f1-score	support
non spam	0.89	0.92	0.90	2788
spam	0.87	0.82	0.84	1813
accuracy			0.88	4601
macro avg	0.88	0.87	0.87	4601
weighted avg	0.88	0.88	0.88	4601

Figura 3. 6. Reporte de correos recibidos por la Red Bayesiana (Mueller, 2021).

- Regresión Lineal

Este código genera valores aleatorios del 0 al 20 y a partir de la ecuación $y = wx + b$ buscará los mejores valores para predecir la intersección en “y” para un número dado (Martínez, 2018).

```
import numpy as np
import matplotlib.pyplot as plt
from sklearn.linear_model import LinearRegression
from sklearn.metrics import mean_squared_error
def f(x): # función f(x) = 0.1*x + 1.25 + 0.2*Ruido_Gaussiano
    np.random.seed(42) # para poder reproducirlo
    y = 0.1*x + 1.25 + 0.2*np.random.randn(x.shape[0])
    return y
x = np.arange(0, 20, 0.5) # generamos valores x de 0 a 20 en intervalos de 0.5
```

```

y = f(x) # calculamos y a partir de la función que hemos generado
# hacemos un gráfico de los datos que hemos generado
regresion_lineal = LinearRegression() # creamos una instancia de LinearRegression
# instruimos a la regresión lineal que aprenda de los datos (x,y)
regresion_lineal.fit(x.reshape(-1,1), y)
# vemos los parámetros que ha estimado la regresión lineal
print('w = ' + str(regresion_lineal.coef_) + ', b = ' + str(regresion_lineal.intercept_))
# vamos a predecir y = regresion_lineal(5)
nuevo_x = np.array([5])
prediccion = regresion_lineal.predict(nuevo_x.reshape(-1,1))
print(prediccion)
# Predecimos los valores y para los datos usados en el entrenamiento
prediccion_entrenamiento = regresion_lineal.predict(x.reshape(-1,1))
# Calculamos el Error Cuadrático Medio (MSE = Mean Squared Error)
mse = mean_squared_error(y_true = y, y_pred = prediccion_entrenamiento)
# La raíz cuadrada del MSE es el RMSE
rmse = np.sqrt(mse)
print('Error Cuadrático Medio (MSE) = ' + str(mse))
print('Raíz del Error Cuadrático Medio (RMSE) = ' + str(rmse))
# calculamos el coeficiente de determinación R2
r2 = regresion_lineal.score(x.reshape(-1,1), y)
print('Coeficiente de Determinación R2 = ' + str(r2))
plt.title("Datos")
plt.xlabel('X')
plt.ylabel('Y')
plt.scatter(x,y,label='Datos', color='blue')
plt.plot(x,prediccion_entrenamiento, color = "red", label = "Regresión Lineal")
plt.legend()
plt.show()

```




Figura 3. 7. Gráfico de los datos predichos vs la regresión lineal, los valores para “w” y “b” generados por la regresión y el cálculo de “y” (Martínez, 2018).

3.2 Generación de base de datos (dataset)

3.2.1 Adquisición de datos

Para la adquisición de las bases de datos se tomaron diferentes artículos relacionados con el tema de propiedades PVT, y se tomaron las columnas de datos necesarias para cada modelo. Debido a que los archivos provenían de diferentes pozos de Oriente Medio, se hizo la conversión de unidades para que no hubiera ningún inconveniente con el manejo de la información.

Para el factor volumétrico se obtuvieron 713 puntos de datos (Tabla 4. 1Tabla 4. 1. Valores estadísticos para la base de datos de factor volumétrico.), los cuales contaban con temperatura, presión, relación de solubilidad y gravedad API:

Tabla 4. 1. Valores estadísticos para la base de datos de factor volumétrico.

	TEMPERATURA (°F)	PRESIÓN (PSIA)	RS (SCF/STB)	API	OFVF
DATOS	713	713	713	713	713
MEDIA	205.414586	1954.788509	569.137023	33.683969	1.38981
MÍNIMO	80	1.141	0	6	1
MÁXIMO	341.6	10347	3298.66	56.8	2.91
DES. ESTÁNDAR	47.803098	1619.565936	496.826452	9.589128	0.304718

Para la viscosidad se obtuvieron 711 puntos de datos (Tabla 4. 2), los cuales contaban con temperatura, presión, relación de solubilidad y gravedad API:

Tabla 4. 2. Valores estadísticos para la base de datos de la viscosidad.

	TEMPERATURA (°F)	PRESIÓN (PSIA)	RS (SCF/STB)	API	OFVF
DATOS	711	711	711	711	711
MEDIA	2805.908987	563.397468	195.478978	32.835584	2.960364

MÍNIMO	29.7	0	80.6	10	0.093
MÁXIMO	7126.13	3298.66	341.6	56.8	29
DES. ESTÁNDAR	1705.757123	413.213951	47.176885	9.274014	5.825744

3.2.2 Análisis de datos

Como análisis exploratorio de los datos se sacaron las gráficas de caja (Figura 3. 8 y Figura 3. 9) y los histogramas (Figura 3. 10 y Figura 3. 11) correspondientes para conocer la distribución de cada variable (T, P, RS, API, Bo y Uo).




Figura 3. 8. Gráficas de caja para los datos del factor volumétrico.




Figura 3. 9. Gráficas de caja para los datos de viscosidad.




Figura 3. 10. Histogramas para los datos de factor volumétrico.




Figura 3. 11. Histogramas para los datos de viscosidad.

3.3 Generación del modelo

3.3.1 Especificaciones técnicas

Para la ejecución del modelo se utilizó un equipo de cómputo con las siguientes especificaciones:

- Procesador: 11th Gen Intel(R) Core(TM) i7-1165G7 @ 2.80GHz 2.80 GHz
- RAM: 16.0 GB
- Tipo de sistema: Sistema operativo de 64 bits, procesador basado en x64
- Edición: Windows 11 Home
- Versión: 23H2
- Versión del sistema operativo: 22631.3155

En conjunto con las siguientes versiones de librerías para hacer la arquitectura de la red, las evaluaciones y los gráficos:

- Pandas 2.0.3
- Matplotlib 3.7.5

- Keras 2.13.1
- Tensorflow 2.13.0
- Numpy 1.24.3
- Scikit-learn 1.3.2

3.3.2 Red Neuronal para viscosidad

Tabla 4. 3. Descripción general del modelo de red neuronal para viscosidad.

CAPAS DE ENTRADA	CAPAS OCULTAS	CAPAS DE SALIDA	OPTIMIZADOR	FUNCIONES DE ACTIVACIÓN	VARIABLES DE ENTRADA	VARIABLES DE SALIDA
1	7	1	RMS de Keras	relu, gelu	T, P, RS, API	Uo

```
import numpy as np
import pandas as pd
import tensorflow as tf
import keras
from keras import layers
import matplotlib.pyplot as plt
from sklearn.model_selection import train_test_split

def build_model():
    model= keras.Sequential([
        layers.Dense(64, activation='relu', input_shape=[4]), #4 es num de entrada de datos
        layers.Dense(32, activation='gelu'),
        layers.Dense(32, activation='gelu'),
        layers.Dense(32, activation='relu'),
        layers.Dense(32, activation='gelu'),
        layers.Dense(32, activation='relu'),
        layers.Dense(32, activation='gelu'),
        layers.Dense(64, activation='relu'),
        layers.Dense(1)
    ])

    optimizer = tf.keras.optimizers.RMSprop(learning_rate=0.00035)
    model.compile(loss='mse', optimizer=optimizer, metrics=['mae', 'mse'])
    return model

df = pd.read_csv("C:/Users/Monse/Documents/Codigos_Tesis/Datos_Totales/Datos_TU.csv")
#print(df)
v=df.loc[df.loc[:, "U"] <= 30]
```

```

#print(v)
dataset=v.values
X= dataset[:,0:4]
Y= dataset[:,4]

X_train, X_val, y_train, y_val = train_test_split(X, Y, test_size=0.2, random_state=42)

model= build_model()
model.fit(X_train, y_train, epochs=5500, verbose=1)

test_predic_e = model.predict(X_train).flatten()

plt.figure(figsize=(10, 6))
a = plt.axes(aspect= 'equal')
plt.scatter(y_train, test_predic_e)
plt.xlabel('X')
plt.ylabel('Y')
plt.title('Modelo de RNA para Viscosidad')
_=plt.plot(y_train,y_train, color='orange')

plt.figure(figsize=(10, 6))
plt.xlabel('X')
plt.ylabel('Y')
plt.plot(range(len(y_train)), y_train, 'b-', label='Uo PVT')
plt.plot(range(len(y_train)), test_predic_e, 'r-', label='Uo por modelo RNA')
plt.xlabel('Número de datos')
plt.ylabel('Rango (Uo)')
plt.title('Resultados de los valores de Viscosidad - Dataset de entrenamiento')
plt.legend()

test_predic_v = model.predict(X_val).flatten()

plt.figure(figsize=(10, 6))
plt.xlabel('X')
plt.ylabel('Y')
plt.plot(range(len(y_val)), y_val, 'b-', label='Uo PVT')
plt.plot(range(len(y_val)), test_predic_v, 'r-', label='Uo por modelo RNA')
plt.xlabel('Número de datos')
plt.ylabel('Rango (Uo)')
plt.title('Resultados de los valores de Viscosidad - Dataset de validación')
plt.legend()

from sklearn.metrics import mean_squared_error
from sklearn.metrics import r2_score

```

```

# Calcular el Mean Squared Error (MSE) y R-squared (R2) para set de entrenamiento
mse = mean_squared_error(y_true=y_train, y_pred=test_predic_e)
r2 = r2_score(y_true=y_train, y_pred=test_predic_e)
rmse = np.sqrt(mean_squared_error(y_true=y_train, y_pred=test_predic_e))

# Imprimir los resultados
print("Valores para set de entrenamiento")
print(f"Mean Squared Error (MSE) for training set: {mse:.4f}")
print(f"R-squared (R2) for training set: {r2:.4f}")
print(f"RMSE for training set: {rmse:0.4f}")

# Calcular el Mean Squared Error (MSE) y R-squared (R2) para set de validación
mse = mean_squared_error(y_true=y_val, y_pred=test_predic_v)
r2 = r2_score(y_true=y_val, y_pred=test_predic_v)
rmse = np.sqrt(mean_squared_error(y_true=y_val, y_pred=test_predic_v))

# Imprimir los resultados
print("Valores para set de validación")
print(f"Mean Squared Error (MSE) for validation set: {mse:.4f}")
print(f"R-squared (R2) for validation set: {r2:.4f}")
print(f"RMSE for validation set: {rmse:0.4f}")

plt.show()

#model.save('C:/Users/Monse/Documents/Codigos_Tesis/UO') #Guardar modelo

```

3.3.3 Red Neuronal para factor volumétrico

Tabla 4. 4. Descripción general del modelo de red neuronal para el factor volumétrico.

CAPAS DE ENTRADA	CAPAS OCULTAS	CAPAS DE SALIDA	OPTIMIZADOR	FUNCIONES DE ACTIVACIÓN	VARIABLES DE ENTRADA	VARIABLES DE SALIDA
1	4	1	RMS de Keras	gelu	T, P, RS, API	Bo

```

import numpy as np
import pandas as pd
import tensorflow as tf
import keras
from keras import layers
import matplotlib.pyplot as plt
from sklearn.model_selection import train_test_split

```

```

def build_model():
    model= keras.Sequential([
        layers.Dense(128, activation='gelu', input_shape=[4]), #4 es num de entrada de datos
        layers.Dense(64, activation='gelu'),
        layers.Dense(64, activation='gelu'),
        layers.Dense(64, activation='gelu'),
        layers.Dense(128, activation='gelu'),
        layers.Dense(1)
    ])

    optimizer = tf.keras.optimizers.RMSprop(learning_rate=0.0005)
    model.compile(loss='mse', optimizer=optimizer, metrics=['mae', 'mse'])
    return model

df = pd.read_csv("C:/Users/Monse/Documents/Codigos_Tesis/Datos_Totales/Datos_TB0.csv")
#print(df)
dataset = df.values
X= dataset[:,0:4]
y= dataset[:,4]

X_train, X_val, y_train, y_val = train_test_split(X, y, test_size=0.2, random_state=42)

model= build_model()
model.fit(X_train, y_train, epochs=500, verbose=1)

test_predic_e = model.predict(X_train).flatten()

plt.figure(figsize=(10, 6))
a = plt.axes(aspect= 'equal')
plt.scatter(y_train, test_predic_e)
plt.xlabel('X')
plt.ylabel('Y')
plt.title('Modelo de RNA para Factor Volumétrico')
_=plt.plot(y_train,y_train, color='orange')

plt.figure(figsize=(10, 6))
plt.xlabel('X')
plt.ylabel('Y')
plt.plot(range(len(y_train)), y_train, 'b-', label='Bo PVT')
plt.plot(range(len(y_train)), test_predic_e, 'r-', label='Bo por modelo RNA')
plt.xlabel('Número de datos')
plt.ylabel('Rango (Bo)')
plt.title('Resultados de los valores de Factor Volumétrico - Dataset de entrenamiento')
plt.legend()

```

```

test_predic_v = model.predict(X_val).flatten()

plt.figure(figsize=(10, 6))
plt.xlabel('X')
plt.ylabel('Y')
plt.plot(range(len(y_val)), y_val, 'b-', label='Bo PVT')
plt.plot(range(len(y_val)), test_predic_v, 'r-', label='Bo por modelo RNA')
plt.xlabel('Número de datos')
plt.ylabel('Rango (Bo)')
plt.title('Resultados de los valores de Factor Volumétrico - Dataset de validación')
plt.legend()

from sklearn.metrics import mean_squared_error
from sklearn.metrics import r2_score

# Calcular el Mean Squared Error (MSE) y R-squared (R2) para set de entrenamiento
mse = mean_squared_error(y_true=y_train, y_pred=test_predic_e)
r2 = r2_score(y_true=y_train, y_pred=test_predic_e)
rmse = np.sqrt(mean_squared_error(y_true=y_train, y_pred=test_predic_e))

# Imprimir los resultados
print("Valores para set de entrenamiento")
print(f"Mean Squared Error (MSE) for training set: {mse:.4f}")
print(f"R-squared (R2) for training set: {r2:.4f}")
print(f"RMSE for training set: {rmse:0.4f}")

# Calcular el Mean Squared Error (MSE) y R-squared (R2) para set de validación
mse = mean_squared_error(y_true=y_val, y_pred=test_predic_v)
r2 = r2_score(y_true=y_val, y_pred=test_predic_v)
rmse = np.sqrt(mean_squared_error(y_true=y_val, y_pred=test_predic_v))

# Imprimir los resultados
print("Valores para set de validación")
print(f"Mean Squared Error (MSE) for validation set: {mse:.4f}")
print(f"R-squared (R2) for validation set: {r2:.4f}")
print(f"RMSE for validation set: {rmse:0.4f}")

plt.show()

#model.save('C:/Users/Monse/Documents/Codigos_Tesis/BO') #Guardar modelo

```

3.4 Propuesta de software para su ejecución

Se propuso un diseño fácil de manipular y comprender, agradable y útil para el usuario. La interfaz se desarrolló en QtDesigner en conjunto con Python, como única pantalla interactiva, y tiene el objetivo de facilitar el cálculo del factor volumétrico y la viscosidad a partir de la lectura de archivos “Excel” implementando los dos modelos de redes neuronales generados en este trabajo.

La interfaz se compone principalmente de un espacio para datos del usuario (1), un espacio para carga de datos (2) (Figura 3. 13 y Figura 3. 14) y una sección para realizar los cálculos de viscosidad y factor volumétrico (3), ya sea de manera individual o tomando en cuenta un archivo “Excel” como se muestra en la Figura 3. 12.

Dentro de las funciones agregadas al software están:

- Abrir: la cual permite leer un archivo “excel” para la comodidad del usuario.
- Nuevo: la cual permite limpiar las 3 secciones para volver a cargar un archivo diferente y hacer cálculos individuales sin la necesidad de eliminar los datos de cada espacio.
- Guardar: la cual permite guardar los datos de la tabla en un archivo “excel” y guardar cambios en el mismo archivo.
- Guardar cómo: esta permite guardar los datos en archivo “excel” o “csv” cuando así se desee.
- Imprimir: permite mandar los datos de la tabla y la sección de información a una impresora conectada a la computadora o solo mandarlo como PDF.
- Botón de ayuda: aquí se encuentran las unidades en las que deben estar los datos para realizar el cálculo correcto de las propiedades.
- Cambio de unidades: estos se activan cuando se carga la tabla de datos y permite al usuario convertir los valores de todas las columnas de manera automática considerando las unidades más comunes.
- Generador de valores individuales: permite al usuario calcular la propiedad cuando solo se tiene uno o dos valores de manera manual.

- Cuadro de datos: en este apartado se permite al usuario incluir y editar la información técnica del aceite y pozo.




Figura 3. 12. Interfaz propuesta para la ejecución de los modelos de Redes Neuronales Artificiales generados.




Figura 3. 13. Ejecución de la selección de un archivo "excel" para cargarlo al software.




Figura 3. 14. Carga de datos en el software propuesto.

CAPÍTULO 4. RESULTADOS

En este capítulo se desarrollarán de manera simple y concisa los objetivos alcanzados con los modelos desarrollados, las interpretaciones gráficas, los valores estadísticos de cada modelo para los datos de entrenamiento y prueba y el final que alcanzó el desarrollo del proyecto.

4.1 Modelo para viscosidad

4.1.1 Resultados para el dataset de entrenamiento y el dataset de validación

Se utilizó un dataset de 711 puntos de datos, el cual se dividió un set del 80% de datos para entrenamiento y 20% para el set de validación del modelo, ambos de manera aleatoria.

El modelo para viscosidad fue el que obtuvo mejores resultados estadísticos para ambos datasets (Tabla 4. 5) los cuales se puede visualizar en la Figura 4. 2 para los datos de entrenamiento y en la Figura 4. 3 para los datos de validación; sin embargo, el modelo solo es aplicable para viscosidades menores a 30 Cp debido al rango de datos con los que fue entrenado (Figura 4. 1).

Tabla 4. 5. Resultados de las bases de datos para entrenamiento y validación del modelo para viscosidad.

Set de datos	R2	MSE	RMSE
Entrenamiento	0.9956	0.1484	0.3852
Validación	0.8162	6.2026	2.4906




Figura 4. 1. Margen de error entre los datos generados (puntos azules) y los datos reales (línea naranja) para viscosidad.




Figura 4. 2. Comparación de los resultados obtenidos por la red neuronal generada (línea roja) y los datos reales con los que se entrenó el modelo (línea azul).




Figura 4. 3. Comparación de los resultados obtenidos por la red neuronal generada (línea roja) y los datos reales con los que se validó el modelo (línea azul).

4.1.2 Resultados de la estimación de la viscosidad para un aceite bajo saturado

Se tomó un archivo que contaba con 93 puntos de datos correspondientes a un aceite bajo saturado (véase anexo: a) Base de datos de un aceite bajo saturado para la viscosidad), el cual también fue parte de la base de datos para el entrenamiento de la red neuronal, con la finalidad de realizar la estimación de la viscosidad a partir del modelo generado y comparar los resultados con los datos reales como se ve en la Figura 4. 4.

En las gráficas se puede observar la cercanía de ambos valores con una variación más alta en resultados menores a 0.5. La generación de esta propiedad está basada en la presión (psia), temperatura (°F), gravedad API y la relación de solubilidad (scf/stb) que son los parámetros más comunes en los archivos PVT provocando que el modelo sea más aplicable; al contrario de las correlaciones convencionales, que tienen que contar con otras viscosidades y varias constantes de cálculo en sus ecuaciones.




Figura 4. 4. Gráfica comparativa de los valores de la viscosidad obtenidos por un reporte PVT y por el modelo de RNA desarrollado.

4.2 Modelo para factor volumétrico

4.2.1 Resultados para el dataset de entrenamiento y el dataset de validación

Se utilizó un dataset de 713 puntos de datos, el cual se dividió un set del 80% de datos para entrenamiento y 20% para el set de validación del modelo, ambos de manera aleatoria.

El modelo para factor volumétrico dio buenos resultados estadísticos para ambos datasets (Tabla 4. 6) los cuales se puede visualizar en la Figura 4. 6 para los datos de entrenamiento y en la Figura 4. 7 para los datos de validación; sin embargo, el modelo solo es aplicable para mezclas con un factor volumétrico estimado de 1 a 3 debido al rango de datos con los que fue entrenado (Figura 4. 5). Margen de error entre los datos generados (puntos azules) y los datos reales (línea naranja) para factor volumétrico.).

Tabla 4. 6. Resultados de las bases de datos para entrenamiento y validación del modelo para factor volumétrico.

Set de datos	R2	MSE	RMSE
Entrenamiento	0.9831	0.0014	0.0377
Validación	0.9818	0.0023	0.0477




Figura 4. 5. Margen de error entre los datos generados (puntos azules) y los datos reales (línea naranja) para factor volumétrico.




Figura 4. 6. Comparación de los resultados obtenidos por la red neuronal generada (línea roja) y los datos reales con los que se entrenó el modelo (línea azul).




Figura 4. 7. Comparación de los resultados obtenidos por la red neuronal generada (línea roja) y los datos reales con los que se validó el modelo (línea azul).

4.2.2 Resultados de la estimación del factor volumétrico para un aceite bajo saturado

Se tomó un archivo que contaba con 185 puntos de datos correspondientes a un aceite bajo saturado (véase anexo: b) Base de datos de un aceite bajo saturado para el factor volumétrico) el cual también fue parte de la base de datos para el entrenamiento de la red neuronal, con la finalidad de realizar la estimación del factor volumétrico a partir del modelo generado y la correlación de Standing (ecuación 2.37) descrita en el capítulo 2.

Para la predicción de los valores con la ecuación de Standing se necesitaron los valores de la temperatura ($^{\circ}\text{R}$), la gravedad específica del aceite y gas y la relación de solubilidad (scf/stb); en cambio, con el modelo de red se utilizaron los valores de presión (psia), temperatura ($^{\circ}\text{F}$), gravedad API y la relación de solubilidad (scf/stb) que son los parámetros más comunes en los archivos PVT.

Posteriormente, se hizo la comparativa con los datos reales para poder visualizar el error entre los dos métodos implementados (mismos que se muestran en las gráficas de la Figura 4. 8.) y se pudo observar la similitud entre ambas formas de cálculo. Para esta propiedad se obtuvo que en la correlación de Standing se tiene un error promedio de 1.2% y para la RNA de 1.7%; sin embargo, el modelo de RNA mostró que tiene menos variaciones en valores mayores a 2.5 en comparación con el método de Standing (Figura 4. 8) y que no necesita de la gravedad específica del gas para poder calcular el Bo, siendo una ventaja para aquellos archivos en donde no se tengan muchas propiedades del crudo.




Figura 4. 8. Gráfica comparativa de los valores del factor volumétrico obtenidos por un reporte PVT, por el modelo de RNA desarrollado y por la correlación de Standing (1981).

4.3 Software diseñado

El software diseñado se logró ejecutar de manera satisfactoria y acorde a como se había planeado. Se logró leer archivos con varios puntos de datos (Figura 4. 9 y Figura 4. 10), así como generar algunos de los valores a partir de esa información obtenida como se ve en la Figura 4. 11.

OIL_NET

	Temperatura	Presión	RS	Gravedad API	Viscosidad
	Unidad	Unidad	Unidad	Unidad	Cp
1	170.06	127.83	313.35	23.7	2.2643094
2	179.96	2432.58	263.04	17.9	3.5278544
3	170.96	3224.8	621.59	25.6	1.2472129
4	179.96	3364.19	582.06	23.6	1.1290872
5	170.06	1636.11	293.42	18.2	2.466905
6	170.06	3762.42	382.91	21.7	1.9401699
7	190.04	2077.01	442.04	21.1	1.9233696
8	177.8	3150.84	527.27	21.8	1.51555

~ WELL INFORMATION ~

- Oil Type:
 - Service Company:
 - User Name:
 - Well Name:
 - Field Name:
 - Field Location:

* Calcular columnas *

* Generar valor de Factor Volumétrico *

☒

T(°F) P(psie) RS(cst/stb) API Bo

* Generar valor de Viscosidad *

☒

T(°F) P(psie) RS(cst/stb) API Uo(cP)

Figura 4. 9. Carga de datos y cálculo de la viscosidad.

OIL_NET

	Temperatura	Presión	RS	Gravedad API	Factor Volumétrico
	Unidad	Unidad	Unidad	Unidad	Adimensional
1	170.06	127.83	313.35	23.7	1.1313249
2	179.96	2432.58	263.04	17.9	1.8963112
3	170.96	3224.8	621.59	25.6	1.9431828
4	179.96	3364.19	582.06	23.6	1.9676911
5	170.06	1636.11	293.42	18.2	1.672028
6	170.06	3762.42	382.91	21.7	1.8277426
7	190.04	2077.01	442.04	21.1	1.8175958
8	177.8	3150.84	527.27	21.8	1.9374287

~ WELL INFORMATION ~

- Oil Type:
 - Service Company:
 - User Name:
 - Well Name:
 - Field Name:
 - Field Location:

* Calcular columnas *

* Generar valor de Factor Volumétrico *

☒

T(°F) P(psie) RS(cst/stb) API Bo

* Generar valor de Viscosidad *

☒

T(°F) P(psie) RS(cst/stb) API Uo(cP)

Figura 4. 10. Carga de datos y cálculo del factor volumétrico.

OIL_NET

	Temperatura	Presión	RS	Gravedad API	Factor Volumétrico
	Unidad	Unidad	Unidad	Unidad	Adimensional
1	170.06	127.83	313.35	23.7	1.1313249
2	179.96	2432.58	263.04	17.9	1.8963112
3	170.96	3224.8	621.59	25.6	1.9431828
4	179.96	3364.19	582.06	23.6	1.9676911
5	170.06	1636.11	293.42	18.2	1.672028
6	170.06	3762.42	382.91	21.7	1.8277426
7	190.04	2077.01	442.04	21.1	1.8175958
8	177.8	3150.84	527.27	21.8	1.9374287

~ WELL INFORMATION ~

- Oil Type:
- Service Company:
- User Name:
- Well Name:
- Field Name:
- Field Location:

* Calcular columnas *

* Generar valor de Factor Volumétrico *

170.06	127.83	313.35	23.7	1.13132	✓
T(°C)	P(psi)	RS(pci/stb)	API	Bo	

* Generar valor de Viscosidad *

170.06	127.83	313.35	23.7	2.26430	✓
T(°C)	P(psi)	RS(pci/stb)	API	Vis(Cp)	

Figura 4. 11. Cálculo de valores individuales para la viscosidad y el factor volumétrico.

CONCLUSIONES

Con la finalización de este proyecto se pudo asegurar que las Redes Neuronales Artificiales (RNA) agilizan el cálculo de variables en cualquier ámbito y en cualquier campo; al menos en el área de la Industria Petrolera, la implementación de este tipo de algoritmos permitió realizar la predicción de dos propiedades PVT: la viscosidad y el factor volumétrico, a partir de la generación de dos modelos, los cuales obtuvieron un desempeño estadístico favorable.

Cabe recalcar que la interacción con esta forma de inteligencia artificial fue compleja debido al poco conocimiento de la misma y la falta de datos de propiedades PVT; sin embargo, se lograron resultados satisfactorios y se retroalimentó la información sobre estos temas. Además, se logró crear adecuadamente la propuesta de un software en donde se pueden leer y visualizar los datos en archivo “.xlsx”, y en donde se puede realizar el cálculo de las dos propiedades del aceite en el mismo.

Finalmente, podemos afirmar que, así como se creó un modelo alimentado por datos PVT se pueden generar diversos modelos más con diferentes enfoques dentro del campo petrolero, gracias a la eficiencia que nos muestran al realizar predicciones complejas teniendo poca información, a la reducción del tiempo de cálculo y sobre todo a la alta certeza que nos ofrece en comparación a otros métodos convencionales.

BIBLIOGRAFÍA

- Abdul-Majeed, G., & Salman, N. (1988). An empirical correlation for FVF prediction. Retrieved from OnePetro: <https://doi.org/10.2118/88-06-10>
- Adeeyo, Y. (2018). Empirical Model for Estimating Formation Volume Factor at Bubblepoint Pressure of Nigeria Crude Oil. Retrieved from OnePetro: <https://doi.org/10.2118/193432-MS>
- Ahmed, T. (2007). Equations of State and PVT Analysis (1ra ed.). Houston, Texas: Gulf Publishing Company.
- Ahmed, T. (2016). Equations of State and PVT Analysis (2da ed.). Cambridge: Elsevier, Inc.
- Al-Marhoun, M. &. (1996). Evaluation of empirically derived PVT properties for Pakistani crude oils. Retrieved from Journal of Petroleum Science and Engineering .
- Arana, C. (2021, 05). REDES NEURONALES RECURRENTE: ANÁLISIS DE LOS MODELOS ESPECIALIZADOS EN DATOS SECUENCIALES. Retrieved from Documentos de Trabajo. Universidad del CEMA: <https://ucema.edu.ar/publicaciones/download/documentos/797.pdf>
- Arteaga, J. e. (2020). Desarrollo de una Herramienta Informática para la simulación de reportes PVT en los pozos del Oriente Ecuatoriano de la Arena U inferior. Retrieved from Revista Politécnica: http://scielo.senescyt.gob.ec/scielo.php?script=sci_arttext&pid=S1390-01292020000400021
- ATRIA INNOVATION. (2019, 10 22). Qué son las redes neuronales y sus funciones. Retrieved from ATRIA INNOVATION: <https://www.atriainnovation.com/que-son-las-redes-neuronales-y-sus-funciones/>

- Beunza, J. &. (2020, 04 28). Inteligencia Artificial en entornos sanitarios. Tipos de algoritmos de 'machine learning'. Retrieved from ELSEVIER: <https://www.elsevier.com/es-es/connect/inteligencia-artificial-en-entornos-sanitarios-tipos-de-algoritmos-de>
- Calvo, D. (2017, 06 13). Clasificación de redes neuronales artificiales. Retrieved from <https://www.diegocalvo.es/clasificacion-de-redes-neuronales-artificiales/>
- Calvo, D. (2018, 12 08). Perceptrón – Red neuronal. Retrieved from <https://www.diegocalvo.es/perceptron/>
- Camargo, A. (2016, 08). Estimación de propiedades PVT para yacimientos de aceite negro y volátil mediante una red neuronal artificial. Retrieved from [Tesis para otorgar el grado de MAestro en Ingeniería de Exploración y Explotación de Recursos Naturales, UNAM].
- Castro, J. (2006, 11). FUNDAMENTOS PARA LA IMPLEMENTACIÓN DE RED NEURONAL PERCEPTRÓN MULTICAPA MEDIANTE SOFTWARE. Retrieved from Biblioteca USAC: http://biblioteca.usac.edu.gt/tesis/08/08_0155_EO.pdf
- Cevallos, J. (2008). Redes Neuronales de Base Radial aplicadas a la mejora de la calidad. Industrial Data. Revista de Investigación, págs 63-72.
- Colmenares, G. (s. f.). FUNCION DE BASE RADIAL. Retrieved from Redes Neuronales: http://www.webdelprofesor.ula.ve/economia/gcolmen/programa/redes_neuronales/capitulo4_funciones_bases_radiales.pdf
- Dokla, M., & Osman, M. (1992). Correlation of PVT for UAE crudes. Retrieved from OnePetro: <https://doi.org/10.2118/21342-MS>
- Guru99. (2022, 09 11). Tutorial de RNN (Rede Neuronal Recurrente): Ejemplo de TensorFlow. Retrieved from Guru99: <https://guru99.es/rnn-tutorial/>

- Hajizadeh, Y. (2007). Intelligent prediction of reservoir fluid viscosity. Retrieved from OnePetro: <https://doi.org/10.2118/106764-MS>
- Hemmati, M., & Kharrat, R. (2007). A correlation approach for prediction of crude oil PVT properties. Retrieved from OnePetro: <https://doi.org/10.2118/104543-MS>
- Hernández, I. (2017). Aplicación de Redes Neuronales en la Ingeniería Petrolera. Retrieved from [Tesis para obtener el título de Ingeniero Petrolero, UNAM].
- Hilera, J., & Martínez, V. (1995). Redes neuronales artificiales: fundamentos, modelos y aplicaciones. España: RA-MA.
- Ikiensikimama, S., & Azubuike, I. (2012). Modeling Approach for Niger- Delta Oil Formation Volume Factor Prediction Using Artificial Neural Network. Retrieved from OnePetro: <https://doi.org/10.2118/162987-MS>
- Iza, A. (2017, 05). Análisis y generación de correlaciones PVT del petróleo y su aplicabilidad en el Ecuador. Retrieved from [Tesis para obtener el título de Ingeniera en Petróleos, EPN]
- Java T point. (2021). Machine Learning Models. Retrieved from Java T point: <https://www.javatpoint.com/machine-learning-models>
- Jordi Torres.AI. (2019, 09 22). Redes Neuronales Recurrentes. Retrieved from Jordi Torres.AI: <https://torres.ai/redes-neuronales-recurrentes/>
- MANUAL MSD. (2022). ESTRUCTURA TÍPICA DE UNA NEURONA. Retrieved from MANUAL MSD: <https://www.msmanuals.com/es/hogar/multimedia/figure/estructura-típica-de-una-neurona>
- Martínez, J. (2018). Linear Regression SVM. Retrieved from GitHub: https://github.com/jmartinezheras/2018-MachineLearning-Lectures-ESA/blob/master/2_LinearRegression_SVM/2_LinearRegression_SVM.pdf

MathWorks. (2022). Redes neuronales convolucionales. Retrieved from MathWorks: <https://es.mathworks.com/discovery/convolutional-neural-network-matlab.html>

Matich, D. (2001, 03). Redes Neuronales: Conceptos Básicos y Aplicaciones. Retrieved from https://www.frro.utn.edu.ar/repositorio/catedras/quimica/5_anio/orientadora1/monograias/matich-redesneuronales.pdf

McCaffrey, J. (2016, 12 08). Redes de función de base radial para programadores. Retrieved from Microsoft: <https://learn.microsoft.com/es-es/archive/msdn-magazine/2013/october/test-run-radial-basis-function-networks-for-programmers>

McCain, W. (1990). The Properties of Petroleum Fluids. Tulsa, Oklahoma: PennWell Books.

Mora, A. (2023, 02 10). Machine Learning con Python: ejemplos prácticos. Retrieved from Data Machine Learning Visualization: <https://blog.damavis.com/machine-learning-con-python-ejemplos-practicos/>

Mueller, J. &. (2021). Machine Learning for dummies a Wiley Brand .

Oladipo, O., & Jonathan, M. (2020). A Novel Algorithmic Design and Implementation for Predicting Crude-Oil PVT Properties. Retrieved from OnePetro: <https://doi.org/10.2118/203716-MS>

Pathak, A. (2022, 08 30). Redes neuronales convolucionales (CNN): una introducción. Retrieved from GEEKFLARE: <https://geekflare.com/es/convolutional-neural-networks/>

Ramirez, J. (2015). Análisis y Evaluación de la Pruebas PVT. Bucaramanga: Universidad Industrial de Santander.

Rubiales, A. (2020, 10 16). Explicación de las Funciones de activación en Redes Neuronales y práctica con Python. Retrieved from Medium.com:

<https://rubialesalberto.medium.com/explicación-funciones-de-activación-y-práctica-con-python-5807085c6ed3>

Varotsis, N. e. (1999, 10 03). A Novel Non-Iterative Method for the Prediction of the PVT Behavior of Reservoir Fluids. Retrieved from OnePetro: <https://doi.org/10.2118/56745-MS>

ANEXOS

a) Base de datos de un aceite bajo saturado para la viscosidad

Tabla anexo a) Base de datos para viscosidad (Al-Marhoun, 1996).

T (°F)	P (psia)	Rs (scf/stb)	API	Uo (Cp)	T (°F)	P (psia)	RS (scf/stb)	API	Uo (Cp)
214	2193	634	45.3	0.459	211	2020	491	39.2	0.172
242	2402	844	40.7	0.627	216	2145	1022	47.9	0.606
214	2194	664	42.9	0.376	210	2090	1011	48.2	0.246
196	1562	463	38.9	0.693	280	2822	1006	46.8	0.25
211	1225	267	38	0.806	208	2290	990	43.1	0.238
203	1660	421	37.1	1.65	228	2500	1355	48.8	0.724
209	1530	355	35	1.21	250	3148	1440	50.3	0.197
211	1760	372	31	1.65	146	952	142	26.9	0.212
211	1225	260	38	0.806	235	2368	440	32.5	2.323
206	1700	364	36.6	0.86	161	2310	636	38.3	0.481
205	1370	313	38.2	0.785	166	2408	683	38.6	0.38
203	1593	421	39.8	0.65	195	3449	899	39.3	0.38
224	1982	415	36.1	0.802	192	3440	863	37.4	0.407
208	1450	359	35.4	1.54	152	1910	384	32.6	0.345
207	1570	366	39	0.98	164	2168	544	37.1	0.99
189	1750	714	48.7	0.336	171	2480	686	38.2	0.417
189	1810	606	50.5	0.316	169	2350	680	37	0.36
186	1658	368	41.4	0.58	190	1744	524	40.5	0.38
228	2632	888	49.3	0.255	247	3142	761	33.3	0.351
190	1755	694	49.5	0.339	239	2970	737	34.6	0.372
215	1728	397	41.8	0.481	173	1951	367	37.5	0.227
205	2058	765	48.8	0.159	177	2616	667	37.7	0.527
238	2221	547	45.3	0.31	152	1818	285	26.6	0.386
245	2274	546	45.2	0.327	225	2611	810	39.6	1.15
230	2081	494	44.5	0.356	127	1058	220	32.3	0.34
174	1220	267	31.4	0.93	194	3387	919	41.4	0.89
226	2390	956	43.2	0.736	159	1492	341	37.4	0.338
180	1302	242	31.4	1.243	125	935	150	31.9	0.71
187	1085	169	29.1	1.931	209	3780	1023	40.2	1.46
187	1271	198	29.2	1.814	180	3063	577	31.2	0.38
180	1195	214	31.9	1.257	169	2423	713	40	0.483
234	2562	741	42	0.383	167	2360	694	40	0.294
150	790	274	39.8	0.94	153	1838	366	34.8	0.325
185	1530	566	45.2	0.493	161	2106	344	28.9	0.81
189	1510	522	47.8	0.438	141	1390	287	33.4	1.25

217	1741	563	48.4	0.357	166	2470	760	40	0.88
220	2111	692	53.2	0.146	179	2692	393	38.6	0.43
199	1758	628	48.4	0.212	194	3420	1212	42.3	0.53
204	1769	585	49.1	0.365	186	3160	1213	45.4	0.33
204	1805	599	48.1	0.351	151	1765	345	34	0.35
185	1414	425	41	0.59	205	1780	509	37.8	0.6
239	2540	1020	50.4	0.236	180	3063	586	32.2	0.47
224	1790	686	47.1	0.212	198	2609	1019	40.4	0.448
188	1620	404	42.9	0.416	184	2344	791	40.4	0.35
211	2165	856	46.6	0.244	193	1698	646	40	0.46
231	2550	1170	48.9	0.225	243	3851	819	34.1	0.46
267	2360	993	48.4	0.172					

b) Base de datos de un aceite bajo saturado para el factor volumétrico

Tabla anexo b) Base de datos para factor volumétrico (Al-Marhoun, 1996).

T (°F)	P (psia)	Rs (scf/stb)	API	Bo	T (°F)	P (psia)	Rs (scf/stb)	API	Bo
250	2899.7	2249	56.5	2.916	237	779.7	362	39.4	1.369
248	1694.7	557	37.2	1.468	237	629.7	325	39.4	1.35
248	1429.7	486	37.2	1.432	237	479.7	285	39.4	1.33
248	1229.7	433	37.2	1.404	237	329.7	241	39.4	1.305
248	1029.7	381	37.2	1.387	237	197.7	190	39.4	1.275
248	829.7	328	37.2	1.352	237	128.7	158	39.4	1.253
248	629.7	273	37.2	1.322	237	93.7	130	39.4	1.238
248	429.7	215	37.2	1.292	237	29.7	0	39.4	1.09
248	241.7	144	37.2	1.246	237	1309.7	357	39.5	1.349
248	147.7	93	37.2	1.214	237	1179.7	330	39.5	1.335
248	29.7	0	37.2	1.092	237	1029.7	299	39.5	1.318
245	3294.7	1340	29.3	1.921	237	879.7	268	39.5	1.303
188	4211.7	2371	39.5	2.365	237	729.7	236	39.5	1.287
248	1739.7	663	38.5	1.522	237	579.7	202	39.5	1.268
248	1529.7	603	38.5	1.493	237	429.7	166	39.5	1.248
248	1329.7	547	38.5	1.465	237	279.7	126	39.5	1.225
248	1129.7	490	38.5	1.438	237	176.7	92	39.5	1.2
248	929.7	432	38.5	1.409	237	29.7	0	39.5	1.099
248	729.7	376	38.5	1.38	254	1489.7	885	42.2	1.804
248	529.7	316	38.5	1.35	254	1329.7	821	42.2	1.771
248	329.7	251	38.5	1.314	254	1129.7	744	42.2	1.73
248	197.7	192	38.5	1.278	254	929.7	666	42.2	1.685
248	127.7	152	38.5	1.248	254	729.7	588	42.2	1.639
248	29.7	0	38.5	1.098	254	529.7	505	42.2	1.588
229	1330.7	435	40.5	1.375	254	329.7	411	42.2	1.523

229	1079.7	379	40.5	1.35	254	209.7	333	42.2	1.461
229	879.7	335	40.5	1.329	254	149.7	276	42.2	1.411
229	679.7	288	40.5	1.306	254	109.7	213	42.2	1.351
229	479.7	239	40.5	1.282	254	29.7	0	42.2	1.104
229	279.7	182	40.5	1.25	246	1751.7	635	38.8	1.524
229	177.7	145	40.5	1.227	246	1529.7	567	38.8	1.491
229	29.7	0	40.5	1.087	246	1329.7	515	38.8	1.463
222	2963.7	1321	29	1.94	246	1129.7	468	38.8	1.436
222	2629.7	1210	29	1.844	246	929.7	414	38.8	1.41
222	2229.7	1074	29	1.753	246	729.7	360	38.8	1.383
222	1829.7	937	29	1.681	246	529.7	302	38.8	1.353
222	1429.7	802	29	1.61	246	329.7	240	38.8	1.319
222	1029.7	670	29	1.541	246	186.7	181	38.8	1.28
222	629.7	506	29	1.467	246	114.7	141	38.8	1.247
222	312.7	340	29	1.386	246	29.7	0	38.8	1.094
222	29.7	0	29	1.073	255	1469.7	586	38.1	1.503
232	1539.7	550	39.9	1.46	255	1229.7	517	38.1	1.467
232	1329.7	496	39.9	1.431	255	1029.7	458	38.1	1.43
232	1129.7	446	39.9	1.403	255	829.7	403	38.1	1.407
232	929.7	395	39.9	1.376	255	629.7	342	38.1	1.373
232	729.7	342	39.9	1.348	255	429.7	280	38.1	1.335
232	529.7	288	39.9	1.32	255	259.7	204	38.1	1.286
232	329.7	228	39.9	1.286	255	159.7	156	38.1	1.249
232	199.7	180	39.9	1.253	255	29.7	0	38.1	1.098
232	29.7	0	39.9	1.097	248	1496.7	582	38.1	1.511
217	1526.7	512	41	1.416	248	1279.7	519	38.1	1.476
217	1329.7	468	41	1.391	248	1079.7	466	38.1	1.449
217	1129.7	419	41	1.363	248	879.7	413	38.1	1.421
217	929.7	369	41	1.324	248	679.7	360	38.1	1.392
217	729.7	316	41	1.3	248	479.7	302	38.1	1.358
217	529.7	259	41	1.278	248	279.7	230	38.1	1.312
217	329.7	196	41	1.248	248	169.7	180	38.1	1.276
217	197.7	145	41	1.217	248	29.7	0	38.1	1.094
217	29.7	0	41	1.088	252	1474.7	936	43.8	1.821
188	1731.7	556	42.6	1.394	252	1279.7	850	43.8	1.777
188	1529.7	509	42.6	1.373	252	1079.7	768	43.8	1.733
188	1329.7	462	42.6	1.354	252	879.7	683	43.8	1.685
188	1129.7	419	42.6	1.335	252	679.7	601	43.8	1.637
188	929.7	378	42.6	1.318	252	479.7	517	43.8	1.584
188	729.7	330	42.6	1.298	252	279.7	416	43.8	1.514
188	529.7	280	42.6	1.275	252	184.7	347	43.8	1.459
188	329.7	225	42.6	1.247	252	129.7	278	43.8	1.404
188	184.7	165	42.6	1.215	252	29.7	0	43.8	1.106
188	29.7	0	42.6	1.067	244	1583.7	542	37.5	1.456

296	2897.7	1977	39.9	2.619	244	1329.7	474	37.5	1.423
296	2629.7	1757	39.9	2.475	244	1129.7	423	37.5	1.398
296	2329.7	1536	39.9	2.331	244	929.7	371	37.5	1.371
296	2029.7	1340	39.9	2.203	244	729.7	318	37.5	1.344
296	1729.7	1169	39.9	2.092	244	529.7	261	37.5	1.313
296	1429.7	1018	39.9	1.995	244	329.7	199	37.5	1.277
296	1129.7	884	39.9	1.91	244	201.7	147	37.5	1.241
296	829.7	760	39.9	1.832	244	29.7	0	37.5	1.091
296	529.7	628	39.9	1.747	182	1112.7	373	42.1	1.312
296	263.7	470	39.9	1.633	182	929.7	335	42.1	1.296
296	166.7	379	39.9	1.599	182	729.7	295	42.1	1.278
296	118.7	317	39.9	1.504	182	529.7	250	42.1	1.258
296	29.7	0	39.9	1.142	182	329.7	192	42.1	1.235
281	4989.7	2496	31.9	2.713	182	199.7	151	42.1	1.213
281	4129.7	1458	31.9	1.981	182	29.7	0	42.1	1.068
281	3329.7	1074	31.9	1.777	255	1256.7	565	39.2	1.553
281	2629.7	827	31.9	1.658	255	1029.7	512	39.2	1.527
281	1929.7	615	31.9	1.552	255	829.7	462	39.2	1.501
281	1229.7	407	31.9	1.449	255	629.7	410	39.2	1.473
281	629.7	248	31.9	1.351	255	429.7	315	39.2	1.441
281	29.7	0	31.9	1.104	255	259.7	294	39.2	1.405
237	1240.7	470	39.4	1.418	255	174.7	257	39.2	1.378
237	1079.7	433	39.4	1.401	255	29.7	0	39.2	1.11
237	929.7	398	39.4	1.385					