


	GESTIÓN SERVICIOS BIBLIOTECARIOS					  	
	CARTA DE AUTORIZACIÓN						
CÓDIGO	AP-BIB-FO-06	VERSIÓN	1	VIGENCIA	2014	PÁGINA	1 de 2

Neiva, 7 de abril de 2016

Señores

CENTRO DE INFORMACIÓN Y DOCUMENTACIÓN

UNIVERSIDAD SURCOLOMBIANA

Ciudad

Los suscritos:

Cristian Stiven Loaiza Cano, con C.C. No. 1075264422 y Samuel Quintero Herrera, con C.C. No.1075266602 autores de la tesis titulado DESARROLLO DE UN MODELO PARA LA DETERMINACIÓN DE LA PRESIÓN DE INICIO DE PRECIPITACIÓN DE ASFALTENOS (ONSET) EN YACIMIENTOS DE PETRÓLEO presentado y aprobado en el año 2016 como requisito para optar al título de Ingeniero de petróleos; autorizamos al CENTRO DE INFORMACIÓN Y DOCUMENTACIÓN de la Universidad Surcolombiana para que con fines académicos, muestre al país y el exterior la producción intelectual de la Universidad Surcolombiana, a través de la visibilidad de su contenido de la siguiente manera:

- Los usuarios puedan consultar el contenido de este trabajo de grado en los sitios web que administra la Universidad, en bases de datos, repositorio digital, catálogos y en otros sitios web, redes y sistemas de información nacionales e internacionales “open access” y en las redes de información con las cuales tenga convenio la Institución.
- Permita la consulta, la reproducción y préstamo a los usuarios interesados en el contenido de este trabajo, para todos los usos que tengan finalidad académica, ya sea en formato Cd-Rom o digital desde internet, intranet, etc., y en general para cualquier formato conocido o por conocer, dentro de los términos establecidos en la Ley 23 de 1982, Ley 44 de 1993, Decisión Andina 351 de 1993, Decreto 460 de 1995 y demás normas generales sobre la materia.
- Continúo conservando los correspondientes derechos sin modificación o restricción alguna; puesto que de acuerdo con la legislación colombiana aplicable, el presente es un acuerdo jurídico que en ningún caso conlleva la enajenación del derecho de autor y sus conexos.

De conformidad con lo establecido en el artículo 30 de la Ley 23 de 1982 y el artículo 11 de la Decisión Andina 351 de 1993, “Los derechos morales sobre el trabajo son propiedad de los autores”, los cuales son irrenunciables, imprescriptibles, inembargables e inalienables.

Cristian Stiven Loaiza Cano

Samuel Quintero Herrera



GESTIÓN SERVICIOS BIBLIOTECARIOS

CARTA DE AUTORIZACIÓN



CÓDIGO

AP-BIB-FO-06

VERSIÓN

1

VIGENCIA






2014

PÁGINA

2 de 2

Firma:

Firma:

	GESTIÓN SERVICIOS BIBLIOTECARIOS						   
	DESCRIPCIÓN DE LA TESIS Y/O TRABAJOS DE GRADO						
CÓDIGO	AP-BIB-FO-07	VERSIÓN	1	VIGENCIA	2014	PÁGINA	1 de 3

TÍTULO COMPLETO DEL TRABAJO: DESARROLLO DE UN MODELO PARA LA DETERMINACIÓN DE LA PRESIÓN DE INICIO DE PRECIPITACIÓN DE ASFALTENOS (ONSET) EN YACIMIENTOS DE PETRÓLEO

AUTOR O AUTORES:

Primero y Segundo Apellido	Primero y Segundo Nombre
LOAIZA CANO	CRISTIAN STIVEN
QUINTERO HERRERA	SAMUEL

DIRECTOR Y CODIRECTOR TESIS:

Primero y Segundo Apellido	Primero y Segundo Nombre
SEPÚLVEDA GAONA	JAIRO ANTONIO
MOSQUERA CERQUERA	VLADIMIR

ASESOR (ES):

Primero y Segundo Apellido	Primero y Segundo Nombre

PARA OPTAR AL TÍTULO DE: INGENIERO DE PETRÓLEOS

FACULTAD: INGENIERÍA

PROGRAMA O POSGRADO: INGENIERÍA DE PETRÓLEOS





CIUDAD: NEIVA

AÑO DE PRESENTACIÓN: 2016

NÚMERO DE PÁGINAS: 115

TIPO DE ILUSTRACIONES (Marcar con una X):

La versión vigente y controlada de este documento, solo podrá ser consultada a través del sitio web Institucional www.usco.edu.co, link Sistema Gestión de Calidad. La copia o impresión diferente a la publicada, será considerada como documento no controlado y su uso indebido no es de responsabilidad de la Universidad Surcolombiana.

	GESTIÓN SERVICIOS BIBLIOTECARIOS					  	
	DESCRIPCIÓN DE LA TESIS Y/O TRABAJOS DE GRADO						
CÓDIGO	AP-BIB-FO-07	VERSIÓN	1	VIGENCIA	2014	PÁGINA	2 de 3

Diagramas_X_ Fotografías___ Grabaciones en discos___ Ilustraciones en general_X_ Grabados___ Láminas___ Litografías___ Mapas___ Música impresa___ Planos___ Retratos___ Sin ilustraciones___ Tablas o Cuadros_X

SOFTWARE requerido y/o especializado para la lectura del documento: Microsoft Word, Adobe Reader.

MATERIAL ANEXO:

PREMIO O DISTINCIÓN (*En caso de ser LAUREADAS o Meritoria*): Tesis Meritoria

PALABRAS CLAVES EN ESPAÑOL E INGLÉS:

Español





Inglés

- | | |
|----------------------------------|----------------------------|
| 1. Presión onset | Onset pressure |
| 2. Precipitación de asfaltenos | Asphaltene deposition |
| 3. Redes neuronales artificiales | Artificial neural networks |
| 4. SOM | Self-organizing maps |
| 5. Feed-forward | Feed-forward |

RESUMEN DEL CONTENIDO: (Máximo 250 palabras)

Se desarrolló un modelo con redes neuronales artificiales denominado “Neuross-Asph” a partir del cual se obtiene la envolvente superior de precipitación de asfaltenos. Para esto, se recolectaron 58 muestras de diferentes fuentes literarias. La información se sometió a un proceso de análisis antes de ser ingresada a la red. El modelo se construyó en tres etapas, la primera consistió en agrupar los datos según la relación Ponset/Pb a través de mapas auto-organizados (SOM). En la segunda se realizó una subcategorización de la información a partir de la composición química y el análisis SARA con la ayuda de las redes SOM. La última etapa se diseñó con una red feed-forward de contrapropagación para predecir las presiones onset a partir de la asociación con la presión de burbuja.

La principal ventaja del modelo propuesto es lograr predecir la presión onset requiriendo como parámetros de entrada pocos datos y de fácil acceso. Al revisar los datos de salida,

	GESTIÓN SERVICIOS BIBLIOTECARIOS						  
	DESCRIPCIÓN DE LA TESIS Y/O TRABAJOS DE GRADO						
CÓDIGO	AP-BIB-FO-07	VERSIÓN	1	VIGENCIA	2014	PÁGINA	3 de 3

se observan resultados satisfactorios; debido al diseño del modelo que permitió identificar las relaciones que mayor influencia tienen sobre la precipitación de asfaltenos.

ABSTRACT: (Máximo 250 palabras)

A model with artificial neural networks called "Neuross-Asph" was developed from which the upper envelope of asphaltene precipitation is obtained. To achieve this, 58 samples were collected from different literary sources and the information was subjected to an analysis process before being admitted to the network. The model was constructed in three stages, the first consisted of a grouping of the data according to Ponset / Pb ratio through self-organizing maps (SOM). In the second, a subcategorization of information was made, this based on the chemical composition and SARA analysis with the help of the SOM networks. The last stage was designed with a feed-forward network of backpropagation to predict the onset pressures by means of the association with bubble pressure.

The main advantage of the proposed model is to predict the onset pressure, requiring little and easily accessible data as input parameters. In reviewing the data output, satisfactory results were observed; due to the design model, which identified the relationships that have more influence on the precipitation of asphaltenes.

APROBACION DE LA TESIS

Nombre Presidente Jurado:

Firma:

Nombre Jurado: Freddy Humberto Escobar

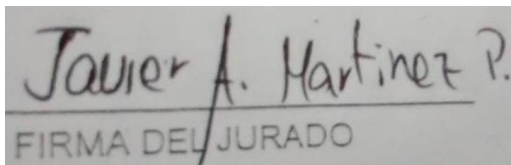
Firma:



FIRMA DEL JURADO

Nombre Jurado: Javier Andres Martinez

Firma:



FIRMA DEL JURADO

**DESARROLLO DE UN MODELO PARA LA DETERMINACIÓN DE LA PRESIÓN
DE INICIO DE PRECIPITACIÓN DE ASFALTENOS (ONSET) EN YACIMIENTOS
DE PETRÓLEO**



**CRISTIAN STIVEN LOAIZA CANO
SAMUEL QUINTERO HERRERA**

**UNIVERSIDAD SURCOLOMBIANA
FACULTAD DE INGENIERÍA
GRUPO DE INVESTIGACIÓN COMPORTAMIENTO DE FASES
PROGRAMA INGENIERÍA DE PETRÓLEOS
NEIVA HUILA
2016**

**DESARROLLO DE UN MODELO PARA LA DETERMINACIÓN DE LA PRESIÓN
DE INICIO DE PRECIPITACIÓN DE ASFALTENOS (ONSET) EN YACIMIENTOS
DE PETRÓLEO**

**CRISTIAN STIVEN LOAIZA CANO
SAMUEL QUINTERO HERRERA**

**Trabajo de grado presentado como requisito para optar al Título de Ingeniero de
Petróleos**

**Director:
ING. JAIRO ANTONIO SEPÚLVEDA GAONA, MSc.
Codirector:
ING. VLADIMIR MOSQUERA CERQUERA, MSc.**

**UNIVERSIDAD SURCOLOMBIANA
FACULTAD DE INGENIERÍA
GRUPO DE INVESTIGACIÓN COMPORTAMIENTO DE FASES
PROGRAMA INGENIERÍA DE PETRÓLEOS
NEIVA HUILA
2016**

Nota de aceptación

Firma del Director

Firma del Codirector

Firma del Evaluador

Firma del Evaluador

Neiva, Huila abril 5 de 2016

A Dios, por demostrarme que la disciplina, el esfuerzo y la entrega son herramientas para lograr lo que mente-corazón anhelan.

A mi madre, por no rendirse nunca y permitir que este sueño hoy en día sea una estupenda realidad.

A mi abuela Q.E.P.D gracias por todos los años compartidos, fue grata compañía durante mi crecimiento.

Cristian Stiven

*A Dios, por guiar mi caminar, demostrarme su
majestuoso amor y hacerme feliz.
A mi madre Blanca Nelly, por su amor, su lucha y
entrega para hacerme crecer como persona.
A mi padre José Arnulfo que está en el cielo, todo un
ejemplo a seguir, me dejó enseñanzas invaluablees.
A mis hermanos: Faiber, Yenny, Mayerly, José,
Wilfredo y Lorena, por apoyarme en el proceso y estar
siempre presentes.
A mis 10 sobrinos, que con su dulzura me llenan de
alegría.*

Samuel

AGRADECIMIENTOS

Los autores expresan agradecimientos a:

Ingeniero Vladimir Mosquera Cerquera por su compromiso, dedicación y apoyo durante el desarrollo del proyecto; sin su colaboración no habría sido posible la realización de éste.

Ingeniero Jairo Antonio Sepúlveda Gaona por el excelente direccionamiento durante toda la investigación. Su impulso fue valioso para continuar hasta el final.

Ingeniero Joseph Moreno por el acompañamiento durante la primera parte de la investigación.

Nuestros familiares, por el apoyo y cariño constante. Fueron motivación y soporte para lograr este importante logro.

Andrea Álvarez, Diana Álvarez y Ana María Cruz por su compañerismo incondicional.

Nuestros amigos, compañeros y conocidos que hicieron parte de este grandioso proceso.

RESUMEN

TÍTULO:

DESARROLLO DE UN MODELO PARA LA DETERMINACIÓN DE LA PRESIÓN DE INICIO DE PRECIPITACIÓN DE ASFALTENOS (ONSET) EN YACIMIENTOS DE PETRÓLEO

AUTORES:

CRISTIAN STIVEN LOAIZA CANO
SAMUEL QUINTERO HERRERA

PALABRAS CLAVES:

Presión onset, precipitación de asfaltenos, redes neuronales artificiales, SOM, Feed-forward.

DESCRIPCIÓN:

Se desarrolló un modelo con redes neuronales artificiales denominado “Neuross-Asph” a partir del cual se obtiene la envolvente superior de precipitación de asfaltenos. Para esto, se recolectaron 58 muestras de diferentes fuentes literarias. La información se sometió a un proceso de análisis antes de ser ingresada a la red. El modelo se construyó en tres etapas, la primera consistió en agrupar los datos según la relación Ponset/Pb a través de mapas auto-organizados (SOM). En la segunda se realizó una subcategorización de la información a partir de la composición química y el análisis SARA con la ayuda de las redes SOM. La última etapa se diseñó con una red feed-forward de contrapropagación para predecir las presiones onset a partir de la asociación con la presión de burbuja.

La principal ventaja del modelo propuesto es lograr predecir la presión onset requiriendo como parámetros de entrada pocos datos y de fácil acceso. Al revisar los datos de salida, se observan resultados satisfactorios; debido al diseño del modelo que permitió identificar las relaciones que mayor influencia tienen sobre la precipitación de asfaltenos.

ABSTRACT

TITLE:

DEVELOPMENT OF A MODEL FOR DETERMINING THE ASPHALTENE ONSET PRESSURE IN OIL RESERVOIRS

AUTHORS:

CRISTIAN STIVEN LOAIZA CANO
SAMUEL QUINTERO HERRERA

KEYWORDS:

Onset pressure, asphaltene deposition, artificial neural networks, self-organizing maps, feed-forward.

DESCRIPTION:

A model with artificial neural networks called "Neuross-Asph" was developed from which the upper envelope of asphaltene precipitation is obtained. To achieve this, 58 samples were collected from different literary sources and the information was subjected to an analysis process before being admitted to the network. The model was constructed in three stages, the first consisted of a grouping of the data according to Ponset / Pb ratio through self-organizing maps (SOM). In the second, a subcategorization of information was made, this based on the chemical composition and SARA analysis with the help of the SOM networks. The last stage was designed with a feed-forward network of backpropagation to predict the onset pressures by means of the association with bubble pressure.

The main advantage of the proposed model is to predict the onset pressure, requiring little and easily accessible data as input parameters. In reviewing the data output, satisfactory results were observed; due to the design model, which identified the relationships that have more influence on the precipitation of asphaltenes.

TABLA DE CONTENIDO

1. FUNDAMENTOS BÁSICOS	1
1.1 ASFALTENOS	1
1.1.1 GENERALIDADES	1
1.1.2 COMPOSICIÓN Y ESTRUCTURA	1
1.1.3 MECANISMOS DE DEPOSICIÓN DE ASFALTENOS	4
1.1.4 MODELOS DE PRECIPITACIÓN DE ASFALTENOS	6
1.2 ANÁLISIS SARA	9
1.2.1 SATURADOS	10
1.2.2 AROMÁTICOS	10
1.2.3 RESINAS	10
1.2.4 ASFALTENOS	10
1.2.5 ESTABILIDAD DE LOS ASFALTENOS	11
2. PRECIPITACIÓN DE ASFALTENOS	14
2.1 FLOCULACION, PRECIPITACIÓN Y DEPOSITACIÓN	14
2.1.1 FLOCULACIÓN	15
2.1.2 PRECIPITACIÓN O AGREGACIÓN	15
2.1.3 DEPOSITACIÓN	16
2.2 PRESIÓN DE INICIO DE PRECIPITACION DE ASFALTENOS (AOP).	16
2.3 ENVOLVENTE DE PRECIPITACIÓN DE ASFALTENOS (ADE).	17
2.4 FACTORES CAUSANTES DE LA PRECIPITACIÓN DE ASFALTENOS	18
2.4.1 FACTORES TERMODINÁMICOS	18
2.4.2 FACTORES QUÍMICOS	20
2.4.3 FACTORES ELÉCTRICOS	21
2.4.4 FACTORES MECÁNICOS	22
2.4.5 OTROS FACTORES	22
2.5 EFECTOS GENERADOS POR LA DEPOSITACIÓN DE ASFALTENOS	22
2.5.1 TAPONAMIENTO DEL YACIMIENTO Y EN LA VECINDAD DEL POZO.	23
2.5.2 CAMBIOS DE MOJABILIDAD EN EL YACIMIENTO	24
2.5.3 TAPONAMIENTO DE LA TUBERÍA DE PRODUCCIÓN	24
2.5.4 TAPONAMIENTO DE LÍNEAS DE FLUJO Y DEMÁS EQUIPOS DE SUPERFICIE.	25
2.5.5 FORMACIÓN DE EMULSIONES ESTABLES.	25

3. REDES NEURONALES ARTIFICIALES EN LA PRECIPITACIÓN DE ASFALTENOS	26
3.1 FUNDAMENTOS DE LAS REDES NEURONALES ARTIFICIALES	26
3.1.1 ESTRUCTURA BÁSICA DE UNA RED NEURONAL ARTIFICIAL	27
3.1.2 APLICACIONES DE LAS RNA	29
3.1.3 FUNCIONAMIENTO DE LAS RNA	30
3.2 ANTECEDENTES	31
3.3 ANÁLISIS DE LOS PARÁMETROS DE ENTRADA	33
3.3.1 RECOLECCIÓN	33
3.3.2 ORGANIZACIÓN	34
3.3.3 PROCESAMIENTO	34
3.3.4 VISUALIZACIÓN	37
3.3.5 ANÁLISIS	42
4. DESARROLLO DEL MODELO NEUROSS-ASPH PARA PREDECIR LA PRESIÓN ONSET A PARTIR DE REDES NEURONALES	52
4.1 BASES DEL MODELO	52
4.2 FUNDAMENTOS DE LA RED DISEÑADA	54
4.2.1 RED NEURONAL SOM (SELF ORGANIZING MAP)	54
4.2.2 RED NEURONAL FEED-FORWARD DE CONTRAPROPAGACIÓN (FEED-FORWARD BACKPROPAGATION)	56
4.3 CONSTRUCCIÓN Y ENTRENAMIENTO DEL MODELO	57
4.3.1 PROCESAMIENTO DE LA INFORMACIÓN.	59
4.3.2 CATEGORIZACIÓN SEGÚN PROMEDIO PONSET/Pb.	59
4.3.3 SUBCATEGORIZACIÓN SEGÚN COMPOSICIÓN	60
4.3.4 ASOCIACIÓN DE PRESIONES DE BURBUJA CON PRESIONES ONSET.	61
4.4 SIMULACIÓN DEL MODELO	62
4.4.1 ACOPLAMIENTO DE LA COMPOSICIÓN QUÍMICA.	63
4.4.2 ACOPLAMIENTO DE LA RELACIÓN PONSET/Pb.	64
4.4.3 SELECCIÓN DE LA RED FEED-FORWARD	64
4.4.4 PREDICCIÓN DE LA PRESIÓN ONSET.	64
5. RESULTADOS Y DISCUSIONES	67
5.1 VALIDACIÓN DEL MODELO CON LA INFORMACIÓN DE ENTRADA.	67
5.1.1 VALIDACIÓN DEL MODELO CON LA INFORMACIÓN DE ENTRADA.	67
5.1.2 VALIDACIÓN DEL MODELO CON UNA MUESTRA NUEVA.	70

5.2 COMPARATIVO CON OTROS MODELOS NUMÉRICOS DISPONIBLES	72
5.2.1 MODELO DE FAHIM	72
5.2.2 MODELO DE REGRESIÓN DE MÍNIMOS CUADRADOS MODIFICADO.	74
5.3 CURVA DE PRECIPITADOS EN PESO A PARTIR DE LA INFORMACIÓN GENERADA POR EL MODELO	76
<hr/>	
6. CONCLUSIONES Y RECOMENDACIONES	79
6.1 CONCLUSIONES	79
6.2 RECOMENDACIONES	81
<hr/>	
BIBLIOGRAFÍA	82
<hr/>	
ANEXOS	88
ANEXO 1: COMPOSICIONES DE LAS MUESTRAS UTILIZADAS EN LA CONSTRUCCIÓN DEL MODELO	88
ANEXO 2: ANÁLISIS SARA DE LAS MUESTRAS UTILIZADAS EN LA CONSTRUCCIÓN DEL MODELO	91
ANEXO 3: PRESIÓN ONSET Y PRESIÓN DE BURBUJA DE LAS MUESTRAS UTILIZADAS EN LA CONSTRUCCIÓN DEL MODELO	93
ANEXO 4: LISTADO COMPLETO DE PRESIONES ONSET Y DE BURBUJA CON LA QUE SE CONSTRUYÓ EL MODELO PARA UNA MUESTRA EJEMPLO (MUESTRA 48).	97

LISTA DE TABLAS

Tabla 1. Composición típica de elementos presentes en moléculas de asfalteno [2].	3
Tabla 2. Presiones onset y de burbuja experimentales para la muestra 48	35
Tabla 3. Organización de las 58 muestras según el valor de presión onset a 310 K, 350 K y 400 K.	43
Tabla 4. Análisis en composición y análisis SARA para muestras del grupo 1 a 310 K.	44
Tabla 5. Pendientes promedio del cociente entre presión onset y presión de burbuja	48
Tabla 6. Promedio de cocientes entre presión onset y presión de burbuja.	50
Tabla 7. Nomenclatura de las composiciones químicas dentro del modelo	60
Tabla 8. Rangos de las variables utilizadas para la creación del Modelo Neuross-Asph	66
Tabla 9. Comparación de los datos experimentales y los predichos con el modelo Neuross-Asph	67
Tabla 10. Comparación de presiones onset calculadas con los modelos de Fahim y Neuross-Asph	73
Tabla 11. Comparación de presiones onset calculadas con los modelos de mínimos cuadrados y Neuross-Asph	75

LISTA DE GRÁFICAS

Gráfica 1. Stankiewicz Plot [23].	12
Gráfica 2 Stability Cross Plot (SCP). (a) [(R/A)/(S/Ar)] vs [Ar/A] (b) [(R/A)/(S/Ar)] vs [R/A] (c) [S/Ar] vs [R/A] (d) [(R/A)/(S/Ar)] vs [Ar/(S/A)] [25].	13
Gráfica 3. Envoltente de equilibrio líquido-vapor para la muestra 48	35
Gráfica 4. Información de entrada al software Table Curve de la Muestra 48	36
Gráfica 5. Curva de presión onset generada por Table Curve para la muestra 48	37
Gráfica 6. Composición de las muestras utilizadas	38
Gráfica 7. Análisis SARA de las muestras utilizadas	39
Gráfica 8. Presión de saturación de las muestras utilizadas	40
Gráfica 9. Presión onset de las muestras utilizadas	41
Gráfica 10. Relación entre presión onset y presión de burbuja para las 58 muestras a 310 K.	46
Gráfica 11. Relación entre presión onset y presión de burbuja para las 58 muestras	47
Gráfica 12. Composición y análisis SARA para muestras con pendientes entre -0.09 y -0.11	49
Gráfica 13. Composición y análisis SARA para muestras con cocientes promedios entre 1.83 y 1.98	51
Gráfica 14. Acoplamiento en función de la composición química	64
Gráfica 15 Proceso de predicción de la presión onset (a) a la entrada del FF, (b) a la salida del FF.	65
Gráfica 16. Región formada por las presiones de burbuja utilizadas en la creación del Modelo Neuross-Asph	66
Gráfica 17. Envoltente de precipitación de asfaltenos (APE) generada por el software SMAP para un punto experimental de la muestra 48	77
Gráfica 18. Envoltente de precipitados de asfaltenos a diferentes temperaturas	78

LISTA DE FIGURAS

Figura 1 “Diagrama de long” los asfaltenos en el crudo presentan una cantidad alta en peso molecular, polaridad y aromaticidad.	2
Figura 2. Efecto del cambio de composición sobre la precipitación de compuestos orgánicos pesados [6].	4
Figura 3. Peptización de las moléculas de asfaltenos y migración de moléculas de resinas [6].	5
Figura 4. Floculación y precipitación de las moléculas de asfaltenos [6].	5
Figura 5. Deposición electrocinética y taponamiento en una tubería. [6]	6
Figura 6. Composición general del crudo [20].	9
Figura 7. Agregación y precipitación de asfaltenos. (A) Asfaltenos en estado coloidal peptizados por las resinas. (B) Por modificaciones fisicoquímicas las resinas comienzan a abandonar al asfalteno. (C) Floculación de asfaltenos. (D) Precipitación de los asfaltenos.	15
Figura 8. Presión onset de precipitación de asfaltenos [26].	17
Figura 9. Envoltorio de precipitación de asfaltenos (ADE) en el espacio presión-temperatura [20].	18
Figura 10. Problemas ocasionados por la precipitación y depositación de los asfaltenos [20].	23
Figura 11. Efecto de taponamiento por depósitos de asfaltenos en el medio poroso.	24
Figura 12. Efecto de cambio de mojabilidad por depósitos de asfaltenos en el medio poroso.	24
Figura 13. Componentes de una Neurona [32].	27
Figura 14. Diagrama de una Neurona Artificial (PE) [33].	28
Figura 15. Arquitectura de una red neuronal totalmente conectada [30].	28
Figura 16. Etapas de desarrollo del modelo	52
Figura 17. Representación genérica del modelo.	53
Figura 18. Estructura de la red SOM [45].	55
Figura 19. Topologías del SOM [46].	55
Figura 20. Esquema típico de red neuronal de tipo feedforward [47].	56
Figura 21. Representación estructural del modelo	58
Figura 22. Topología del SOM que categoriza el promedio entre Pons/Pb. (a) Antes del entrenamiento. (b) Después del entrenamiento	60
Figura 23. Topología del SOM que subcategoriza por composición. (a) Antes del entrenamiento. (b) Después del entrenamiento	61
Figura 24. Esquema del proceso de simulación.	63

INTRODUCCIÓN

El deseo constante de mejorar procesos, perfeccionar técnicas, implementar innovadoras metodologías lleva a los hombres a la búsqueda constante de herramientas y mecanismos que permitan hacerlo realidad y adaptarlo a la vida diaria. La industria petrolera frecuentemente se ve expuesta ante desafiantes retos que llevan a replantear ideas y conceptos con el fin de lograr la eficiencia y eficacia en todos los procedimientos que la componen.

La precipitación de asfaltenos corresponde a uno de los tantos temas de atención porque involucra variables tan delicadas como lo son la producción y equipos operativos. Los estudios realizados para comprender éste fenómeno y las consecuencias que genera han permitido establecer que su ocurrencia es casi inminente, ya que se asocia a la caída de presión del yacimiento; situación que se podría catalogar como “normal” teniendo en cuenta que es producto de la relación producción de hidrocarburos versus tiempo.

Las medidas o esfuerzos adoptados pretenden prevenir las adversidades y no solamente corregir sobre el daño efectuado. La floculación, precipitación y depositación de asfaltenos son causantes de daño de formación (disminución de porosidad y permeabilidad) así como detrimento de instalaciones y equipos. Si a éstos efectos se asocia el impacto económico que generan, el tiempo empleado en su mitigación y los efectos colaterales capaces de producir, la precipitación de asfaltenos deja de convertirse en un simple fenómeno y pasa a ser un problema de gran consideración.

Son varias las opciones que hasta el momento se han considerado para explicar el por qué y el qué causa el fenómeno en mención, así mismo han sido planteados diversos modelos que permiten cuantificarlo y caracterizarlo. De los que mayor interés y en constante evolución se encuentra son los modelos de tipo numérico, ya que generalmente intentan encontrar la presión de inicio de precipitación de asfaltenos (onset), obtener la envolvente de precipitación (ADE) y/o representar la curva de %wt de los asfaltenos-sólidos precipitados; sin necesidad de realizar procedimientos experimentales que impliquen tiempo y costos ni involucrar variables que aunque teóricamente están bien sustentadas, a nivel práctico generan incertidumbres.

Entre las propuestas que hasta el momento han sido desarrolladas de modelos numéricos, están las ecuaciones empíricas, sistemas inteligentes, redes neuronales artificiales, entre otras. Precisamente éstas últimas son las que con el paso de los años han demostrado su potencial en el desarrollo de destacadas investigaciones no solo en la industria de los hidrocarburos sino en casi todas las áreas de trabajo del ser humano.

Con el presente trabajo de grado titulado “DESARROLLO DE UN MODELO PARA LA DETERMINACIÓN DE LA PRESIÓN DE INICIO DE PRECIPITACIÓN DE ASFALTENOS (ONSET) EN YACIMIENTOS DE PETRÓLEO”, se logra entregar un considerable aporte a las múltiples investigaciones desarrolladas en el tema. A través de un modelo con redes neuronales artificiales se predice las presiones que forman la envolvente superior de precipitación de asfaltenos de yacimientos de petróleo.

La información necesaria para poner en marcha la red y lograr predecir las presiones onset para pozos donde no se conoce, está fácilmente al alcance; además el modelo Neuross-Asph (como se decidió nombrarlo) abarca un amplio rango de aplicación, es ágil y con un grado de confiabilidad satisfactorio.

El presente libro está compuesto por seis capítulos con un notable soporte teórico a la construcción del sistema y sobre las investigaciones realizadas al respecto, las cuales aportaron alternativas de solución al problema planteado. El capítulo uno, presenta las bases teóricas para comprender el entorno y naturaleza de los asfaltenos.

El segundo capítulo expone los fundamentos que conforman el fenómeno de precipitación de asfaltenos. El capítulo tres, es la introducción al modelo desarrollado en la presente investigación ya que aclara los principios teóricos de las RNA, los avances conseguidos con estos sistemas y el procesamiento realizado a los datos recolectados para la construcción de la red.

En el cuarto capítulo se detalla los procedimientos, características, limitaciones a partir de las cuales se construyó el modelo Neuross-Asph. El capítulo cinco publica los resultados y discusiones; se realiza especial énfasis en los escenarios de aplicación, así como el aporte respecto al de otras propuestas. Finalmente, en el sexto capítulo a partir de las Conclusiones y Recomendaciones se logra sintetizar la importancia, alcances y mejoras de la investigación.

Este material incluye además las referencias bibliográficas utilizadas, así como 4 anexos que complementan los aspectos involucrados del sistema desarrollado.

1. FUNDAMENTOS BÁSICOS

1.1 ASFALTENOS

El petróleo en su estado natural es una mezcla de compuestos orgánicos de estructura variada y de pesos moleculares diferentes. En general, es posible agrupar los constituyentes del petróleo en cuatro grupos orgánicos bien definidos: Saturados, Aromáticos, Resinas y Asfaltenos conocido como SARA. El estudio de la fracción pesada del crudo (los asfaltenos), se ha incrementado en los últimos años debido a los problemas que estos representan en los procesos de upstream y downstream.

1.1.1 Generalidades

El término asfaltenos hace referencia a los constituyentes de una mezcla de hidrocarburos que a temperatura ambiente son insolubles en n-alcanos de bajo peso molecular como n-pentano y n-heptano, pero solubles en aromáticos como benceno, tolueno y xileno. Los asfaltenos son considerados como la fracción más pesada del hidrocarburo y el componente más polar (Kokal y Sayegh, 1995).

Son partículas sólidas semicristalinas de color marrón oscuro a negro que contienen carbón, hidrógeno, oxígeno, nitrógeno, azufre y se encuentran en suspensión coloidal o en forma micelar dependiendo de la polaridad y de la presencia de otros compuestos en el petróleo (Mansoori et al, 2001).

Los asfaltenos no tienen un punto de fusión definido y usualmente espuman y expanden cuando se calientan y pueden dejar residuos carbonáceos. El peso molecular de los asfaltenos es alto y variable, no se ha logrado consolidar un valor exacto o rango específico, sin embargo, se podría establecer que en todos los casos es mayor a 500 g/mol y el punto de ebullición está por arriba de 540°C. Esta variación en el peso molecular pone en manifiesto la existencia del fenómeno de asociación intermolecular en los asfaltenos, que generan valores altos en el peso molecular [1].

1.1.2 Composición y estructura

La estructura elemental de los asfaltenos es muy variada y depende del crudo del cual provienen. Los asfaltenos son sólidos friables de color marrón oscuro a negro, sin punto de fusión definido. Ellos se descomponen por calentamiento, se funden y por posterior

enfriamiento se resolidifican. Los resultados de análisis elementales realizados a varias muestras de asfaltenos precipitadas por el n-pentano y n-heptano de diferentes crudos del mundo poseen cantidades de carbono e hidrógeno que varían en rango muy pequeño: $82 \pm 3\%$ en peso para el carbono; $8,1 \pm 0,7\%$ en peso para el hidrógeno. Esto indica que la relación de H/C también es bastante constante: 1.15 ± 0.05 . La relación constante de H/C sugiere que los asfaltenos tienen una composición definida (Kokal y Sayegh, 1995).

Existe una significativa diferencia de los asfaltenos precipitados con n-heptano respecto a los precipitados con n-pentano, la relación H/C de los primeros es más baja, lo que indica su alto grado de aromaticidad. Las relaciones N/C, O/C y S/C son usualmente más altas en los asfaltenos precipitados con n-heptano, a causa de la alta proporción de heteroátomos en esta fracción. En la figura 1 se muestran gráficamente las principales características de las fracciones asfálticas de C5 (precipitados con n-pentano) y C7 (precipitados con n-heptano) y su relación con el peso molecular.




Figura 1 “Diagrama de long” los asfaltenos en el crudo presentan una cantidad alta en peso molecular, polaridad y aromaticidad.

La estructura de las moléculas de asfaltenos muestra que son hidrocarburos con partes relativamente polares dadas por los anillos aromáticos y los grupos funcionales y partes apolares constituidas por las cadenas alifáticas; lo cual permite presentar una dualidad polar-apolar dándole propiedades interfaciales.

Tabla 1. Composición típica de elementos presentes en moléculas de asfalteno [2].

Elemento (% peso)	Rango	Valores típicos
Carbón	78-90	82-84
Hidrogeno	6.1-10.3	6.5-7.5
Nitrógeno	0.5-3	1.0-2.0
Azufre	1.9-10.8	2.0-6.0
Oxígeno	0.7-6.6	0.8-2.0
Vanadio (ppm)	0-1200	100-300
H/C	0.8-1.5	1.0-1.2

La determinación de la estructura molecular de los asfaltenos se realiza mediante diversas técnicas analíticas, entre las más importantes se tiene [3] [4]:

- Difracción de rayos X.
- Resonancia magnética nuclear.
- Absorción óptica.
- Espectroscopia molecular de fluorescencia.
- Difracción de neutrones a pequeños ángulos.
- Espectroscopia de masas, ultracentrifugación.
- Microscopía de sonda de barrido.
- Hidrogenación.
- Oxidación.

Los resultados de muchas de estas técnicas convergen en que los asfaltenos contienen de 4 a 10 anillos aromáticos [3].

Los asfaltenos son lipofílicos con respecto a los aromáticos en que ellos están formando soluciones micelares sumamente dispersas. Específicamente, son moléculas lipofóbicas con respecto a parafinas como el pentano y suelen formar complejas macromoléculas altamente polares (Pacheco y Mansoori, 1997). Se ha comprobado que estructuralmente los asfaltenos son una fracción de compuestos que existen naturalmente en el crudo como agregados de núcleos aromáticos condensados, organizados en grupos funcionales como: carboxilo, cetonas, aldehídos, benzotiofenos, dibenzotiofenos, naftenobenzotiofenos, sulfuros alquílicos, sulfuros alquil-arílicos y sulfuros arílicos [5], los cuales poseen heteroátomos (nitrógeno, azufre, oxígeno). Los metales, como níquel y vanadio, aunque han sido detectados en las fracciones asfalténicas en cantidades importantes, son difíciles de integrar a la estructura del asfalteno. Estos metales se

encuentran comúnmente en las porfirinas, pero aún se desconoce si éstas son parte o no de la estructura de los asfaltenos.

1.1.3 Mecanismos de deposición de asfaltenos

El tipo y la cantidad de depósitos de compuestos orgánicos pesados del petróleo varían dependiendo de los hidrocarburos presentes, y de la cantidad relativa de cada familia orgánica involucrada. En general la deposición de asfaltenos se puede explicar detalladamente con base en cuatro efectos (mecanismos): 1) Efecto de la polidispersidad; 2) efecto estérico coloidal; 3) efecto de agregación y 4) efecto electrocinético. Uno o más de estos mecanismos puede describir la deposición de asfaltenos durante los procesos de producción, transporte o procesamiento de crudo [6].

1.1.3.1 Efecto de la polidispersidad

Según Kawanaka, Park y Mansoori (1991) y Kawanaka, Leontaritis, Park y Mansoori (1989), el grado de dispersión de las fracciones pesadas en el crudo depende de la composición química del petróleo. La relación moléculas polares/moléculas no polares y livianas/pesadas (figura 2) son los factores responsables de la estabilidad de la polidispersión presente en el seno del crudo; cualquier perturbación que altere el balance de los factores mencionados dará origen a la deposición de fracciones pesadas. Un cambio en la temperatura, presión, composición, así como la adición de un solvente miscible en el crudo puede desestabilizar el sistema.

Como consecuencia, las fracciones pesadas y/o polares se separan del crudo dentro de otra fase líquida o dentro de un líquido precipitado. Los segmentos de las fracciones separadas, los cuales contienen N, S, O o enlaces de hidrógeno, comienzan a flocular y pueden originar depósitos irreversibles de orgánicos pesados, los cuales pueden ser insolubles en los solventes [7].




Figura 2. Efecto del cambio de composición sobre la precipitación de compuestos orgánicos pesados [6].

1.1.3.2 Efecto estérico coloidal

(Katz y Bea 1945), (Ray et. al. 1957), (Rogachera et al 1980), (Kawanaka et al. 1989; 1991). Algunos de los orgánicos pesados (especialmente asfaltenos) se separarán de la fase del crudo en un agregado y permanecerán suspendidos en él, mediante agentes peptizantes como las resinas, que serán adsorbidas sobre su superficie y mantenidas a flote. La estabilidad del coloide es función de concentración del agente peptizante en solución, la fracción superficial de los agregados ocupada por el agente peptizante y las condiciones de equilibrio en solución entre éste y los agregados asfálticos [7].




Figura 3. Peptización de las moléculas de asfaltenos y migración de moléculas de resinas [6].

1.1.3.3 Efecto de agregación

La variación de la concentración de un agente peptizante causa cambios en la adsorción sobre las partículas orgánicas pesadas. La concentración del agente peptizante puede disminuir a un punto en el cual la cantidad adsorbida no es suficiente para cubrir completamente la superficie de las partículas orgánicas pesadas. Esto conlleva a que las partículas pesadas se acerquen simultáneamente, aumenten su tamaño y floculen.




Figura 4. Floculación y precipitación de las moléculas de asfaltenos [6].

1.1.3.4 Efecto electrocinético

Cuando el petróleo fluye en un conducto (medio poroso, pozo, tubería, etc.) debe considerarse el efecto electrocinético (Mansoori, 1994) originado por el desarrollo de una

diferencia de potencial eléctrico a lo largo de la longitud del conducto, generado por el movimiento de partículas coloidales cargadas. Esta diferencia de potencial eléctrico podría entonces causar un cambio en las cargas de las partículas coloidales conducto abajo, produciendo como resultado final la deposición y taponamiento del conducto.




Figura 5. Deposición electrocinética y taponamiento en una tubería. [6]

1.1.4 Modelos de precipitación de asfaltenos

Constituyen una herramienta matemática que relaciona los parámetros físico-químicos del sistema asfaltenos solvente (medio de dispersión o solubilización) con los mecanismos intermoleculares que dan origen al comienzo de la floculación y la cantidad de asfaltenos precipitados en el petróleo.

Los modelos predictivos se dividen en siete grupos: 1) modelo termodinámico coloidal, 2) modelo de solución polimérica, 3) modelo de solución regular, 4) modelo de sólido, 5) modelo de PC-Saft, 6) modelo de micelización y 7) Modelo numérico.

1.1.4.1 Modelo termodinámico coloidal

Es un modelo basado en la termodinámica estadística y en la ciencia de los coloides. Supone que los asfaltenos son partículas dispersas en el crudo en suspensión coloidal, estabilizados por resinas adsorbidas en su superficie.

El modelo se fundamenta en los siguientes métodos:

- Potencial químico de las resinas y la teoría de polímeros en solución de la termodinámica estadística.
- Adsorción de las resinas e isoterma de Langmuir.
- Fenómenos electrocinéticos durante la precipitación de los asfaltenos.

En este modelo, el equilibrio Líquido – Vapor es modelado por una ecuación de estado cúbica para establecer la composición de la fase líquida (crudo). Con base a medidas

experimentales del punto de floculación de los asfaltenos se estima el potencial químico crítico de las resinas usando la teoría de polímeros en solución de Flory – Huggins. Este potencial químico crítico es usado para predecir el punto de floculación para otras condiciones [7].

1.1.4.2 Modelo de solución polimérica

En varios trabajos sobre la precipitación de asfaltenos, se ha sugerido que la teoría de solución polimérica puede ser utilizada para modelar la fase líquida en equilibrio con una fase de asfaltenos, (por ejemplo, Hirschberg et al [8], 1988; Burke et al [9], 1990; Kawanaka et al [10], 1991; y de Boer et al [11], 1995). Este modelo tiene en cuenta variables como volumen molar del asfalteno, promedio de volumen molar del líquido a la temperatura del sistema, parámetro de solubilidad de las moléculas de asfalteno y la fase líquida, entre otras.

1.1.4.3 Modelo de solución regular

Este modelo es propuesto por Chung T en 1992 [12] y también es trabajo por Yarranton et al en 1996 [13]. Se describe como un modelo predictivo generalizado que se basa en el principio termodinámico de equilibrio de fase sólido-líquido. El modelo tiene en cuenta los efectos de la temperatura, composición, y el coeficiente de actividad en la solubilidad de la cera y asfaltenos en soluciones orgánicas. Se asume que los asfaltenos se disuelven en el aceite en un estado líquido verdadero, no en suspensión coloidal, y el proceso de disolución-precipitación es reversible mediante el cambio de las condiciones termodinámicas. El modelo es termodinámicamente consistente.

1.1.4.4 Modelo de sólido

Propuesto por Ngheim et al en 1993 [14], trata los asfaltenos precipitados como un componente simple en fase sólida, mientras que las fases crudo y gas son modeladas con una ecuación de estado cúbica.

Actualmente es uno de los modelos que tienen mayor precisión a la hora de realizar predicciones para precipitación de asfaltenos, para lograr esto requiere un grado considerable de datos experimentales para ajustar el modelo.

1.1.4.5 Modelo de PC-SAFT

La ecuación de PC-SAFT (Gross y Sadowski) [15], puede ser un buen candidato para cerrar la brecha entre los modelos de mecánica estadística y los modelos clásicos de ingeniería de petróleo dominadas por las ecuaciones de estado cúbicas. PC-SAFT es un modelo que ha sido desarrollado con base al trabajo de Chapman et al [16].

PC-SAFT representa cada molécula a través de tres parámetros:

- Número de segmentos: m
- Diámetro Segmento: σ
- Energía Segmento: ϵ

1.1.4.6 Modelo de micelización.

Victorov y Firoozabadi (1996) [17] y más adelante Prausnitz y Firoozabadi (1996 y 2000) [18] han propuesto un modelo de formación de micelas para la precipitación de asfáltenos a partir de aceites crudos. De acuerdo con este modelo, los asfáltenos se auto-asocian para formar un núcleo micelar esférico. Moléculas de resina son absorbidas sobre la superficie del núcleo micelar de asfáltenos formando una capa alrededor de ella. La precipitación es un resultado de minimizar la energía libre de Gibbs, cuando los asfáltenos en una fase infinitamente diluida se transfieren a una fase de asfáltenos puro con una carcasa de resina. Para utilizar el concepto de este modelo, es necesario contar con modelos de fugacidad de asfáltenos, resinas y micelas de resina-asfáltenos en solución, y un modelo para el cambio en la energía libre de Gibbs, como resultado de la formación de micelas. Debido a su complejidad, el modelo tiene un potencial limitado como modelo predictivo.

1.1.4.7 Modelo numérico.

Son recientes, surgieron de la necesidad de no involucrar procedimientos complejos de laboratorio; con el paso de los años se han enriquecido hasta lograr avances significativos y convertirse en una poderosa herramienta. Las propuestas realizadas involucran la aplicación de técnicas como ecuaciones empíricas, sistemas inteligentes, redes neuronales artificiales. Se plantean a partir de parámetros como la composición química del crudo, %wt de asfaltenos y resinas, temperatura, gravedad API.

Los modelos son diseñados a partir de información disponible de estudios experimentales o de literatura, con el fin de predecir el %wt de asfaltenos precipitados, la presión de inicio de precipitación de asfaltenos (AOP), la envolvente de precipitación de asfaltenos (ADE) e incluso la presión de burbuja. La principal desventaja de los modelos numéricos ha sido la obtención de resultados precisos y fiables sólo para condiciones restringidas; debido a que se fundamentan en los datos a partir de los cuales son construidos.

1.2 ANÁLISIS SARA

En general, es posible agrupar los constituyentes del petróleo en cuatro grupos orgánicos bien definidos, a saber: a) Saturados, b) Aromáticos, c) Resinas y d) Asfaltenos, este conjunto es conocido como SARA [19].




Figura 6. Composición general del crudo [20].

El fraccionamiento se basa en la solubilidad de los componentes de hidrocarburos en diversos solventes utilizados en esta prueba. Los asfaltenos se separan de los otros componentes de los hidrocarburos mediante el agregado de un n-alcano, tal como n-heptano. Los componentes remanentes, denominados maltenos, son fraccionados en forma ulterior haciendo pasar la mezcla a través de una columna. Cada componente es removido de la columna mediante lavado con diversos solventes.

La importancia de esta herramienta, es que sirve como punto de partida para evaluar otras metodologías de evaluación de estabilidad de los asfaltenos existentes en la literatura, como el índice de inestabilidad coloidal (CII) y el índice de refracción (IR).

1.2.1 Saturados

Los hidrocarburos saturados o alcanos, son removidos mediante lavado con n-alcano. Saturado significa que la molécula contiene el número máximo de átomos de hidrógeno posibles, con enlaces dobles o triples entre los átomos de carbono e hidrógeno. La fracción saturada consiste de material no polar. La más simple de esas moléculas es el metano [CH₄].

1.2.2 Aromáticos

Los aromáticos incorporan uno o más anillos de seis átomos de carbono y seis átomos de hidrógeno, los cuales son más polarizables. El aromático más simple es el benceno [C₆H₆].

1.2.3 Resinas

Las resinas se asemejan un tanto a los asfaltenos. Constituyen el componente polar no volátil del petróleo crudo que es soluble en n-alcanos e insoluble en propano líquido.

1.2.4 Asfaltenos

Los asfaltenos son insolubles en n-alcanos, tales como el n-pentano o el n-heptano, y solubles en tolueno.

La ventaja del método SARA es que se trata de un procedimiento simple, que puede ser llevado a cabo en muchos laboratorios. No obstante, el análisis SARA también plantea numerosas desventajas, que se ponen de manifiesto cuando se utiliza con fines ajenos a su objetivo original.

En primer lugar, el petróleo muerto carece de los componentes gaseosos que están disueltos en los petróleos vivos y, por ende, los resultados no son representativos de la forma en que actuaría el petróleo bajo condiciones de yacimiento. Además, los métodos de laboratorio difieren considerablemente y la solubilidad de los asfaltenos varía con el tipo de n-alcano utilizado para precipitarlos. Esto significa que un mismo petróleo podría tener dos o más resultados SARA, dependiendo del precipitante utilizado.

Dada su simplicidad, el análisis SARA se ha convertido en un medio generalizado para comparar los petróleos, pero a menudo, como no se informan las variaciones de las técnicas de laboratorio, las comparaciones entre laboratorios probablemente carecen de validez. Aunque el método SARA constituye un primer paso razonable para categorizar

los crudos muertos, provee una caracterización insuficiente tanto para las necesidades de refinación del petróleo como para los problemas del sector de exploración y producción, donde se necesitan las propiedades de los petróleos vivos.

1.2.5 Estabilidad de los asfaltenos

Diversas técnicas y enfoques son utilizados para evaluar la estabilidad de los asfaltenos en el petróleo muerto. Estos tienen como base el análisis SARA, los principales métodos se explican a continuación:

1.2.5.1 Relación asfaltenos/resinas

Las resinas constituyen la fracción del petróleo que peptiza a los asfaltenos manteniéndolos en forma de nano-agregados dispersos en la matriz oleosa. El cociente entre las resinas y los aromáticos representan una relación importante para identificar la estabilidad de los asfaltenos [21].

$$\frac{R}{A} = \frac{\text{Resinas}}{\text{Aromáticos}} \quad (1)$$

Se establecen tres rangos de estabilidad.

- Si $R/A > 3.0$: Se considera que los asfaltenos están en estado estable.
- Si $2.0 < R/A < 3.0$: Se considera que los asfaltenos están en estado metaestable.
- Si $R/A < 2.0$: Se considera que los asfaltenos están en estado inestable.

1.2.5.2 Índice de Inestabilidad Coloidal (CII)

El CII (Coloidal Instability Index), propuesto por Asomaning y Watkinson [22], se define como la relación entre las fracciones desfavorables (asfaltenos + saturados) sobre las fracciones favorables (resinas + aromáticos) del petróleo.

$$\frac{(\text{Saturados} + \text{Asfaltenos})}{(\text{Aromaticos} + \text{Resinas})} = CII \quad (2)$$

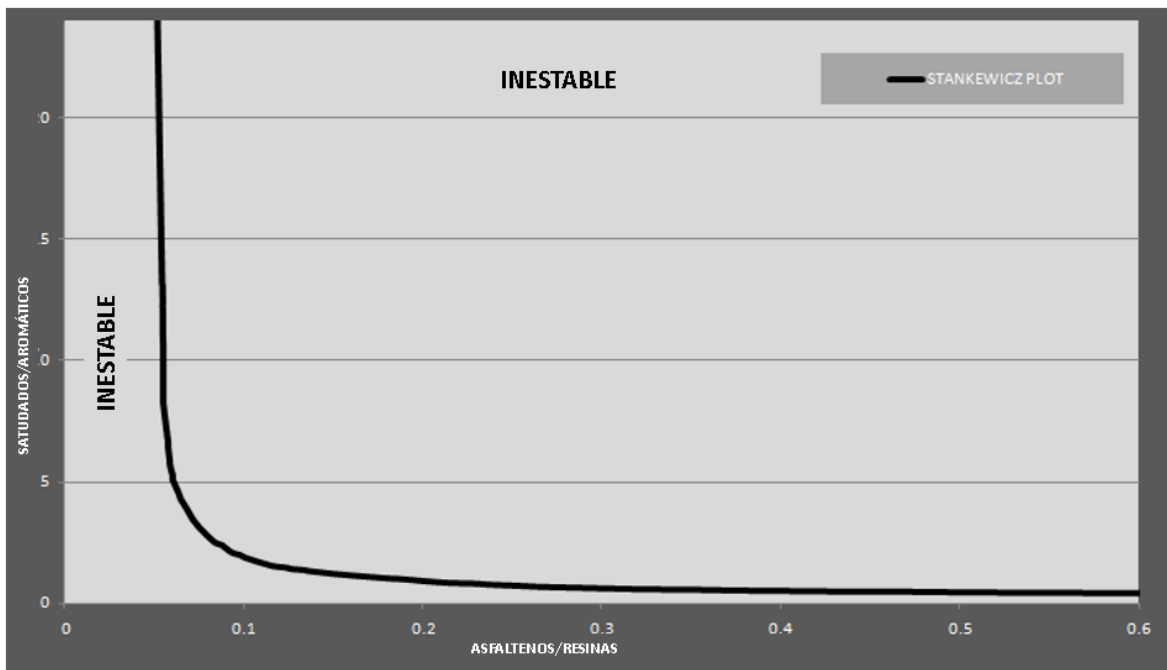
Se clasifican en tres rangos:

- $CII > 0.9$: Se considera que los asfaltenos están en estado inestable.
- $0.7 < CII < 0.9$: Se considera que los asfaltenos están en estado metaestable o incierto
- $CII < 0.7$: Se considera que los asfaltenos están en estado estable.

1.2.5.3 Stankiewicz Plot

Otro método analítico para la determinación de la estabilidad de los asfaltenos es el propuesto por Stankiewicz donde relaciona saturados/aromáticos vs asfaltenos/resinas en una sola gráfica. La primera relación (saturados/aromáticos) muestra una medida indirecta de la capacidad disolvente de la muestra en los asfaltenos (un valor elevado implica una tendencia pobre del disolvente). Por otra parte, la relación asfaltenos/resinas, se refiere a la medida de la estabilidad coloidal de los asfaltenos (una baja proporción de asfaltenos/resinas implica una buena estabilización coloidal) [23].


Gráfica 1. Stankiewicz Plot [23].



1.2.5.4 Stability Cross Plot (SCP)

Bonilla et al [24] proponen una serie de gráficas basándose en el análisis físico-químico, cualitativo y cuantitativo. Las cuatro curvas que se muestran a continuación separan los aceites estables de los inestables.

Gráfica 2 Stability Cross Plot (SCP). (a) $[(R/A)/(S/Ar)]$ vs $[Ar/A]$ (b) $[(R/A)/(S/Ar)]$ vs $[R/A]$ (c) $[S/Ar]$ vs $[R/A]$ (d) $[(R/A)/(S/Ar)]$ vs $[Ar/(S/A)]$ [25].



2. PRECIPITACIÓN DE ASFALTENOS

El fenómeno de precipitación de asfaltenos se manifiesta en mayor o menor grado en prácticamente todas las facetas asociadas a la producción, transporte y procesamiento de petróleo y en algunos casos, puede constituirse en un serio problema; ya que puede ocasionar daños a la formación y taponamiento en sitio, de pozos y equipos de superficie [26].

Los asfaltenos presentes en el crudo tienden a desestabilizarse bajo ciertas condiciones de presión, temperatura, composición y régimen de flujo lo que ocasiona que se agreguen, floculen y precipiten en el medio poroso. La precipitación ocurre por diversos factores químicos, eléctricos, mecánicos y termodinámicos que afectan la estabilidad de los asfaltenos en el fluido.

La precipitación de asfaltenos no depende del contenido de éstos en el crudo, pero sí de la proporción de parafinas y aromáticos presentes. Los crudos pesados tienen mayor contenido de asfaltenos, sin embargo, los crudos livianos son los que presentan mayor problemática con la precipitación y depositación de asfaltenos.

2.1 FLOCULACION, PRECIPITACIÓN Y DEPOSITACIÓN

A pesar que la precipitación de asfaltenos es un problema muy conocido y estudiado dentro de la industria petrolera, sus principales causas, y en particular, sus mecanismos no han podido ser totalmente comprendidos hasta el momento.

Con base en la numerosa información experimental se ha propuesto que el fenómeno de precipitación de asfaltenos puede ser descrito como un proceso en varias etapas que van desde la asociación de asfaltenos para formar pequeños agregados o pseudo-micelas, pasando por el crecimiento de éstos para conducir a agregados más grandes, los cuales, en condiciones favorables, crecen lo suficiente como para precipitar, la figura 7 representa las etapas de la precipitación de asfaltenos [2].




Figura 7. Agregación y precipitación de asfaltenos. (A) Asfaltenos en estado coloidal peptizados por las resinas. (B) Por modificaciones fisicoquímicas las resinas comienzan a abandonar al asfalto. (C) Floculación de asfaltenos. (D) Precipitación de los asfaltenos.

2.1.1 Floculación

La floculación se define como la capacidad de las partículas coloidales para agregarse ante cualquier cambio de las condiciones iniciales, tales como cambios en la temperatura, presión o composición. Alkafeef, Gochin y Smith [27] señalan que el mecanismo de floculación describe el crecimiento de las partículas de asfaltenos a tamaños más grandes.

2.1.2 Precipitación o agregación

El mecanismo de precipitación representa una cantidad de asfalto que se separa de la solución y tiende a “agregarse”. Este fenómeno ocurre cuando dos partículas de asfalto con movimiento Browniano presentan contacto en áreas libres de resina, formando un cúmulo asfáltico de dos partículas que se difundirá en el sistema, con la probabilidad de quedar pegado a otras partículas individuales o a otros agregados asfálticos que se encuentren en el aceite.

2.1.3 Depositación

El fenómeno de depositación transcurre luego de la agregación, el número de partículas individuales y cúmulos asfálticos disminuye, debido a que se juntan para formar agregados más grandes y pesados que se acumulan. Además, elementos externos, tales como la gravedad, adsorción, etc., ocasionan que las partículas y agregados asfálticos tiendan a precipitarse hacia la superficie de la roca y a pegarse a las paredes de las tuberías.

2.2 PRESIÓN DE INICIO DE PRECIPITACION DE ASFALTENOS (AOP).

Una de las más populares técnicas para evaluar la precipitación de asfaltenos consiste en la determinación del onset. El término "onset" representa el punto en que la primera partícula sólida se forma tras la desestabilización, causada principalmente por la declinación de la presión además del efecto que genera las alteraciones de temperatura y composición, lo que conlleva posteriormente a la precipitación. Con base en lo anterior, el flujo de petróleo en el medio poroso puede contener asfaltenos solubles, asfaltenos precipitados disueltos y/o asfaltenos depositados. Todo el asfalteno precipitado no se deposita ni causa daño a la formación; los precipitados pueden ser arrastrados por el fluido, pueden depositarse en la superficie de la roca, o se agregan hasta formar un precipitado mayor que logre taponar las gargantas de poro.

A medida que la presión desciende, la cantidad de precipitado aumenta, hasta un máximo como se observa en la figura 8. Siguiendo este mismo comportamiento la cantidad de asfalteno precipitado alcanza su nivel más alto en la presión de saturación y por debajo la cantidad de precipitado disminuye debido a que el gas que está en solución es liberado causando que los asfaltenos se estabilicen y por lo tanto se redisuelvan en el fluido de yacimiento. Por lo tanto, este proceso es reversible siempre y cuando no haya depositación.




Figura 8. Presión onset de precipitación de asfaltenos [26].

Debido a la naturaleza del crudo, su composición y propiedades de yacimiento, la presión onset es diferente en cada fluido de yacimiento y resulta complejo estimarlo para cada sistema.

Se han hecho estudios para predecir el onset de precipitación en laboratorio mediante detección por cambios de intensidad de luz, por fluorescencia óptica y conductividad eléctrica, mediciones de viscosidad e intensidad superficial de fluidos asfálticos, entre otros. Sin embargo, son métodos que tienen como limitante la toma de muestras de fondo de pozo a condiciones específicas, lo que involucra desarrollar actividades alternas y alta inversión por los elevados costos.

2.3 ENVOLVENTE DE PRECIPITACIÓN DE ASFALTENOS (ADE).

Habitualmente, la cantidad de asfalteno precipitado se incrementa a medida que se reduce la presión, y alcanza un punto máximo con la presión de burbujeo. La línea de presión-temperatura (P-T), que delinea las condiciones de precipitación por encima del punto de burbujeo, se conoce como el límite superior de la envolvente de precipitación de asfaltenos (Asphaltene Deposition Envelopment) [20].

Al revisar la figura 9 se puede dar seguimiento al fenómeno de precipitación de asfaltenos en el yacimiento: la envolvente de precipitación de asfaltenos (curva roja continua y a trazos) delimita las zonas de estabilidad para los asfaltenos en solución. Las condiciones de yacimiento establecidas se representan con el punto rojo, el agotamiento primario hace que la presión se reduzca. Cuando la presión alcanza la envolvente superior de precipitación de asfaltenos, también conocida como presión de inicio de la precipitación

de asfaltenos, los asfaltenos menos solubles precipitarán. Conforme la presión continúe decreciendo, más asfaltenos precipitarán hasta que se alcance la presión de burbujeo, y se libere el gas de la solución. Con la reducción continua de la presión se ha removido suficiente gas del sistema, y el petróleo crudo podrá comenzar a redissolver los asfaltenos hasta la envolvente inferior de precipitación de asfaltenos.

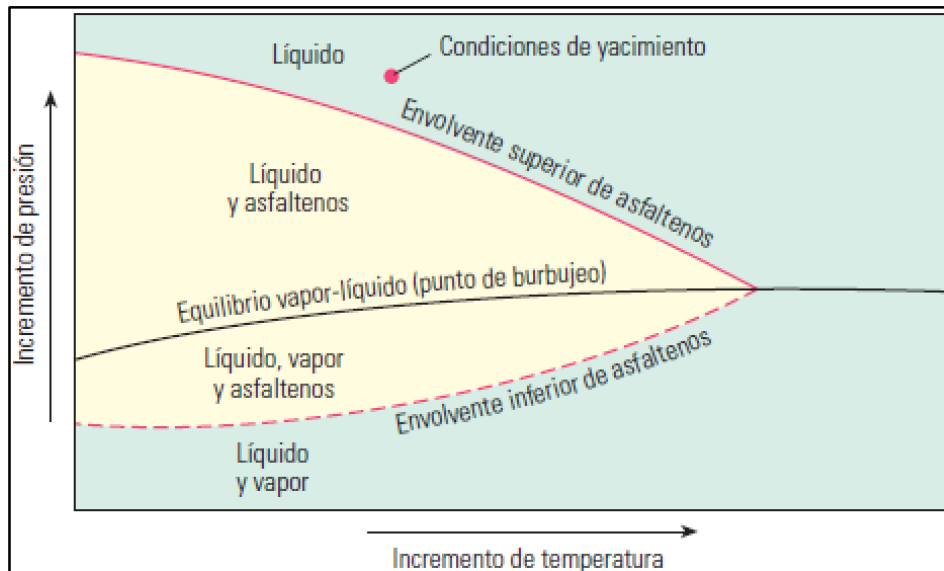


Figura 9. Envolvente de precipitación de asfaltenos (ADE) en el espacio presión-temperatura [20].

2.4 FACTORES CAUSANTES DE LA PRECIPITACIÓN DE ASFALTENOS

Los principales parámetros que controlan la dispersabilidad de los asfaltenos son la presión, temperatura y la composición del crudo. Por lo que cualquier acción de naturaleza química, eléctrica o mecánica, en el proceso de producción, que altere dichos parámetros, tiende a comprometer la dispersabilidad, provocando una variación del balance termodinámico que mantiene los coloides en solución, ocasionando la floculación y precipitación de los asfaltenos en el crudo. De esta manera, este fenómeno puede originarse debido a los siguientes factores:

2.4.1 Factores Termodinámicos

La dispersabilidad molecular está particularmente influenciada por cambios graduales en las variables operacionales más importantes dentro del proceso de producción: la presión y la temperatura, los cuales son generalmente causados por la interacción del crudo con obstrucciones, tales como: válvulas de subsuelo, conexiones entre tuberías, y reductores,

etc., que controlan la velocidad del flujo y, en consecuencia, la ocurrencia o no del fenómeno de precipitación.

2.4.1.1 Efecto de la Temperatura

Los efectos de temperatura son importantes ya que mientras más alta sea la temperatura mayor es la solubilidad de las resinas en los n-alcenos y por consiguiente los asfaltenos son menos solubles en el crudo. (Takhar, 1995). Al disminuir la temperatura algunas micelas resina-asfalteno se desestabilizan y se agregan entre ellas formando grandes cúmulos.

2.4.1.2 Efecto de la Presión

La presión es uno de los factores más importantes que influencia los depósitos de sólidos en crudos asfálticos. El efecto de la presión es más intenso cuando el petróleo es rico en fracciones livianas y está cercano a su punto de burbujeo (Leontaritis y Mansoori, 1988).

Bajo condiciones isotérmicas, la disminución de la presión del crudo se asocia con la disminución de la densidad del fluido y, correspondientemente con la disminución de la solubilidad. La separación promedio entre moléculas de la fase líquida y las micelas de resina-asfalteno es mayor en densidades bajas, resultando interacciones menos atractivas. Por tal motivo al disminuir la presión y por consiguiente la densidad, algunas micelas de resina-asfalteno se agregan formando grandes cúmulos que pueden llegar a precipitar.

Cerca de la zona de presión de burbuja, la precipitación es mayor debido a la diferencia máxima entre la densidad de los asfaltenos y la del aceite a la presión de burbuja, esto se da justo antes de que la primera burbuja de gas se desprende del aceite sub-saturado. Cuando el porcentaje en moles de gas está a punto de aumentar desde cero, se presenta el valor más alto de deposición de asfaltenos.

Cuando la presión de yacimiento disminuye por encima de la presión del punto de burbuja, se debilita los enlaces de Van der Waals, junto con el cambio en las propiedades del fluido hace que se perturbe la estabilidad de las micelas de asfalteno-resina. Como el aceite se despresuriza desde la presión del yacimiento a la presión del punto de burbuja, la masa y la composición molar se mantienen constante, pero el volumen molar del contenido de aceite está aumentando, mientras que la densidad global está reduciendo. Debido a la diferencia en la compresibilidad, los volúmenes ocupados por los componentes C6- están aumentando más rápidamente que los de la fracción C7+ [6]. Por lo tanto, los fluidos del yacimiento poseen mayor comportamiento de aceite liviano y

actúan como tal mientras la presión disminuye. Todo esto ocasiona que la precipitación de asfaltenos aumente hasta encontrar un máximo a la presión de saturación [28].

Por debajo de la presión de saturación, la composición de los fluidos del yacimiento cambia cuando la fracción de hidrocarburo más liviana se evapora del aceite como fase gas, cambiando así el volumen molar de la fase líquida y restableciendo una parte de la pérdida de solubilidad de los asfaltenos. Como la presión siga descendiendo, la liberación de gas liviano deja a los fluidos del yacimiento más pesados con mayor fracción de resinas, que es insuficiente para peptizar y estabilizar los asfaltenos. Por lo tanto, con la disminución de la presión por debajo del punto de burbuja, el cambio en la composición de los fluidos del yacimiento resultará en una solubilidad mejorada, con la disminución de la deposición y una redisolución de los asfaltenos en el crudo [28].

2.4.1.3 Efecto de la composición de los fluidos del yacimiento

La composición de un fluido del yacimiento puede cambiar como consecuencia de un agotamiento normal durante la producción primaria del mismo. Esto resultará en la pérdida de los componentes más livianos del petróleo causando una disminución en la relación gas-petróleo (GOR) y un aumento en la densidad de los fluidos.

Como una regla general, ambos efectos reducirán la tendencia de precipitación de asfaltenos de los fluidos del yacimiento. Esto es porque tanto el gas como los asfaltenos compiten por la prevalencia en el petróleo crudo y cuando el petróleo pierde sus fracciones ligeras, más asfaltenos puede ir en solución. Por consiguiente, como la producción en el yacimiento declina, la presión disminuye y el petróleo se hace más pesado, debe esperarse que los problemas de asfalteno disminuyan (Kokal y Sayegh, 1995).

2.4.2 Factores Químicos

Desde el punto de vista químico, existen diferentes vías a través de las cuales se puede provocar cambios en la composición del crudo, y, por consiguiente, la floculación de los asfaltenos. Los distintos factores que producen la precipitación de los asfaltenos se encuentran asociadas a los casos de contacto del petróleo con fluidos no involucrados en el proceso natural de producción, como en métodos de recobro mejorado, estimulación del pozo, inyección química y en otras operaciones como workover y control de arenas. Los factores más influyentes en la estabilidad de los asfaltenos se listan a continuación [24].

2.4.2.1 Inyección de dióxido de carbono

El dióxido de carbono es utilizado en procesos de recobro mejorado por su efecto positivo en la miscibilidad y en el hinchamiento del crudo. Sin embargo, el CO₂ representa una de las causas más comunes de floculación de asfaltenos en pozos productores. El CO₂ produce una desestabilización en el equilibrio de la solución por disminución del pH, cambios de composición y formación de turbulencias.

2.4.2.2 Inyección de gases ricos:

La inyección de gases ricos desestabiliza a los asfaltenos porque disminuye la proporción de carbonos e hidrógenos. Los hidrocarburos livianos tienen una menor afinidad con las estructuras asfálticas comparado con el crudo que posee una proporción de carbono e hidrógeno alta.

2.4.2.3 Alteración del pH

Los cambios en el pH se producen por la presencia de CO₂, ácido mineral o ácido orgánico ocasionado por bacterias. La alteración del equilibrio de la solución desencadenará los depósitos de asfaltenos.

2.4.2.4 Procesos de estimulación

El contacto del crudo con aditivos de estimulación incompatibles como el alcohol isopropílico, alcohol metílico, acetona e incluso glicol o solventes duales a base de surfactantes, que no poseen componentes aromáticos, pueden causar la floculación de los asfaltenos a partir de la solución. En procesos de acidificación con ácidos minerales fuertes se causa cambios bruscos en el equilibrio químico local por pH y por liberación de dióxido de carbono, como también se eleva la concentración de iones [29].

2.4.3 Factores Eléctricos

El estudio de los depósitos orgánicos en el yacimiento ha mostrado que una de las principales causas de desestabilización de los asfaltenos constituye la presencia de un campo eléctrico que se genera por el flujo de partículas cargadas dentro del medio poroso y de la tubería. Los asfaltenos por su característica polar, poseen una carga eléctrica intrínseca, que se considera responsable en cierta forma de la estabilidad de la micela asfaltenos-resina, según el modelo coloidal.

Las micelas se mantienen estabilizadas debido a las fuerzas de repulsión electrostáticas de los núcleos cargados de igual signo. La generación de un potencial eléctrico debido al flujo de partículas cargadas o la aplicación de un potencial externo grande, puede llegar

a neutralizar las cargas eléctricas, perturbar el balance de fuerzas entre las micelas y causar la floculación de asfaltenos [2] [24].

2.4.4 Factores Mecánicos

Los factores mecánicos incluyen los esfuerzos de cizalla por equipos de bombeo de subsuelo como bombas de varilla y bombas electrosumergible además de fuerzas de fricción y fuerzas de impacto entre partículas. Los esfuerzos se asocian a caídas de presión en el fondo del pozo y el equipo de superficie [2].

2.4.5 Otros factores

Algunos sólidos suspendidos en el crudo como finos de arcillas o minerales, limaduras de metales, sedimentos y grava favorecen los procesos de precipitación de los asfaltenos. Las pequeñas partículas suspendidas en el crudo pueden servir de núcleos que promueven la adhesión de los coloides de asfaltenos. Se forman así grandes cadenas de moléculas que tienden a precipitarse más rápido de la solución.

Este efecto ocurre a nivel de las perforaciones y a nivel de las tuberías donde las rugosidades internas también representan “sitios de nucleación” para los depósitos orgánicos [2].

2.5 EFECTOS GENERADOS POR LA DEPOSITACIÓN DE ASFALTENOS

Los problemas asociados a la deposición de asfaltenos ocurren tanto en el subsuelo como en superficie, afectando la explotación efectiva de los yacimientos petrolíferos. Se ha encontrado que la cantidad de asfalteno soluble en un crudo pasa por un mínimo a la presión de burbuja. Esto implica que los problemas relacionados con la deposición de asfaltenos corresponden primordialmente a los yacimientos subsaturados (Hirschberg et al, 1.984).




Figura 10. Problemas ocasionados por la precipitación y deposición de los asfaltenos [20].

A continuación, se presentan los problemas típicos ocasionados por la precipitación de asfaltenos:

2.5.1 Taponamiento del yacimiento y en la vecindad del pozo.

Un problema de gran relevancia es cuando la deposición de los asfaltenos ocurre a nivel de yacimiento y en las cercanías del pozo, debido a que en esta zona ocurren las mayores caídas de presión, alcanzando las condiciones por debajo del umbral superior de precipitación. Debido a que en esta zona el área de flujo es pequeña, la mayor cantidad

de flóculos se adhiere a la roca o es retenida en las gargantas de los poros ocasionando el taponamiento de la formación, ya que sólo una pequeña cantidad de estos es transportada por los fluidos hasta la tubería del pozo. Si los flóculos que se adhieren a la roca tienen un diámetro mayor a $\frac{1}{3}$ del diámetro del poro, se produce el taponamiento.

$$\text{si } \phi_{\text{asfaltenos}} \geq \frac{1}{3} \phi_{\text{poro}} \text{ Taponamiento del medio poroso} \quad (3)$$



Figura 11. Efecto de taponamiento por depósitos de asfaltenos en el medio poroso.

2.5.2 Cambios de mojabilidad en el yacimiento

Si los depósitos de asfaltenos se acumulan en el medio poroso, se afecta la humectabilidad de la roca, debido a la capa orgánica que se forma sobre la misma. Esto se refleja porque la roca, que en la mayoría de los casos es mojada por agua, cambia a ser fuertemente mojada por aceite, facilitando la movilidad del agua, y generando un efecto negativo en la producción.



Figura 12. Efecto de cambio de mojabilidad por depósitos de asfaltenos en el medio poroso.

2.5.3 Taponamiento de la tubería de producción

Durante la producción, el crudo sufre cambios de presión y temperatura a medida que fluye desde el yacimiento hasta la superficie. Esto conduce a que factores

termodinámicos y mecánicos afecten la estabilidad de los asfaltenos causando depósitos en la tubería de producción y en los sistemas de levantamiento artificial.

2.5.4 Taponamiento de líneas de flujo y demás equipos de superficie.

Los problemas de precipitación de asfaltenos en superficie ocurren principalmente en las estaciones de flujo, en las instalaciones y equipos asociadas a los sistemas de manejo, transporte y compresión del gas.

Estudios hechos sobre la deposición de los asfaltenos en los gasductos, han determinado que la presencia de estos en los sistemas de compresión, transporte y manejo del gas, se debe fundamentalmente al arrastre de líquidos por corrientes de gas en los separadores (Álvarez, 2001).

2.5.5 Formación de emulsiones estables.

De estudios experimentales se ha concluido que la presencia de material asfáltico favorece la formación de emulsiones en la mayor parte de los crudos que lo contienen. A mayor contenido de este material, las emulsiones agua-crudo son más estables; ya que las sustancias asfálticas envuelven a las partículas de agua (Álvarez, 2001).

3. REDES NEURONALES ARTIFICIALES EN LA PRECIPITACIÓN DE ASFALTENOS

Las redes neuronales, RNA, y en general los modelos inteligentes, se han convertido en una herramienta fundamental para el análisis y procesamiento de datos en la industria petrolera. En el estudio de la caracterización de asfaltenos, se han planteado modelos con importantes avances enfocados a predecir las condiciones termodinámicas (presión y temperatura) y las cantidades (%wt asfaltenos) precipitadas. Las RNA son un paradigma de aprendizaje y procesamiento automático cuyos elementos se comportan de forma similar a las neuronas biológicas en sus funciones más comunes. Estos elementos están organizados de forma parecida a la que presenta el cerebro humano.

3.1 FUNDAMENTOS DE LAS REDES NEURONALES ARTIFICIALES

Las redes neuronales artificiales son redes interconectadas masivamente en paralelo de elementos simples (usualmente adaptativos) y con organización jerárquica, las cuales intentan interactuar con los objetos del mundo real del mismo modo que lo hace el sistema nervioso biológico [30]. Están inspiradas en las redes neuronales biológicas del cerebro humano. Las RNA al margen de "parecerse", presentan una serie de características propias del cerebro. Por ejemplo, aprenden de la experiencia, generalizan de ejemplos previos a ejemplos nuevos y abstraen las características principales de una serie de datos.

- *Aprender*: adquirir el conocimiento de una cosa por medio del estudio, ejercicio o experiencia. Las RNA pueden cambiar su comportamiento en función del entorno. Se les muestra un conjunto de entradas y ellas mismas se ajustan para producir unas salidas consistentes.
- *Generalizar*: extender o ampliar una cosa. Las RNA generalizan automáticamente debido a su propia estructura y naturaleza. Estas redes pueden ofrecer, dentro de un margen, respuestas correctas a entradas que presentan pequeñas variaciones debido a los efectos de ruido o distorsión.
- *Abstraer*: aislar mentalmente o considerar por separado las cualidades de un objeto. Algunas RNA son capaces de abstraer la esencia de un conjunto de entradas que aparentemente no presentan aspectos comunes o relativos [31].

3.1.1 Estructura básica de una red neuronal artificial

Así como en el sistema nervioso y el cerebro humano, la unidad básica de funcionamiento es la neurona; las RNA también son sistemas compuestos por grandes cantidades de este pequeño elemento. Las neuronas biológicas son células de estructura compleja y funcionamiento sincronizado; cada una se encarga de recibir, procesar y transmitir señales electroquímicas desde y hacia otras neuronas (interconexiones). Si la combinación de entradas es suficientemente fuerte, la salida de la neurona se activa. La Figura 13 muestra las partes que constituyen una neurona.




Figura 13. Componentes de una Neurona [32].

Las RNA simulan principalmente tres elementos de la estructura biológica: las entradas que hace las veces de las dendritas; los pesos, encargados de realizar las interconexiones entre neuronas, simula la sinapsis en el ser humano; y las salidas que son representadas por los axones. La mayoría de los modelos RNA asemeja el funcionamiento básico de las neuronas biológicas aun cuando el comportamiento real de una célula nerviosa tiene muchas complejidades y excepciones.

En las RNA, la unidad análoga a la neurona biológica es el elemento procesador, EP, que tiene varias entradas y las combina, normalmente con una suma básica. La suma de las entradas es modificada por una función de transferencia y el valor de la salida de esta función de transferencia se pasa directamente a la salida del elemento procesador.

La salida del EP se puede conectar a las entradas de otras neuronas artificiales, mediante conexiones ponderadas correspondientes a la eficacia de la sinapsis de las conexiones neuronales.

La Figura 14 representa un elemento procesador de una red neuronal artificial implementada en un ordenador.

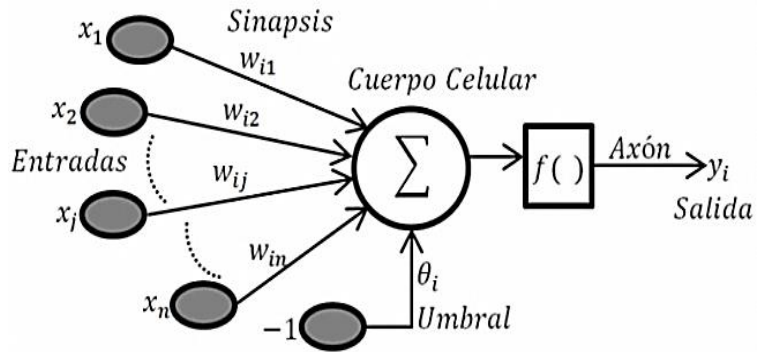


Figura 14. Diagrama de una Neurona Artificial (PE) [33].

El interés de las RNA no reside solamente en el modelo del EP sino en las formas en que se conectan. Generalmente los EP están organizados en grupos llamados niveles o capas, que contienen las interconexiones formadas entre las neuronas. Una red típica consiste en una secuencia de capas con conexiones entre capas adyacentes consecutivas.

Los datos ingresan por medio de la "capa de entrada" donde son presentados a la red, pasan a través de la "capa oculta" y salen por la "capa de salida" que mantiene la respuesta de la red a una entrada. Cabe mencionar que la capa oculta puede estar constituida por varias capas. La Figura 15 muestra el aspecto de una Red Neuronal Artificial.




Figura 15. Arquitectura de una red neuronal totalmente conectada [30].

3.1.2 Aplicaciones de las RNA

Los sistemas de computación neuronal, permiten que las RNA tengan una extensa variedad de aplicaciones, pues provee un acercamiento mayor al reconocimiento y percepción humana que los métodos tradicionales de cálculo, además, presentan resultados razonables en aplicaciones donde las entradas presentan ruido o están incompletas. Algunas de las áreas de aplicación de las RNA son:

- Finanzas.
- Medio ambiente.
- Manufacturación.
- Medicina y salud.
- Fuerzas militares.
- Energía.
- Ciencia e ingeniería.

De igual manera, en la industria del petróleo, las RNA se han convertido en una poderosa herramienta de aplicación en diferentes sectores desde hace bastante tiempo. En la exploración, por ejemplo, permiten evaluar la probabilidad de formaciones geológicas y petrolíferas a partir de la extracción de rasgos estructurales e información litológica de campos potenciales. En ingeniería de yacimientos, se ha logrado a partir de las RNA: caracterización de yacimientos; predicción de la permeabilidad, saturación de agua y daños de formación; estudio de equilibrios de estado, entre otros. En perforación y workover, algunas de los aportes son la predicción de fallas durante la ejecución; optimización de la perforación hidráulica y el diseño de una fractura hidráulica; elección de pozos candidatos a re-estimulación; diseños de sistemas de control de arena, etc.

Complementando lo anterior, a partir de las RNA se ha logrado predecir la clasificación de facies, el tipo de litología y cuantificar propiedades (permeabilidad, porosidad, saturaciones) a partir de los registros de pozos. En el área de producción, ha permitido el análisis de fluidos de fondo de pozo; así como la selección-optimización de sistemas de levantamiento artificial de acuerdo a las necesidades o requerimientos específicos. Ha sido tal el aprovechamiento de las RNA en la industria de los hidrocarburos, que algunos proyectos son sometidos a estudios de viabilidad y/o revisión a partir del diseño de sistemas de RNA.

3.1.3 Funcionamiento de las RNA

La construcción de una RNA incluye la correcta aplicación de aspectos teóricos, así como la ejecución de variados procesos que incluyen el diseño o concepción de la red, entrenamiento, validación, codificación, hasta conseguir el funcionamiento completo.

Entre los múltiples aspectos a considerar está la búsqueda, preparación y codificación de los datos; la topología de la red que depende de la cantidad y tipo de capas a utilizar, el esquema de interconexión entre capas y entre capas-neuronas, la cantidad de neuronas; el proceso de aprendizaje seleccionado que abarca los ciclos, regla (s) de aprendizaje, entrenamiento y finalmente la evaluación de la misma.

El proceso más decisivo para lograr el adecuado funcionamiento de una RNA es el aprendizaje, más conocido como proceso de entrenamiento o acondicionamiento. Como se estipuló anteriormente, los datos de entrada son procesados con el fin de lograr una salida; para lograr el objetivo, la RNA debe ejercitarse para calcular la salida correcta para cada constelación (arreglo o vector) de entrada.

En el proceso de entrenamiento, la topología de la red (arquitectura) y las diferentes funciones de cada neurona (entrada, activación y salida) no pueden cambiar, mientras que los pesos sobre cada una de las conexiones si pueden hacerlo; por ende, el aprendizaje de una red neuronal corresponde a la adaptación de los pesos en respuesta a una información de entrada.

Así como en los sistemas biológicos, los cambios que se producen durante el aprendizaje en las RNA se reducen a la destrucción, modificación y creación de conexiones entre las neuronas. Los métodos de aprendizaje son los criterios que se siguen para cambiar el valor asignado a las conexiones cuando se pretende que la red aprenda una nueva información; los principales son: aprendizaje supervisado y no supervisado.

- **Aprendizaje supervisado:**

Se caracteriza porque el proceso de aprendizaje se realiza mediante un entrenamiento controlado por un agente externo (supervisor, maestro) que determina la respuesta que debería generar la red a partir de una entrada. El supervisor controla la salida de la red y en caso de que ésta no coincida con la deseada, se procederá a modificar los pesos de las conexiones, con el fin de conseguir que la salida obtenida se aproxime a la deseada [30].

- Aprendizaje no supervisado.

Las redes con aprendizaje no supervisado, también conocido como autosupervisado, no requieren influencia externa para ajustar los pesos de las conexiones entre sus neuronas. La red no recibe ninguna información por parte del entorno que le indique si la salida generada en respuesta a una determinada entrada es o no correcta. Estas redes deben encontrar las características, regularidades, correlaciones o categorías que se puedan establecer entre los datos que se presenten en su entrada [30].

3.2 ANTECEDENTES

La utilización de las redes neuronales artificiales en los últimos años, ha constituido una herramienta muy importante para identificar las condiciones de precipitación de asfaltenos. Hasta el momento, para caracterizar los asfaltenos se recurren a diversas técnicas experimentales que en la mayoría de los casos no son ejecutadas por sus elevados costos y rigurosidad de los procedimientos involucrados. El objetivo del empleo de las RNA es obtener las variables experimentales sin necesidad de realizar las operaciones.

La primera investigación encontrada en la literatura relacionada con el tema fue desarrollada por Mohammadi y Richon (2008) [34], a partir de un modelo matemático basado en la técnica de RNA de alimentación hacia adelante, se aprovechó el algoritmo de optimización Levenberg-Marquardt modificado, para modelar el inicio de la precipitación de asfaltenos disueltos en la solución de disolvente + precipitado. Este modelo tiene una neurona de salida (masa de precipitante / masa de asfaltenos), una neurona de entrada (masa de disolvente / masa de asfaltenos) y una neurona en la capa oculta; utiliza una función de activación lineal.

Abedini et al (2010) [35], desarrollaron un modelo RNA para predecir y simular la cantidad de precipitación de asfaltenos en función de la relación de dilución, el peso molecular del disolvente y la temperatura. Se utilizó el algoritmo de aprendizaje de retropropagación con diferentes métodos de entrenamiento; haciendo uso del algoritmo de Levenberg-Marquardt (LM). Los datos experimentales sirvieron como datos de entrada y de destino para generar el modelo en un rango de temperatura de 293 a 343 K. A su vez, los resultados del modelo de RNA se compararon con los valores predichos utilizando algunas ecuaciones de escala, como Rassamdana (1996), Hu et al. (2000), y Ashoori et al (2003) concluyendo así que éstas no eran lo suficientemente capaces de predecir y simular la cantidad de precipitación de asfaltenos.

En 2011 Ahmadi [36], desarrolló un modelo híbrido para la predicción de la precipitación de asfaltenos basado en la combinación de una red neuronal de alimentación hacia adelante (feed-forward) y el modelo de optimización de nubes de partículas unificado (UPSO) para decidir los pesos iniciales a la red. El modelo UPSO-RNA utilizó 130 datos para entrenamiento y 60 datos para prueba; al aplicarlo a los datos experimentales reportados en la literatura mostraron buenos resultados. Este modelo tiene la limitante en la determinación de la estructura óptima de la red neuronal ya que se realizó de forma manual.

En 2012, Ahmadi et al [37], a partir de 5 muestras (una experimental y 4 de literatura) se propuso un híbrido de la optimización de partículas (PSO) y algoritmo de la red neuronal artificial (RNA) que combina de forma efectiva la capacidad de búsqueda local del método de retropropagación (BP) con la capacidad de búsqueda global del PSO. La idea del algoritmo PSO es que cada punto inicial de la red neuronal se selecciona por la unificación de la optimización de nube de partículas y la aptitud del PSO está determinada por una red neuronal. Se demostró que el modelo de PSO-RNA tiene un rendimiento predictivo superior al del modelo de red neuronal de retropropagación convencional. Sigue presentándose como inconveniente la determinación de la estructura óptima de la red neuronal, por lo que se hace de forma manual.

En 2013, Zendejboudia et al [38], unieron a las redes neuronales artificiales (RNA) con el algoritmo imperial competitivo (ICA) y la optimización de nube de partículas (PSO) para estimar la precipitación y deposición de asfaltenos con y sin inyección de CO₂. Se realizaron ensayos dinámicos para simular el proceso de producción (con 290 datos de literatura y 81 de pruebas experimentales) y experimentos estadísticos para el análisis de sensibilidad. Los resultados concluyeron que la temperatura y la caída de presión tienen la mayor influencia en la deposición de asfaltenos durante los ensayos dinámicos. Se estableció además que el ICA-RNA alcanza resultados más fiables en comparación con el PSO-RNA, la RNA convencional, y los modelos de escala.

En 2013, Hemmati-Sarapardeh et al [39], desarrollaron un modelo de precipitación de asfaltenos, basado en un sistema inteligente llamado máquinas vectoriales soportadas en mínimos cuadrados (least squares support vector machine-LSSVM), en ella utilizaron 157 datos correspondientes a 32 muestras de aceite de Irán. La información de entrada correspondió a información PVT, presión de burbuja, gravedad API, temperatura y análisis SARA. Con base a esto se predijo el porcentaje de precipitados de asfaltenos en peso (%wt) con resultados satisfactorios, además simula la tendencia física real de la precipitación respecto a la presión.

En 2014 Kamari et al [40], también plantean un modelo basado en LSSVM. Para ello utilizan 32 muestras de Oriente Medio obtenidas en la literatura para predecir las condiciones de precipitación de asfaltenos. Es una propuesta innovadora ya que para determinar la presión de inicio de precipitación de asfaltenos (presión onset) requieren pocos parámetros: condiciones de funcionamiento, composición y caracterización del aceite crudo. Los resultados indican que la estrategia propuesta ofrece resultados predictivos razonablemente satisfactorios. La limitante del modelo es la pequeña muestra de datos que utilizaron para entrenar la LSSVM. Este modelo es el que más se asemeja a la presente investigación ya que se busca determinar la presión onset involucrando pocos parámetros de entrada.

3.3 ANÁLISIS DE LOS PARÁMETROS DE ENTRADA

Con el fin de presentar un modelo eficiente para la determinación de las presiones onset de los asfaltenos, fue necesario investigar las variables que más influencia tienen en la generación de dicho fenómeno. Todos los estudios realizados hasta el momento coinciden que los cambios de presión, temperatura y composición influyen directamente en la precipitación de asfaltenos. Por lo tanto, la búsqueda de la información tuvo en cuenta los siguientes parámetros:

- Composición del crudo.
- Análisis SARA.
- Presión de burbuja a condiciones de yacimiento.
- Presión de inicio de precipitación de asfaltenos a diferentes temperaturas.

3.3.1 Recolección

Se realizó una consulta detallada en las bibliotecas virtuales especializadas sobre los avances en este tema para extraer la información básica necesaria para desarrollar el proyecto. Obtener la información base fue un reto importante, debido a que en muchos casos se encontraba de forma parcial. Algunas de las situaciones más comunes que se identificaron en la búsqueda fueron:

- Ausencia de datos de presión onset: Presentaban la presión onset a una sola temperatura; en otros casos no la registraban, sino que reportaban el porcentaje en peso de asfaltenos precipitados o el porcentaje de precipitados totales.
- Análisis SARA incompleto: Las investigaciones requerían solamente el porcentaje en peso de las resinas y los asfaltenos.

- Composición incompleta: No se presentaba información de la fracción plus; la sumatoria de las composiciones no alcanzaba el 100%.

En total se recolectaron 54 muestras provenientes de la literatura.

Como trabajo adicional se contactaron algunos ingenieros que trabajan con el tema y a partir de allí se obtuvo información de 4 muestras de crudos colombianos; lo cual permitió trabajar con 58 muestras de crudos.

3.3.2 Organización

La composición, se clasificó en 10 componentes, el i-C₄ y n-C₄ se agrupó en uno solo al igual que el i-C₅ y n-C₅. Todas las fracciones plus se ajustaron a C₇₊.

Componentes	N ₂	CO ₂	H ₂ S	C ₁	C ₂	C ₃	C ₄	C ₅	C ₆	C ₇₊
--------------------	----------------	-----------------	------------------	----------------	----------------	----------------	----------------	----------------	----------------	-----------------

Las unidades seleccionadas para representar cada variable fueron:

- Composición en porcentaje molar (%mol).
- Análisis SARA en porcentaje en peso (%wt).
- Presiones de burbuja y onset en Megapascuales (Mpa).
- Temperatura en grados Kelvin (K).

A partir del análisis de la información, se estableció como rango de temperatura 294 K - 423 K (69 °F - 302 °F) debido a que la mayoría de las muestras no contaban con datos a bajas temperaturas (<315 K). En la mayoría de los casos, la temperatura de los yacimientos a nivel mundial y en Colombia, está por encima de los 294 K.

3.3.3 Procesamiento

Al detallar que la mayoría de las muestras recolectadas tienen pocos datos de presiones de burbuja y onset, y que el éxito de las RNA depende de la cantidad de información con la que se construyen; fue necesario recurrir a procedimientos adicionales antes de ingresarlos a la red.

3.3.3.1 Presiones de burbuja


Como la presión de saturación está en función de la temperatura, fue necesario estimarla en todo el rango de 294 K a 423 K para el correcto funcionamiento de la red. Para lograrlo se empleó el software WinProp de la plataforma CMG [41] para generar la envolvente de

equilibrio líquido-vapor. Luego, se tomaron los valores de presión de saturación en el rango de temperatura establecido. Por ejemplo, en la tabla 2 se reportan los cuatro (4) valores experimentales de Ponset y Pb para la muestra 48, y la gráfica 3 presenta la envolvente de equilibrio líquido-vapor generada a través del CMG [42].

Tabla 2. Presiones onset y de burbuja experimentales para la muestra 48

Temperatura (K)	Ponset (Mpa)	P burbuja (Mpa)	P onset (Psia)	P burbuja (Psia)
372,15	47,26	22,21	6854,5	3221,3
377,15	45,42	22,64	6587,6	3283,7
383,15	44,26	22,59	6419,4	3276,4
389,15	42,92	22,68	6225,0	3289,5

Gráfica 3. Envolvente de equilibrio líquido-vapor para la muestra 48



En algunos casos, no fue posible realizar la simulación con CMG debido a que no se contó con la información completa para ser ingresada. Por tal motivo, se decidió utilizar el mismo procedimiento implementado con la presión onset el cual se detalla a continuación.


3.3.3.2 Presiones onset

Al igual que para la presión de saturación, el adecuado funcionamiento de la red exige que en el rango de temperatura establecido se cuente con la mayor cantidad de datos de

presión onset. Para conseguirlo, se utilizó la herramienta computacional Table Curve 2D V 5.01 [43].

Para cada muestra se realizó una gráfica; en el eje de las abscisas se ubicó la temperatura y en el eje de las ordenadas la presión onset, en el mejor de los casos, la gráfica contó con 5 puntos. La gráfica 4 presenta un ejemplo.

Gráfica 4. Información de entrada al software Table Curve de la Muestra 48




Una de las principales aplicaciones de Table Curve, es obtener ecuaciones que representan el comportamiento de una serie de datos. Para lograr el objetivo de obtener la curva de precipitación de asfaltenos en el rango de temperatura, se tuvieron en cuenta 2 criterios evaluativos:

- El coeficiente de correlación entre los datos reales y los simulados debe ser cercano a 1 ($R^2 \cong 1$).
- La forma de la gráfica debe corresponder con el comportamiento físico del fenómeno de precipitación de asfaltenos, es decir, a condiciones subsaturadas, con la disminución de la temperatura, es mayor la presión onset.

La gráfica 5 corresponde a los datos luego de ser procesados con la herramienta Table Curve.

Gráfica 5. Curva de presión onset generada por Table Curve para la muestra 48



3.3.4 Visualización

En las siguientes gráficas se presenta la información que se utilizó para la construcción, entrenamiento y simulación del modelo con redes neuronales artificiales.


La gráfica 6 corresponde a la composición química de las 58 muestras utilizadas, en porcentaje molar (%mol). Se evidencia la heterogeneidad de la información, principalmente en el contenido de CO₂, C₁ y C₇₊.

La gráfica 7 presenta al análisis SARA en un diagrama radial, para las 58 muestras. La principal característica es que las muestras están compuestas en mayor proporción por saturados y aromáticos.


En la gráfica 8 se visualiza las envolventes de saturación entre 294 K y 423 K. El intervalo de presión entre las muestras es amplio, lo cual permite que el modelo a construir tenga un mayor rango de aplicación.

Finalmente, la gráfica 9, muestra la presión onset, cuyo comportamiento es resultado de la diversidad en la composición, el análisis SARA y la envolvente de saturación.


Gráfica 6. Composición de las muestras utilizadas




Gráfica 7. Análisis SARA de las muestras utilizadas



Gráfica 8. Presión de saturación de las muestras utilizadas



Gráfica 9. Presión onset de las muestras utilizadas



3.3.5 Análisis

Para entender el comportamiento de la información, se realizó una evaluación de tendencias de las variables utilizadas. Es necesario aclarar que la composición y análisis SARA se consideran variables estáticas, debido a que son propiedades fijas e independientes; mientras que la presión de burbuja y la presión onset al depender de la temperatura, son variables dinámicas. Por tanto, encontrar una relación entre estas variables será un reto complejo.

A partir de la información de P_b , P_{onset} y T ; se escogieron tres (3) valores de temperaturas (310 K, 350 K y 400 K) con la intención de identificar las características, relaciones, tendencias y/o correlaciones entre las variables estáticas y dinámicas, a través del rango objeto de estudio.

El siguiente paso fue ordenar para cada una de las temperaturas seleccionadas, las presiones onset de menor a mayor. Luego, cada grupo de temperatura se dividió en 6 grupos según el orden de P_{onset} (ver tabla 3). Se observa que, aunque algunas muestras conservan la posición en los 3 escenarios, por ejemplo, la muestra 25 siempre apareció en la última posición del primer grupo. En la mayoría de los casos cambiaron de posición o incluso de grupo, como la muestra 52 que en los tres escenarios pasó por los grupos 4, 5 y 6.

Para cada muestra de los diferentes grupos se analizó la composición y el análisis SARA; como criterios evaluativos se calcularon el valor mínimo, el valor máximo, la diferencia entre mínimo-máximo y el promedio entre las muestras agrupadas. La tabla 4 presenta los resultados para el grupo 1 (310 K). Al revisar todos los casos no se encontró una relación directa entre los grupos de P_{onset} similares y las respectivas composiciones de las muestras. La única característica común es la similitud en la magnitud de los componentes C_2 - C_6 .

Tabla 3. Organización de las 58 muestras según el valor de presión onset a 310 K, 350 K y 400 K.

Temperatura	Grupo 1	Grupo 2	Grupo 3	Grupo 4	Grupo 5	Grupo 6
310 K	Muestra 32	Muestra 35	Muestra 33	Muestra 42	Muestra 4	Muestra 12
	Muestra 30	Muestra 27	Muestra 19	Muestra 17	Muestra 1	Muestra 58
	Muestra 24	Muestra 28	Muestra 36	Muestra 8	Muestra 43	Muestra 40
	Muestra 21	Muestra 18	Muestra 39	Muestra 5	Muestra 55	Muestra 16
	Muestra 23	Muestra 2	Muestra 56	Muestra 3	Muestra 41	Muestra 15
	Muestra 38	Muestra 26	Muestra 6	Muestra 45	Muestra 48	Muestra 51
	Muestra 37	Muestra 54	Muestra 34	Muestra 52	Muestra 13	Muestra 53
	Muestra 31	Muestra 20	Muestra 46	Muestra 57	Muestra 22	Muestra 11
	Muestra 9	Muestra 50	Muestra 7	Muestra 47	Muestra 10	
	Muestra 25	Muestra 29	Muestra 44	Muestra 49	Muestra 14	
350 K	Muestra 32	Muestra 38	Muestra 56	Muestra 34	Muestra 1	Muestra 58
	Muestra 30	Muestra 37	Muestra 33	Muestra 45	Muestra 41	Muestra 12
	Muestra 31	Muestra 54	Muestra 6	Muestra 49	Muestra 14	Muestra 10
	Muestra 50	Muestra 27	Muestra 7	Muestra 4	Muestra 47	Muestra 22
	Muestra 24	Muestra 28	Muestra 19	Muestra 17	Muestra 48	Muestra 11
	Muestra 21	Muestra 20	Muestra 39	Muestra 42	Muestra 52	Muestra 16
	Muestra 23	Muestra 26	Muestra 36	Muestra 55	Muestra 57	Muestra 53
	Muestra 29	Muestra 35	Muestra 8	Muestra 3	Muestra 40	Muestra 51
	Muestra 9	Muestra 2	Muestra 46	Muestra 5	Muestra 13	
	Muestra 25	Muestra 18	Muestra 44	Muestra 43	Muestra 15	
400 K	Muestra 31	Muestra 23	Muestra 4	Muestra 36	Muestra 40	Muestra 12
	Muestra 50	Muestra 27	Muestra 35	Muestra 19	Muestra 3	Muestra 52
	Muestra 32	Muestra 28	Muestra 18	Muestra 46	Muestra 47	Muestra 11
	Muestra 30	Muestra 38	Muestra 2	Muestra 34	Muestra 48	Muestra 10
	Muestra 29	Muestra 37	Muestra 8	Muestra 43	Muestra 15	Muestra 22
	Muestra 54	Muestra 20	Muestra 45	Muestra 44	Muestra 1	Muestra 16
	Muestra 24	Muestra 26	Muestra 55	Muestra 41	Muestra 42	Muestra 53
	Muestra 9	Muestra 56	Muestra 7	Muestra 17	Muestra 13	Muestra 51
	Muestra 21	Muestra 33	Muestra 6	Muestra 5	Muestra 58	
	Muestra 25	Muestra 49	Muestra 39	Muestra 14	Muestra 57	

Tabla 4. Análisis en composición y análisis SARA para muestras del grupo 1 a 310 K.

Muestra \ Comp.	9	21	23	24	25	30	31	32	37	38	Mín.	Máx.	Dif.	Prom.
N2	0,2	1,3	0,2	0,2	0,2	0,1	0,1	0,1	0,2	0,2	0,1	1,3	1,2	0,3
CO2	1,9	1,2	2,2	2,1	1,9	10,6	5,7	0,7	1,7	1,4	0,7	10,6	9,9	2,9
H2S	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,1	0,1	0,0	0,1	0,1	0,0
C1	33,6	36,0	36,8	35,0	33,5	11,3	11,9	12,5	27,9	33,0	11,3	36,8	25,5	27,1
C2	7,6	10,3	8,0	7,8	7,7	5,1	5,4	5,6	9,0	7,9	5,1	10,3	5,2	7,4
C3	6,7	8,4	6,8	6,8	7,3	6,2	6,5	6,9	8,6	6,2	6,2	8,6	2,5	7,1
C4	6,6	4,8	6,1	6,3	6,6	3,6	3,8	4,0	5,4	4,4	3,6	6,6	3,0	5,2
C5	5,2	2,3	4,6	4,8	5,2	8,0	8,4	8,9	4,0	3,7	2,3	8,9	6,5	5,5
C6	5,0	2,4	3,3	3,5	5,1	3,1	3,3	3,5	4,1	4,0	2,4	5,1	2,7	3,7
C7+	32,6	33,3	32,0	33,7	32,7	52,0	54,9	57,8	39,1	39,1	32,0	57,8	25,8	40,7
SAT	66,3	54,8	75,6	75,6	66,3	38,8	38,8	38,8	59,4	59,4	38,8	75,6	36,8	57,4
ARM	25,6	34,5	20,1	20,1	25,6	49,6	49,6	49,6	22,6	22,6	20,1	49,6	29,5	32,0
RES	5,4	7,4	4,1	4,1	5,4	7,7	7,7	7,7	14,0	14,0	4,1	14,0	9,8	7,7
ASF	2,8	3,3	0,2	0,2	2,8	3,9	3,9	3,9	1,7	1,7	0,2	3,9	3,7	2,4

Posteriormente se efectuaron varias relaciones entre las variables estudiadas con el objetivo de intentar establecer un criterio común que defina el comportamiento de los datos. La composición, el análisis SARA y la presión de burbuja se relacionaron para evaluar su incidencia en la presión onset. A continuación, se muestran las relaciones planteadas con P_b y P_{onset} a 310 K, 350 K y 400 K. En ninguno de los casos se encontró alguna relación convincente que establezca incidencia sobre la presión onset.

$$a = \left(\frac{RES}{ASF} \right) C_6 \quad (4)$$

$$c = \frac{C_{II}}{C_{7+}} \quad (7)$$

$$C_{II} = \frac{SAT + ASF}{RES + ARM} \quad (5)$$

$$d = \frac{C_2 - C_6}{C_{7+}} \quad (8)$$

$$b = \frac{C_{II}}{C_6} \quad (6)$$

$$e = \frac{C_1}{C_2 - C_6} \quad (9)$$

$$f = \frac{C_1}{C_{7+}} \quad (10)$$

$$g = \left(\frac{C_1}{C_2 - C_6} \right) \left(\frac{C_1}{C_{7+}} \right) \quad (11)$$

$$h = \left(\frac{C_1}{C_{7+}} \right) \div \left(\frac{C_1}{C_2 - C_6} \right) \quad (12)$$

$$i = Pb \left(\frac{C_1}{C_{7+}} \right) \quad (13)$$

$$j = \left(\frac{C_1}{C_{7+}} \right)^{Pb} \quad (14)$$

$$k = \left(\frac{C_1}{C_{7+}} \right) CO_2 \quad (15)$$

$$l = \left(\frac{Pb}{C_2 - C_6} \right) \quad (16)$$

$$m = \left(\frac{C_1}{C_{7+}} \right)^{\left(\frac{Pb}{C_2 - C_6} \right)} \quad (17)$$

$$n = Pb^{C_2 - C_6} \quad (18)$$


$$o = \left(\frac{Pb}{C_2 - C_6} \right) \quad (19)$$

$$p = \left(\frac{C_1 - C_4}{C_{7+}} \right) \quad (20)$$

$$q = \left(\frac{C_1 - C_4}{C_{7+}} \right) Pb \quad (21)$$


El siguiente escenario que se planteó para identificar alguna relación, fue el cociente entre la presión onset y la presión de burbuja. El procedimiento fue similar a los dos anteriores, es decir, para las 58 muestras, se tomaron las presiones a las 3 temperaturas y se analizaron los resultados individualmente. La gráfica 10 muestra los resultados a 310 K. En la gráfica se puede observar que algunas muestras presentan relaciones atípicas al comportamiento general, tal es el caso de las muestras 22, 29, 31, 33, 57 y 58.

Gráfica 10. Relación entre presión onset y presión de burbuja para las 58 muestras a 310 K.



Finalmente, se decidió tomar todos los datos de presión onset y presión de burbuja de las 58 muestras en el rango de temperatura establecido (294 K - 423 K) y se calculó el cociente entre Pons y Pb. La gráfica 11 exhibe esta relación para todas las muestras.

Gráfica 11. Relación entre presión onset y presión de burbuja para las 58 muestras



En la gráfica se puede observar que, aunque hay gran diversidad en los datos, un número importante de muestras tienen comportamiento paralelo, es decir, las pendientes son similares. Por lo tanto, se decidió calcular la derivada de estas curvas a través de la siguiente ecuación.

$$m_i = \frac{\partial \left(\frac{P_{ons}}{P_b} \right)_i}{\partial T} \quad (22)$$

Donde i corresponde a cada uno de los valores de temperatura en el rango establecido (294 K - 423 K). Se calculó el promedio de las pendientes para cada muestra con el fin de obtener un valor representativo que corresponda a las variables dinámicas que permita compararlas con las variables estáticas (composición y análisis SARA).

$$\bar{m}_k = \frac{\sum m_i}{n}, \quad (23)$$

Donde n es el número total de valores de temperatura evaluados y k corresponde a las muestras analizadas.

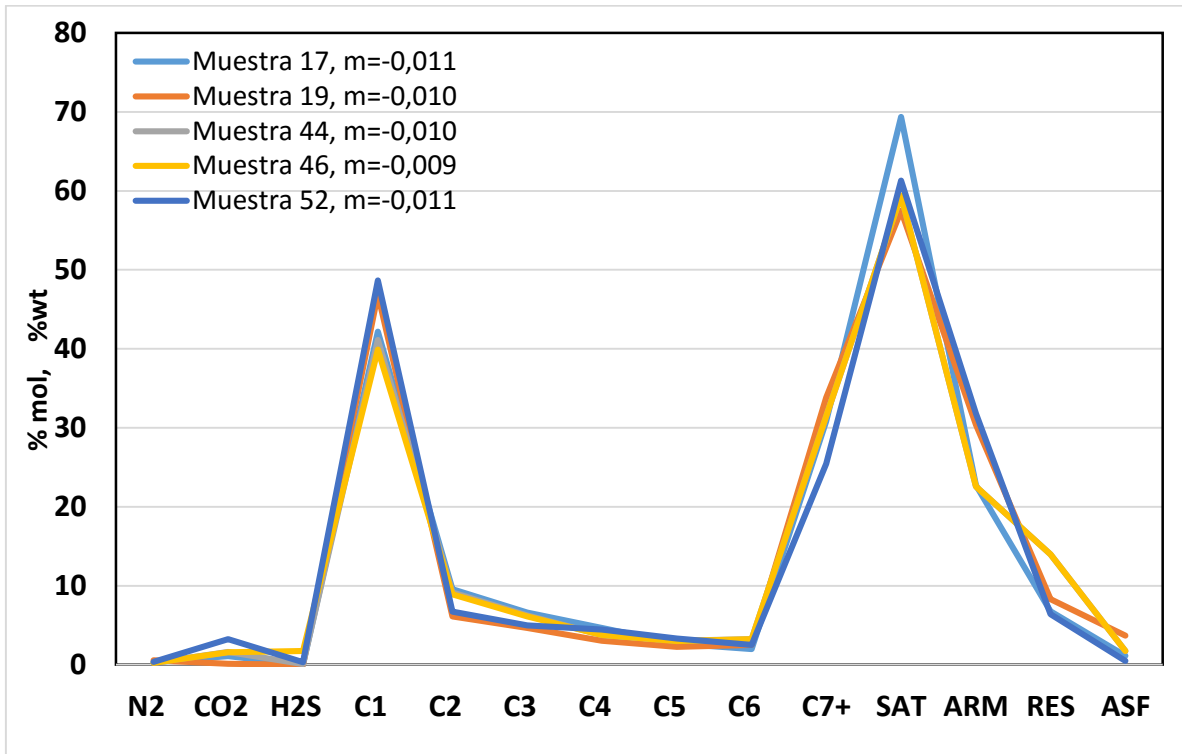
Luego se ordenaron las muestras según el promedio de pendientes calculadas de menor a mayor, la tabla 5 muestra los valores de pendientes promedios calculados.

Tabla 5. Pendientes promedio del cociente entre presión onset y presión de burbuja

Muestras	Derivada promedio
Muestra 1	-0,022
Muestra 2	-0,024
Muestra 3	-0,031
Muestra 4	-0,056
Muestra 5	-0,02
Muestra 6	-0,033
Muestra 7	-0,038
Muestra 8	-0,025
Muestra 9	-0,023
Muestra 10	-0,018
Muestra 11	-0,025
Muestra 12	-0,038
Muestra 13	-0,019
Muestra 14	-0,035
Muestra 15	-0,044
Muestra 16	-0,013
Muestra 17	-0,011
Muestra 18	-0,017
Muestra 19	-0,01
Muestra 20	-0,03
Muestra 21	-0,015
Muestra 22	-0,115
Muestra 23	-0,017
Muestra 24	-0,007
Muestra 25	-0,027
Muestra 26	-0,04
Muestra 27	-0,043
Muestra 28	-0,065
Muestra 29	-0,682
Muestra 30	-0,031
Muestra 31	-3,387
Muestra 32	-0,115
Muestra 33	-0,45
Muestra 34	-0,009
Muestra 35	-0,014
Muestra 36	-0,012
Muestra 37	-0,016
Muestra 38	-0,017
Muestra 39	-0,008
Muestra 40	-0,04
Muestra 41	-0,023
Muestra 42	-0,013
Muestra 43	-0,024
Muestra 44	-0,01
Muestra 45	-0,025
Muestra 46	-0,009
Muestra 47	-0,02
Muestra 48	-0,024
Muestra 49	-0,018
Muestra 50	-0,018
Muestra 51	-0,028
Muestra 52	-0,011
Muestra 53	-0,015
Muestra 54	-0,017
Muestra 55	-0,046
Muestra 56	-0,028
Muestra 57	-0,393
Muestra 58	-2,769

Se escogieron muestras con promedio de pendientes similares para graficar la composición de cada una de ellas y compararse entre sí. Salvo algunas excepciones, las pendientes similares corresponden a composiciones similares. La gráfica 12 muestra algunos casos de este comportamiento para las muestras 17, 19, 44, 46 y 52.

Gráfica 12. Composición y análisis SARA para muestras con pendientes entre -0.09 y -0.11



Este último análisis fue realizado con el cociente entre Ponset y Pb, a través de la siguiente ecuación

$$\bar{m}_k = \frac{\sum \left(\frac{P_{ons}}{P_b} \right)_i}{n}, \quad (24)$$

Donde:

- i corresponde al cociente en cada uno de los valores de temperatura establecidas (294 K - 423 K);
- n es el número total de valores de temperatura evaluados
- k corresponde a las muestras analizadas.

La tabla 6 muestra los valores de los cocientes promedios calculados para cada muestra.


Tabla 6. Promedio de cocientes entre presión onset y presión de burbuja.

Muestras	Cociente promedio
Muestra 1	2,221
Muestra 2	2,428
Muestra 3	2,844
Muestra 4	2,887
Muestra 5	1,986
Muestra 6	2,455
Muestra 7	2,455
Muestra 8	1,689
Muestra 9	1,821
Muestra 10	2,534
Muestra 11	2,467
Muestra 12	3,124
Muestra 13	2,402
Muestra 14	2,903
Muestra 15	3,328
Muestra 16	2,688
Muestra 17	1,925
Muestra 18	1,980
Muestra 19	1,544
Muestra 20	1,962
Muestra 21	1,273
Muestra 22	10,274
Muestra 23	1,582
Muestra 24	1,278
Muestra 25	1,871
Muestra 26	2,862
Muestra 27	2,721
Muestra 28	3,589

Muestra 29	9,953
Muestra 30	1,825
Muestra 31	23,450
Muestra 32	2,497
Muestra 33	6,628
Muestra 34	1,556
Muestra 35	1,725
Muestra 36	2,810
Muestra 37	1,608
Muestra 38	1,640
Muestra 39	1,377
Muestra 40	3,047
Muestra 41	2,455
Muestra 42	2,242
Muestra 43	2,527
Muestra 44	1,620
Muestra 45	2,132
Muestra 46	1,540
Muestra 47	2,277
Muestra 48	2,561
Muestra 49	1,214
Muestra 50	0,647
Muestra 51	3,936
Muestra 52	2,077
Muestra 53	2,787
Muestra 54	1,029
Muestra 55	2,662
Muestra 56	1,829
Muestra 57	9,147
Muestra 58	26,187

Se graficaron las composiciones de las muestras con valores similares de cocientes promedios, se detalló que cocientes promedios similares tienen composiciones similares. Esta relación fue incluso mejor que la que se encontró en el análisis anterior. La gráfica 13 muestra algunos casos de este comportamiento para las muestras 17, 18, 20 y 25 y 56.

Gráfica 13. Composición y análisis SARA para muestras con cocientes promedios entre 1.83 y 1.98



En conclusión, la principal relación identificada luego del análisis de los datos recolectados es el promedio de los cocientes entre presión onset y presión de burbuja, ya que agrupa composiciones similares.

4. DESARROLLO DEL MODELO NEUROSS-ASPH PARA PREDECIR LA PRESIÓN ONSET A PARTIR DE REDES NEURONALES

En este capítulo se expone el desarrollo del modelo para la determinación de la presión onset de asfaltenos en yacimientos de petróleo, cuyo soporte conceptual fue dado en capítulos anteriores. Las etapas llevadas a cabo para la construcción del modelo se presentan a continuación:



Figura 16. Etapas de desarrollo del modelo

La etapa 1 se desarrolló en el capítulo 3, sección “Análisis de los parámetros de entrada”. Las siguientes etapas se describen en el presente capítulo.

4.1 BASES DEL MODELO

El objetivo de la investigación es desarrollar una herramienta que prediga las presiones que forman la envolvente superior de precipitación de asfaltenos en un rango de temperatura entre 294.3 K y 423.2 K. Para lograr que este proyecto represente un aporte considerable al área de investigación, se establecieron tres criterios:

1. La información requerida para la ejecución del modelo debe estar fácilmente al alcance de los interesados.
2. La herramienta debe garantizar credibilidad en los resultados, por lo tanto, la base para la construcción debe ser robusta.
3. El rango de aplicabilidad sea amplio, lo cual asegura que funcione a diferentes condiciones.

El primer criterio se alcanzó satisfactoriamente debido a que la información de entrada para la puesta en marcha del modelo es la composición química del crudo (hasta C_{7+}), el análisis SARA y la envolvente de presión de burbuja. Para la construcción del modelo, se requirió adicionalmente las presiones onset a diferentes temperaturas, lo cual como se comentó en capítulos anteriores, fue un gran reto.

La utilización de las redes neuronales artificiales garantizó el cumplimiento del segundo criterio; ya que a partir del entrenamiento con la doble categorización diseñada se logró vincular las variables de entrada con el objetivo de la salida.

El tercer criterio se concreta gracias a la pluralidad de la información con la que se construyó el modelo; esto permite su ejecución para crudos con características diversas y aun así obtener resultados confiables.

La propuesta planteada se denomina “Neuross-Asph”; en ésta, las propiedades de una muestra de crudo como la composición química, la presión de burbuja y la presión onset permite determinar las presiones onset a partir del ingreso de datos que describen la composición química y las presiones de burbuja. En la Figura 17, se muestra la representación genérica del modelo.

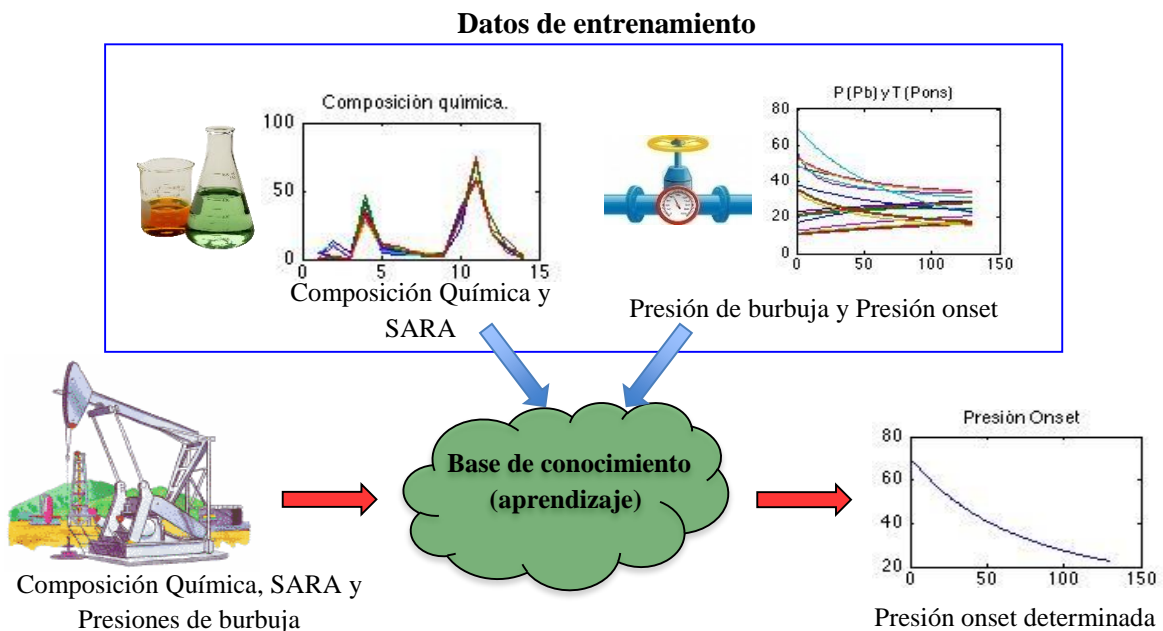


Figura 17. Representación genérica del modelo.

Básicamente, la forma como el modelo puede determinar presiones onset de nuevos pozos es a través de un sistema que “aprenda” la particularidad de las relaciones entre la composición química, análisis SARA, presiones de burbuja y presiones onset de pozos representativos de ejemplo, para de esta forma, obtener una base de conocimiento de las dinámicas del fenómeno. La base de conocimiento-aprendizaje es implementada con varias topologías de RNA gracias a las características de éstas para aprender, clasificar y generalizar conjuntos de datos cuya relación corresponde a la descripción o asociación

con propiedades de sistemas dinámicos, que, en este caso particular, es el comportamiento de la precipitación de asfaltos con el cambio de las propiedades termodinámicas. El entorno de desarrollo utilizado para la implementación del modelo fue la herramienta Matlab [44] que es un producto del catálogo ofrecido por la plataforma Mathworks.

4.2 FUNDAMENTOS DE LA RED DISEÑADA

Para entender el procedimiento de la construcción del modelo es necesario conocer primero qué tipo de redes fueron utilizadas y qué características tiene cada una de ellas.

4.2.1 Red Neuronal SOM (Self Organizing Map)

También conocida como los mapas auto-organizados de Kohonen, es un algoritmo evolutivo de aprendizaje competitivo no supervisado que facilita la búsqueda e identificación de estructuras (patrones o jerarquías entre los datos) dado su proceso de medir distancias entre los datos formando grupos o conglomerados (clústers) a través del encuentro de un representante o centroide por cada grupo.

La red auto-organizada debe descubrir rasgos comunes, regularidades, correlaciones o categorías en los datos de entrada, e incorporarlos a su estructura interna de conexiones. Se dice, por tanto, que las neuronas deben auto-organizarse en función de los estímulos (datos) procedentes del exterior.

Este tipo de red posee un aprendizaje no supervisado competitivo. El objetivo de este aprendizaje es categorizar los datos que se introducen en la red. Se clasifican valores similares en la misma categoría y, por tanto, deben activar la misma neurona de salida. Las clases o categorías deben ser creadas por la propia red a través de las correlaciones entre los datos de entrada.

Un modelo SOM está compuesto por dos capas de neuronas. La capa de entrada (formada por N neuronas, una por cada variable de entrada) se encarga de recibir y transmitir a la capa de salida la información procedente del exterior. La capa de salida (formada por M neuronas) es la encargada de procesar la información y formar el mapa de rasgos. Normalmente, las neuronas de la capa de salida se organizan en forma de mapa bidimensional como se muestra en la figura 18 [45].

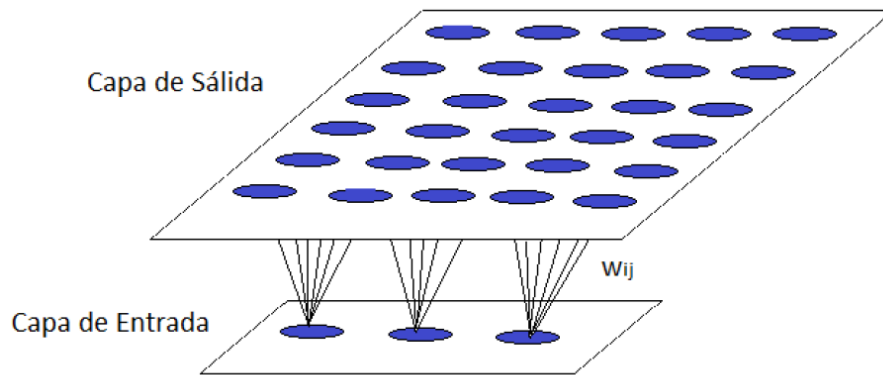


Figura 18. Estructura de la red SOM [46].

Aunque las neuronas de la capa de salida no están conectadas, cada una de éstas va a tener una influencia entre sus vecinas, lo cual se consigue a través de un proceso de competición entre las neuronas y de la aplicación de una función denominada de vecindad, que produce la topología o estructura del mapa. Es decir, las neuronas cercanas responden a patrones similares. Las topologías más frecuentes se presentan en la figura 19.




Figura 19. Topologías del SOM [47].

La función activación calcula el estado de actividad de una neurona; transformando la entrada global en un valor (estado) de activación, cuyo rango normalmente va de (0 a 1) o de (-1 a 1). En este caso, la función de activación es de tipo lineal y responde a la expresión:

$$f(x) = x \quad (25)$$

4.2.2 Red neuronal Feed-forward de contrapropagación (feed-forward backpropagation)

Las feedforward corresponden a la clase de RNA más estudiadas por el ámbito científico y las más utilizadas en los diversos campos de aplicación; se caracteriza por ser un conjunto de neuronas que reciben información multivariable, la procesan y dan una respuesta que puede ser multivariable también. En la arquitectura feedforward la topología del arreglo de neuronas y sus interconexiones hacen fluir la información de forma unidireccional para que nunca pueda pasar más de una vez a través de una neurona antes de generarse la respuesta de salida [48].




Figura 20. Esquema típico de red neuronal de tipo feedforward [48].

El trabajo de la red es ingresar los datos a través de las neuronas de la capa de entrada, y al pasar la información a la siguiente capa, llamada oculta, cada una de las neuronas receptoras recibe la suma ponderada de todas las entradas conectadas a ella. Pues cada conexión entre neuronas representa un peso de conexión. El aprendizaje involucra un ajuste de los pesos comparando la salida deseada con la respuesta de la red de manera que el error sea mínimo. La función que usualmente es utilizada para medir el error es la suma de los errores al cuadrado o su promedio.

La modificación en la intensidad entre las conexiones de las neuronas depende de la función de activación, para el caso de las feedforward la más común es la función sigmoideal que se representa a través de la siguiente ecuación:

$$g(x) = \frac{1}{1 + e^{-x}} \quad (26)$$

El algoritmo inicial para el aprendizaje de este tipo de redes es conocido bajo el nombre de propagación hacia atrás (Back-Propagation) que se fundamenta en una estrategia simple para reducir el error cuadrático medio, similar al método generalizado de regresión. El proceso de aprendizaje de la neurona es de tipo supervisado, es decir, la respuesta está controlada por un agente externo. La metodología de este tipo de red se clasifica como un método de regresión no lineal.

4.3 CONSTRUCCIÓN Y ENTRENAMIENTO DEL MODELO

El modelo completo del sistema “Neuross-Asph” se representa siguiendo una secuencia según las funciones que se realizan. En la Figura 21 se ilustra los principales procesos que intervienen en el diseño y entrenamiento del modelo. Estos procesos son los siguientes:

- Procesamiento de la información.
- Categorización según promedio Ponset/Pb.
- Subcategorización según composición.
- Asociación de presiones de burbuja con presiones onset.

Los detalles de diseño de los diferentes procesos que aparecen en la Figura 21, están fuertemente ligados a la representación matricial de las propiedades termodinámicas de las muestras en función de la categorización y la subcategorización llevadas a cabo. Teniendo presente las consideraciones anteriores, se pasará seguidamente a describir estos procesos.

Para efectos prácticos, durante el desarrollo del modelo al hacer referencia a “composición química”, se incluyen los datos correspondientes a la composición química del crudo y el análisis SARA.




Figura 21. Representación estructural del modelo

4.3.1 Procesamiento de la información.

Las propiedades termodinámicas, composición química, análisis SARA, presión de burbuja y presión onset están representadas por matrices de 1290 filas por nm columnas, donde nm es el número de muestras o pozos (58) y 1290 filas corresponde a la resolución de 0.1 grado kelvin (K) para el rango de temperatura establecido entre Tmín (294.3 K) y Tmáx (423.2 K).

Se trabaja haciendo un submuestreo por un factor de 10, debido a que las propiedades termodinámicas con resolución de 1 grado kelvin son representativas. Esto conduce a obtener una dimensión de 129xnm, lo cual evita que la red se sobrecargue. Por defecto, los valores del eje de las temperaturas están numeradas en forma ascendente, donde 1 corresponde a la Tmín y 129 a la Tmáx.

Al observar la Figura 21, el promedio entre Ponset/Pb genera un vector de 1xnm. Este vector es el usado para realizar la categorización de las propiedades termodinámicas de cada muestra. Como se concluyó en el capítulo 3, el cociente entre Ponset y Pb permite agrupar muestras de composiciones similares.

4.3.2 Categorización según promedio Ponset/Pb.

Es realizada por el primer SOM de la Figura 21. Los elementos del vector promedio entre Ponset/Pb son los que lo entrenan. De esta forma se logra que los elementos se “encierren” en grupos con promedios similares.

La topología de este SOM puede ser cuadrada, pero se prefiere que sea en línea FxC con F=1 debido a la dimensión de la matriz de entrenamiento que en la Figura 21 se ve que es 1xnm, lo importante es que la cantidad de neuronas generarían potencialmente igual número de grupos con promedios similares. Este SOM genera el vector de categoría de dimensión 1xnm, el cual es usado para “mapear” la composición química, el análisis SARA, la presión de burbuja y la presión onset. La figura 22 corresponde a la topología del SOM antes y después del entrenamiento según el promedio entre Ponset/Pb.

En la Figura 21 también se observa que las categorías para las propiedades termodinámicas están representadas por un color según la categoría (amarillo, azul o rojo); como la n-ésima categoría tiene Cn columnas, entonces se cumple que por cada propiedad termodinámica el número de todas las columnas por cada matriz de grupo es nm ($C_1+C_2+\dots+C_n=nm$).




Figura 22. Topología del SOM que categoriza el promedio entre Pons/Pb. (a) Antes del entrenamiento. (b) Después del entrenamiento

4.3.3 Subcategorización según composición

Es realizada por los SOMs de topología rectangular de dimensión SFxSC. Observar que hay un SOM por cada categoría generada según el promedio de Ponset/Pb, por consiguiente, la topología es cuadrada, debido a la dimensión de las respectivas matrices de entrenamiento (dimensión 129xCn). Estos SOMs categorizan los grupos de propiedades termodinámicas en subgrupos que están en función de los clústers obtenidos según la composición química. Por defecto, los datos de composición química están numerados como lo referencia la tabla 7.

Tabla 7. Nomenclatura de las composiciones químicas dentro del modelo

Componente	N ₂	CO ₂	H ₂ S	C ₁	C ₂	C ₃	C ₄	C ₅	C ₆	C ₇₊	SAT	ARM	RES	ASF
Representación	1	2	3	4	5	6	7	8	9	10	11	12	13	14

Cada SOM genera un vector de subcategoría de dimensión 1xCn, los cuales son usados para “mapear” los grupos de composición química, presión de burbuja y presión onset en función de la composición química.

En la Figura 21 también se observa que las subcategorías para las propiedades termodinámicas están representadas por el mismo color usado en la categoría del primer

SOM. Por lo tanto, el número de columnas de todas las matrices de subcategoría, es igual al número de columnas de la categoría asociada. Por ejemplo, $S1+S2+\dots+S_m=C1$.

La figura 23 corresponde a la topología del SOM antes y después del entrenamiento según la subcategorización por composición.

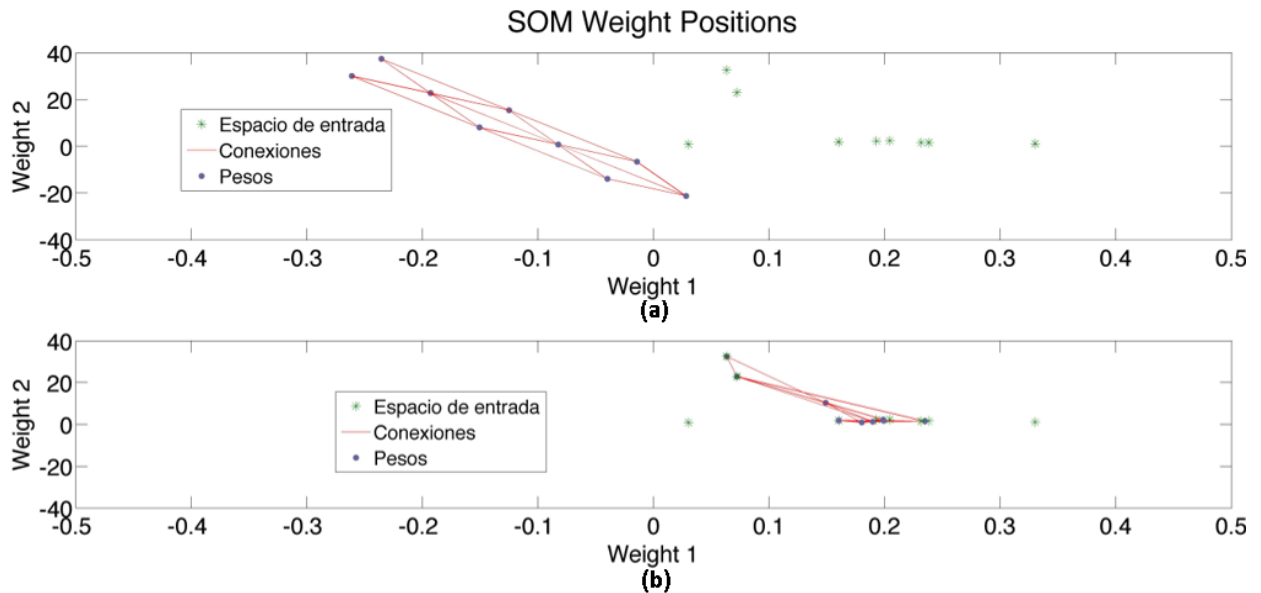


Figura 23. Topología del SOM que subcategoriza por composición. (a) Antes del entrenamiento. (b) Después del entrenamiento

4.3.4 Asociación de presiones de burbuja con presiones onset.

Es realizado por las redes feedforward, una asociada a cada subcategoría. Tienen como objetivo “aprender” la relación entre presiones de burbuja y presiones onset según las subcategorizaciones previas, en donde P_b y P_{onset} comparten composiciones químicas y promedios P_{onset}/P_b similares.

La topología de cada FF es de 10 neuronas, con 129 entradas y 129 salidas debido a la dimensión de las matrices de subcategoría correspondientes a P_b (que actúan como ejemplos de entrenamiento) y a la dimensión de las matrices de subcategoría correspondientes a P_{onset} (que actúan como objetivos o targets).

4.4 SIMULACIÓN DEL MODELO

Posterior al entrenamiento, la simulación consiste en verificar el funcionamiento del modelo construido, en el que se introduce una nueva muestra (con todas sus propiedades), correspondiente al espacio de entrada para obtener la respuesta del modelo, es decir, predecir la envolvente superior de precipitación de asfaltenos.

El proceso de simulación tiene varias etapas, las cuales están relacionadas con la construcción del modelo desde el punto de vista de la categorización y subcategorización. Recordar que, en sí, el modelo plantea un SOM para categorizar a partir de la relación del promedio entre Ponset/Pb, y varios SOMs (de segundo nivel), diseñados para subcategorizar las primeras categorías en función de la composición. Por esta razón, la muestra que se ingresa, se acopla y simula en cada uno de estos SOMs, los cuales a través de un proceso de competición generan un SOM “ganador” que presenta el más alto grado de pertenencia o relación SOM-Muestra ingresada.

El SOM ganador se obtiene usando un algoritmo de prioridades, que consiste en determinar la neurona más fuerte en cada SOM en función de las categorías de primer nivel. Es decir, si la composición de una nueva muestra está muy cercana a una categoría en particular, habrá una alta probabilidad de activar la neurona fuerte del SOM asociado a esta categoría.

El SOM ganador finalmente, a través de la neurona fuerte y sus vecinas, se direccionarán a la red FF correspondiente, la cual será simulada con la composición y las presiones de burbujas asociadas, y las presiones de burbuja de la nueva muestra para predecir las presiones onset.

La simulación se ilustra en la figura 24. Los procesos llevados a cabo en esta etapa son:

- Acoplamiento de la composición química.
- Acoplamiento de la relación Ponset/Pb.
- Selección de la red feed-forward
- Predicción de la presión onset.

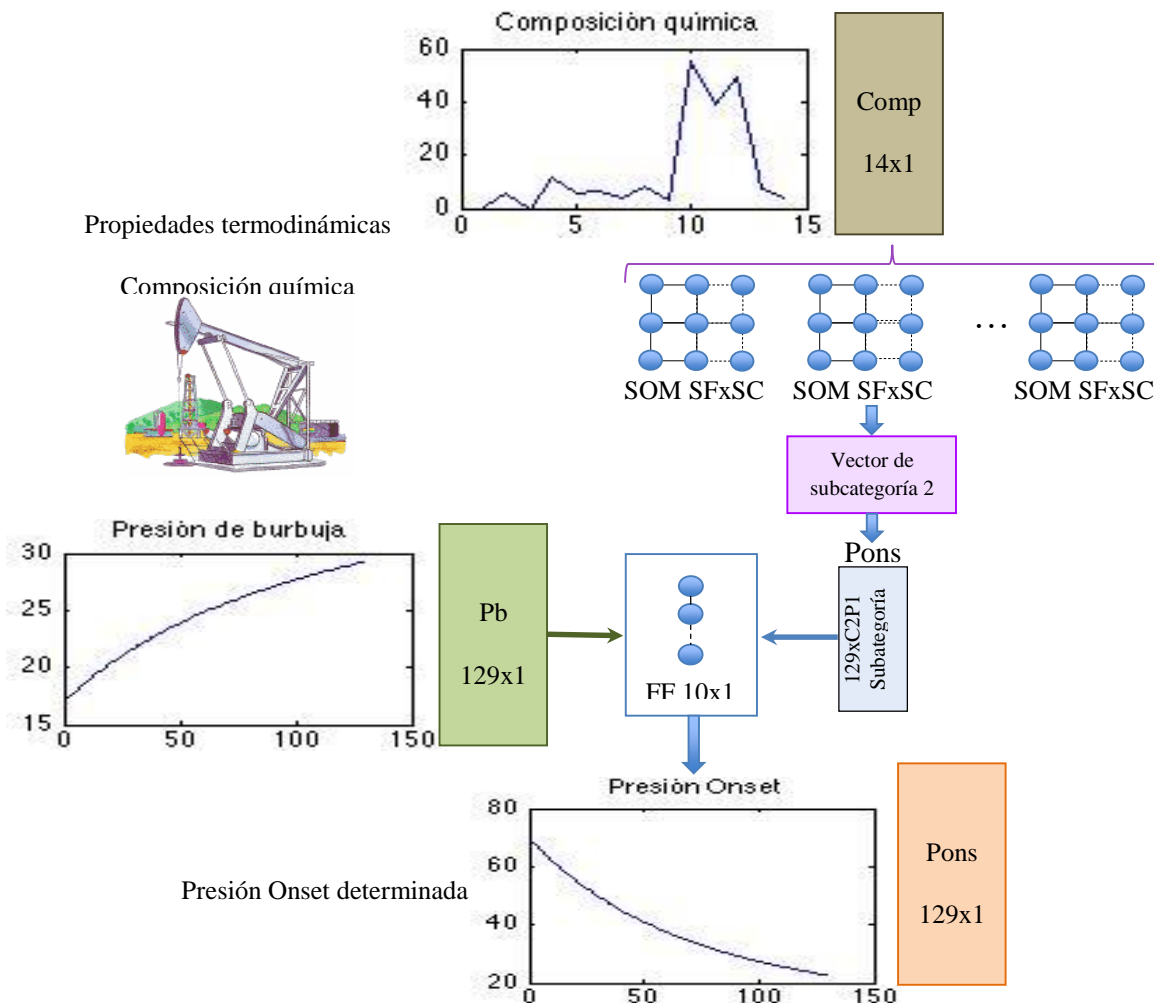



Figura 24. Esquema del proceso de simulación.

4.4.1 Acoplamiento de la composición química.

Se ingresa la composición de la muestra a la que se desea predecir el comportamiento de la precipitación de asfaltenos (presión onset). El vector de entrada para la composición química es de 14x1, acorde a los vectores que se utilizaron en el entrenamiento. Para ubicar la categoría a la que corresponde la composición de entrada, se utiliza los SOMs entrenados.

La composición química ingresada, se evalúa en todos los SOMs, y éstos compiten entre sí, ordenando las neuronas según el acoplamiento entre ellas, de modo que al final se obtienen los SOMs con su respectiva neurona ganadora asociada a la composición de entrada.

Gráfica 14. Acoplamiento en función de la composición química



4.4.2 Acoplamiento de la relación Ponset/Pb.

Durante la fase de entrenamiento, la relación Ponset/Pb correspondía a la categorización inicial, sin embargo, en la simulación no es posible hacer un acoplamiento directo a esta relación debido a que no se cuenta con la presión onset, pues es lo que se pretende predecir. Ésta etapa se encuentra implícita en el SOM de composición química que es resultado del SOM inicial (relación Pons/Pb).


4.4.3 Selección de la red feed-forward

Luego del acople de la nueva composición con la subcategorización dada por el SOM asociado a la composición de entrada a través del vector de subcategoría (ver Figura 24), se selecciona la red FF entrenada con las subcategorías correspondientes direccionada por la neurona más fuerte y sus vecinas.

4.4.4 Predicción de la presión onset.

Se realiza en dos etapas, en la primera se lleva a cabo la asociación entre la presión onset (que es respuesta del SOM de composición química y cuya dimensión es 129x1) y la presión de burbuja de la muestra evaluada que se ingresa en esta etapa la cual debe ser procesada previamente para que su dimensión sea 129x1 (ver 3.3.3.1). La segunda etapa corresponde a la predicción de las presiones onset, a través de la red feed-forward entrenada.

Gráfica 15. Proceso de predicción de la presión onset (a) a la entrada del FF, (b) a la salida del FF.



4.5 RESTRICCIONES DEL MODELO


Las limitaciones del modelo propuesto están en función de los datos empleados en su construcción. Para garantizar mayor confianza en los resultados se recomienda que los datos de entrada estén en los rangos que se presentan en la tabla 8.

Para lograr un mejor rendimiento del modelo es necesario que las presiones de burbuja ingresadas tengan una dimensión de 129x1, es decir, para el rango de temperatura establecido debe haber datos de presión cada 1 K. Además, para tener confianza de los resultados obtenidos con el modelo, se recomienda que los datos de presión de burbuja a ingresar se encuentren dentro de la zona formada por los datos utilizados en su construcción (Ver Gráfica 16).

Tabla 8. Rangos de las variables utilizadas para la creación del Modelo Neuross-Asph

COMPONENTE	RANGO	
	Mínimo	Máximo
N ₂	0,01	5,08
CO ₂	0,01	32,58
H ₂ S	0,00	8,26
C ₁	8,78	57,41
C ₂	3,75	11,02
C ₃	2,95	9,59
C ₄	1,10	6,58
C ₅	1,92	8,85
C ₆	1,76	8,04
C ₇₊	16,52	57,77
SAT	26,88	75,56
ARM	11,60	67,99
RES	2,50	18,80
ASF	0,17	16,30

Gráfica 16. Región formada por las presiones de burbuja utilizadas en la creación del Modelo Neuross-Asph



5. RESULTADOS Y DISCUSIONES

5.1 VALIDACIÓN DEL MODELO CON LA INFORMACIÓN DE ENTRADA.

Para evaluar los resultados del modelo propuesto, se calculó para cada caso, el error absoluto promedio, AAE (average absolute error) que consiste en el promedio de la diferencia absoluta calculada entre el valor real y el valor calculado.

$$ARE = \frac{1}{n} \sum_{i=1}^n |\Delta x_i| \times 100 \quad (27)$$

Para comparar resultados puntuales, se estimó el porcentaje de error.

$$\%error = \left[\frac{x_{experimental} - x_{calculada}}{x_{experimental}} \right] \times 100 \quad (28)$$

5.1.1 Validación del modelo con la información de entrada.

Como se citó en el capítulo 4, la RNA fue entrenada con 58 muestras. Con el fin de verificar los resultados, se compararon los puntos experimentales de cada una de las muestras con los datos de salida del modelo propuesto. La tabla 9 presenta esa evaluación

Tabla 9. Comparación de los datos experimentales y los predichos con el modelo Neuross-Asph

Muestra	Temperatura (K)	Presion Onset Experimental (Mpa)	Presión Onset Calculada (Mpa)	%Error	AAE
1	300	73,27	73,27	0	0
2	300	41,40	41,40	0	0
3	300	69,41	69,41	0	0
4	300	75,97	75,97	0	0
5	300	64,10	64,10	0	0
6	300	57,64	57,64	0	0
7	300	58,20	58,20	0	0

Continuación...

Muestra	Temperatura (K)	Presion Onset Experimental (Mpa)	Presión Onset Calculada (Mpa)	%Error	AAE
8	300	64,57	64,57	0	0
9	300	38,17	38,17	0	0
10	300	83,76	83,76	0	0
11	334	84,37	84,37	0	0
12	334	69,53	69,53	0	0
13	334	65,98	65,98	0	0
14	334	61,99	61,99	0	0
15	334	71,14	71,14	0	0
16	334	80,78	80,78	0	0
17	334	45,51	45,51	0	0
18	334	31,91	31,91	0	0
19	334	36,77	36,77	0	0
20	334	29,66	29,66	0	0
21	358	18,35	18,35	0	0
22	358	68,65	68,65	0	0
23	358	19,52	19,52	0	0
24	358	15,04	15,04	0	0
25	358	20,78	20,78	0	0
26	358	25,45	25,45	0	0
27	358	22,00	22,00	0	0
28	358	22,00	22,00	0	0
29	358	18,65	18,65	0	0
30	358	8,67	8,67	0	0
31	379	4,77	4,77	0	0
32	379	5,28	5,28	0	0
33	379	25,83	25,83	0	0
34	379	36,76	36,76	0	0
35	379	26,42	26,42	0	0
36	379	34,00	34,00	0	0
37	379	20,28	20,28	0	0
38	379	19,59	19,59	0	0
39	379	33,38	33,38	0	0

Continuación...


Muestra	Temperatura (K)	Presion Onset Experimental (Mpa)	Presión Onset Calculada (Mpa)	%Error	AAE
40	379	44,50	44,50	0	0
41	397	36,75	36,75	0	0
42	397	42,67	42,67	0	0
43	397	36,06	36,06	0	0
44	397	35,74	35,74	0	0
45	397	28,19	28,19	0	0
46	397	35,05	35,05	0	0
47	397	40,72	40,72	0	0
48	397	41,19	41,19	0	0
49	397	24,97	24,97	0	0
50	397	3,36	3,36	0	0
51	413	83,11	83,11	0	0
52	413	47,33	47,33	0	0
53	413	77,65	77,65	0	0
54	413	12,33	12,33	0	0
55	413	25,22	25,22	0	0
56	413	20,52	20,52	0	0
57	413	43,59	43,59	0	0
58	413	40,89	40,89	0	0

Se observa que el modelo Neuross-Asph funciona perfectamente con la información que alimentó a la red. Estos resultados permiten deducir que la categorización, entrenamiento y simulación fueron adecuadas. La categorización con el SOM en dos etapas fue conveniente debido a que permitió que las neuronas creadas agruparan muestras que relacionan correctamente la presión de burbuja, la presión onset, la composición y el análisis SARA.

5.1.2 Validación del modelo con una muestra nueva.

Para verificar los resultados del modelo durante la etapa de simulación, se decidió entrenar la red con 50 muestras y simularlo con las muestras restantes. Es válido aclarar que estas 8 muestras al no ser ingresadas durante la etapa de entrenamiento, los resultados corresponderán a las predicciones. Las gráficas 17 y 18 presentan la salida de la red para 2 muestras simuladas las cuales fueron seleccionadas aleatoriamente de las ocho muestras.

Gráfica 17. Predicción de la red para la muestra 14



Como se aprecia en las gráficas, la predicción con el modelo Neuross-Asph es satisfactoria ya que la mayoría de los puntos predichos están muy cercanos a los valores experimentales y el comportamiento de la gráfica corresponde con el fenómeno físico en el que con la disminución de la temperatura la presión aumenta. La tabla 10 presenta los resultados de algunas Ponsets predichas a diferentes temperaturas.

Gráfica 18. Predicción de la red para la muestra 40




Tabla 10. Rangos de las variables utilizadas para la creación del Modelo Neuross-Asph

Muestra	Temp. (K)	Ponset exp. (Mpa)	Ponset Predicha (Mpa)	% Error
14	301,3	90,20	91,53	1,5
	309,3	81,89	82,42	0,6
	319,3	72,85	72,86	0,0
	330,3	64,47	68,45	6,2
	346,3	54,81	52,04	5,1
	365,3	46,64	49,23	5,6
	400,3	38,96	38,73	0,6
40	301,3	100,93	102,82	1,9
	309,3	91,97	93,87	2,1
	319,3	81,90	83,80	2,3
	330,3	72,20	74,09	2,6
	346,3	60,48	62,38	3,1
	365,3	49,96	51,86	3,8
	400,3	39,21	41,11	4,8

Los resultados muestran que el modelo Neuross-Asph presenta desviaciones inferiores al 6.2 %. El AAE para las muestras 14 y 40 fue de 2,4 y 1,9 respectivamente. Es válido aclarar que los resultados no son perfectos, pero representan una aproximación desatacada.

El modelo puede generar resultados mucho más precisos si las RNA se entrenan con un mayor número de muestras, se descarta incertidumbre en los datos experimentales y/o si se logra establecer otro tipo de relaciones a las planteadas en la presente investigación.

5.2 COMPARATIVO CON OTROS MODELOS NUMÉRICOS DISPONIBLES

Como se mencionó en el capítulo 1, existen al menos 7 tipos de modelos disponibles que buscan predecir la presión onset; modelo termodinámico coloidal, modelo de solución polimérica, modelo de solución regular, modelo de sólido, modelo de PC-Saft, modelo de micelización y Modelo numérico.

Para verificar la eficiencia del modelo propuesto se decidió comparar los resultados con dos modelos numéricos propuestos. Ambos modelos están basados en ecuaciones empíricas y su aplicación es sencilla; no se logró comparar con un modelo de RNA debido a que las investigaciones disponibles en la literatura indican los principios de diseño de la red y los resultados obtenidos, mas no el procedimiento de la aplicación. Los demás modelos a pesar de su fuerte fundamentación teórica, requieren mayor información de entrada a la disponible en esta investigación. Incluso muchos de los parámetros de entrada son incertidumbres como es el caso de los modelos de EOS que requiere un valor de peso molecular de los asfaltenos, que puede estar en un amplio rango de valores (500 a 10000 gr/grmol) y depende de la técnica empleada para su obtención. Las EoS son los modelos más utilizados para los cálculos de la presión onset, sin embargo, para llevar a cabo su estimación, la mayoría de los modelos requieren un dato experimental de presión onset, además de afinar o ajustar datos PVT experimentales del fluido del yacimiento, el fraccionamiento y la caracterización de la fracción pesada.

5.2.1 Modelo de Fahim

Fahim desarrolló en 2007 [49] un modelo para estimar la envolvente de precipitación de asfaltenos basado en ecuaciones empíricas, con 33 muestras de crudo principalmente de oriente medio. La ecuación propuesta para calcular la presión onset superior es:

$$\begin{aligned}
P_U^{ONS} = & -4.3243 * H_2S + 2.6047 * N_2 + 0.6890 * CO_2 + 0.6503 * C_1 + 0.9273 * C_2 \\
& + 0.0086 * C_3 - 3.981 * C_4 - 0.5878 * C_5 + 0.1817 * C_6 - 0.0811 * C_{7+} \\
& - 0.1305 * MWC_{7+} + 210.89 * \gamma C_{7+} + 0.908 * Asph - 0.2003 * Resin \\
& - 0.8988 * T + 0.001 * T^2 + 12.4148 * LN(T) \quad (29)
\end{aligned}$$

Donde:

- $H_2S, N_2, CO_2, C_1, C_2, C_3, C_4, C_5, C_6, C_{7+}$; Corresponden a los porcentajes molares de cada muestra (%mol).
- MWC_{7+} ; Peso molecular de la fracción pesada (gr/grmol).
- γC_{7+} ; Gravedad específica de la fracción pesada.
- T ; Corresponde a la temperatura a la que se va a evaluar (K).

Debido a que el modelo de Fahim requiere como datos de entrada el peso molecular y la gravedad específica del C_{7+} , no fue posible aplicarlo a las 58 muestras con que se creó el modelo Neuross-Asph debido a que solo 17 muestras registraban esa información. La tabla 11 muestra el comparativo entre los dos modelos. Se observa que el modelo de Fahim presenta una alta desviación entre el valor calculado y el experimental, porcentaje de error alcanza incluso del 70% mientras que con el modelo propuesto el error es de 0%.

Tabla 11. Comparación de presiones onset calculadas con los modelos de Fahim y Neuross-Asph

Muestra	Temperatura (K)	Presión onset experimental (Mpa)	Presión onset calculada		% Error	
			Modelo Fahim	Modelo Neuross-Asph	Modelo Fahim	Modelo Neuross-Asph
Muestra 2	320	34,98	49,65	34,98	41,92	0
Muestra 4	320	59,15	61,40	59,15	3,80	0
Muestra 6	340	33,01	14,10	33,01	57,28	0
Muestra 7	320	40,79	68,09	40,79	66,90	0
Muestra 9	340	23,95	7,08	23,95	70,41	0
Muestra 10	400	53,54	52,81	53,54	1,37	0
Muestra 11	400	52,36	47,55	52,36	9,19	0
Muestra 17	380	38,26	20,65	38,26	46,02	0
Muestra 32	340	6,38	5,77	6,38	9,60	0
Muestra 33	340	33,91	41,96	33,91	23,72	0
Muestra 47	360	50,43	64,69	50,43	28,29	0
Muestra 48	380	45,00	43,87	45,00	2,50	0

Continuación....

Muestra	Temperatura (K)	Presión onset experimental (Mpa)	Presión onset calculada	% Error	Muestra	Temperatura (K)
Muestra 49	360	37,03	35,21	37,03	4,92	0
Muestra 50	320	31,21	35,69	31,21	14,35	0
Muestra 52	380	50,34	50,30	50,34	0,08	0
Muestra 56	340	33,31	45,22	33,31	35,78	0
Muestra 57	320	62,39	63,57	62,39	1,90	0

5.2.2 Modelo de regresión de mínimos cuadrados modificado.

Del Río, Ramírez y Lira-Galeana [50] plantearon en 2008 ecuaciones para predecir la presión onset de precipitación de fluidos en yacimientos asfálticos basados en un método de regresión de mínimos cuadrados. A continuación, se detalla la ecuación propuesta junto con las constantes obtenidas a partir de 11 muestras de petróleo de México (crudo Maya).

$$P^{upp}(T) = \frac{T}{f^{upp}(C_{upp}) + B^{upp}T} \quad (30)$$

Donde:

- $P^{upp}(T)$; Corresponde a la presión onset (Mpa).
- T ; Corresponde a la temperatura a la que se va a evaluar (K).
- B^{upp} ; Es una constante universal establecida, en este caso 0,047408719
- $f^{upp}(C_{upp})$; Constante particular para cada muestra.

$f^{upp}(C_{upp})$ se calcula a través de:

$$f^{upp}(C_{upp}) = f_{H_2S}^{upp} x_{H_2S} + f_{N_2}^{upp} x_{N_2} + f_{CO_2}^{upp} x_{CO_2} + f_{C_{1-4}}^{upp} x_{C_{1-4}} + f_{sat}^{upp} x_{sat} + f_{arm}^{upp} x_{arm} + f_{res}^{upp} x_{res} + f_{asf}^{upp} x_{asf} \quad (31)$$

Donde:

- $x_{H_2S}, x_{N_2}, x_{CO_2}, x_{C_{1-4}}$; son los porcentajes molares de cada componente (%mol).
- $x_{arm}, x_{arm}, x_{res}, x_{asf}$; son los porcentajes en peso del análisis SARA (%wt).

- $f_{H_2S}^{upp}, f_{N_2}^{upp}, f_{CO_2}^{upp}, f_{C_{1-4}}^{upp}, f_{sat}^{upp}, f_{arm}^{upp}, f_{res}^{upp}, f_{asf}^{upp}$; Son constantes universales de cada componente que se detalla a continuación,

Constante	Valor
$f_{H_2S}^{upp}$	-3,364315662
$f_{N_2}^{upp}$	0,590476022
$f_{CO_2}^{upp}$	-3,337934227
$f_{C_{1-4}}^{upp}$	-1,125509198
f_{sat}^{upp}	1,325877421
f_{arm}^{upp}	-0,515158363
f_{res}^{upp}	0,576495619
f_{asf}^{upp}	2,118534736

Al aplicar este modelo a las 58 muestras, se observa que los errores son muy altos. Estos resultados afirman que la utilización de pocas muestras (11) para la construcción de las ecuaciones limita considerablemente el rango de aplicación de las mismas. Además, intentar caracterizar la precipitación de asfaltenos de forma lineal, es un desacierto, ya que no representa el comportamiento físico del fenómeno; pues este es variable, dinámico, y depende de muchos factores. La tabla 12 presenta los resultados.

Tabla 12. Comparación de presiones onset calculadas con los modelos de mínimos cuadrados y Neuross-Asph

Muestra	Temperatura (K)	Presión onset experimental (Mpa)	F upp	Presión onset calculada		% Error	
				Modelo mín. cuadrados	Modelo Neuross-Asph	Modelo mín. cuadrados	Modelo Neuross-Asph
1	320	62,07	-76,06784	-5,25	62,07	108,47	0
3	400	39,85	-15,51511	116,00	39,85	191,11	0
5	320	55,42	-52,36668	-8,60	55,42	115,52	0
8	320	51,54	-28,66553	-23,71	51,54	146,01	0
12	400	46,91	8,31406	14,66	46,91	68,74	0
13	400	43,31	8,19091	14,73	43,31	65,99	0
14	400	38,99	-4,79269	28,23	38,99	27,61	0
15	380	46,06	-2,41143	24,35	46,06	47,13	0
16	380	66,64	-3,39012	25,98	66,64	61,01	0
18	400	25,82	15,61636	11,57	25,82	55,19	0

Continuación...


Muestra	Temperatura (K)	Presión onset experimental (Mpa)	F upp	Presión onset calculada		% Error	
				Modelo mín. cuadrados	Modelo Neuross-Asph	Modelo mín. cuadrados	Modelo Neuross-Asph
19	360	34,92	4,72268	16,52	34,92	52,68	0
20	400	20,63	18,05046	10,81	20,63	47,62	0
21	320	24,06	-4,00031	28,65	24,06	19,07	0
22	320	76,49	-37,45347	-14,36	76,49	118,77	0
23	400	16,64	20,48456	10,14	16,64	39,05	0
24	380	14,49	22,91866	9,28	14,49	35,91	0
25	400	16,21	15,35674	11,65	16,21	28,11	0
31	320	26,3	-11,42142	85,35	26,3	224,58	0
34	400	35,25	-7,26471	34,19	35,25	2,99	0
35	320	33,01	-7,00929	39,21	33,01	18,77	0
36	400	32,49	-9,50499	42,29	32,49	30,17	0
38	400	18,38	16,00349	11,44	18,38	37,77	0
39	400	32,17	16,71889	11,21	32,17	65,15	0
40	400	39,26	4,41879	17,11	39,26	56,43	0
41	400	35,97	11,13461	13,29	35,97	63,06	0
44	400	35,58	5,40598	16,41	35,58	53,87	0
45	400	27,6	5,2524	16,52	27,6	40,16	0
46	400	34,89	1,77987	19,28	34,89	44,74	0

5.3 CURVA DE PRECIPITADOS EN PESO A PARTIR DE LA INFORMACIÓN GENERADA POR EL MODELO

Una de las formas de complementar el aporte de esta investigación es cuantificar la cantidad de asfaltenos precipitados, con la caída de la presión, para así determinar el grado de afectación capaz de generar en el yacimiento, tuberías o líneas de flujo. Con el modelo Neuross-Asph se predice las presiones que conforman la envolvente superior de precipitación de asfaltenos; generalmente los softwares diseñados para determinar la curva de asfaltenos precipitados en %wt requieren el ingreso de la presión de inicio de precipitación de asfaltenos -es decir, la onset- a condiciones de yacimiento.


A continuación, se ilustra con un ejemplo esta ventaja del modelo desarrollado a través de los softwares SMAP y Winprop.

Gráfica 19. Envoltente de precipitación de asfaltenos (APE) generada por el software SMAP para un punto experimental de la muestra 48

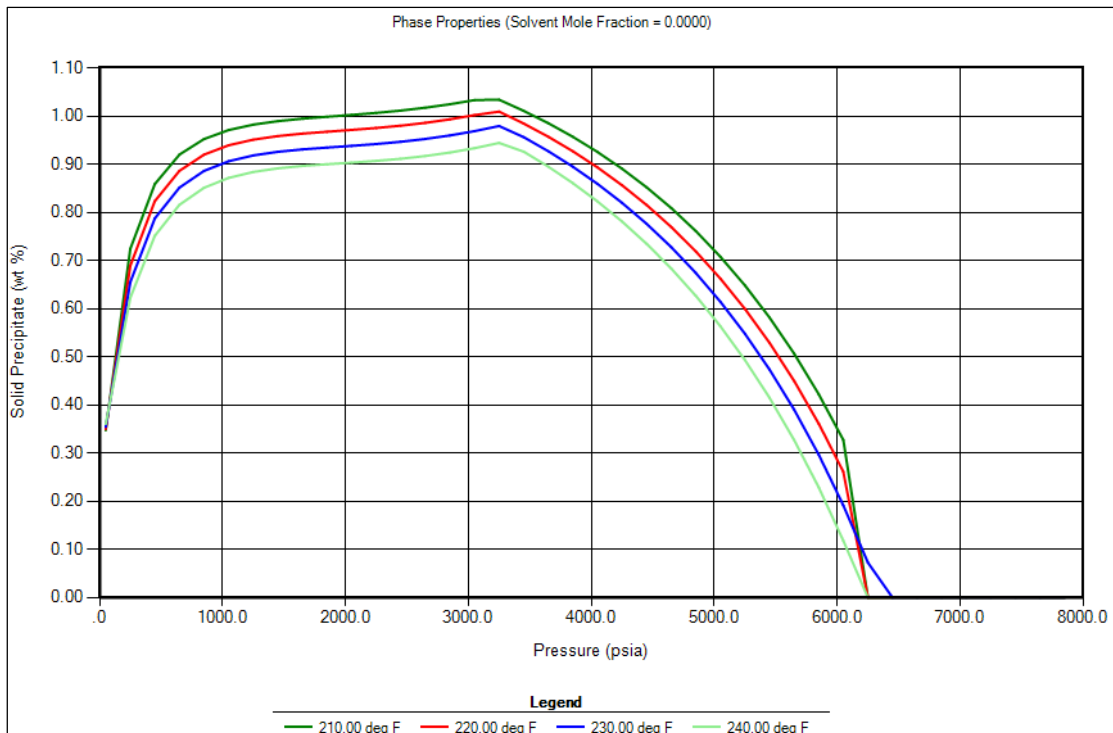


Generalmente los softwares que caracterizan el fenómeno de precipitación de asfaltenos requieren al menos un dato experimental. A modo de ejemplo, se trabajó la muestra 48 a partir de los datos experimentales generados por el modelo Neuross-Asph para obtener las curvas de porcentaje en peso (%wt) de asfaltenos precipitados a diferentes temperaturas. La gráfica 20 muestra la predicción final correspondiente al primer dato experimental predicho. La grafica 18 y 19 presenta el proceso anterior para 4 temperaturas a través de las herramientas SMAP y Winprop respectivamente.

Gráfica 20. Envoltente de precipitados de asfaltenos a diferentes temperaturas simulados con SMAP



Gráfica 21. Envoltente de precipitados de asfaltenos a diferentes temperaturas simulados con Winprop



6. CONCLUSIONES Y RECOMENDACIONES

6.1 CONCLUSIONES

- Se logró desarrollar el modelo Neuross-Asph que calcula con un alto grado de confiabilidad la envolvente superior de precipitación de asfaltenos sin necesidad de introducir datos experimentales de presión onset, que hasta el momento había sido una barrera para la utilización de otros modelos propuestos.
- Si se desea obtener toda la curva de precipitación de asfaltenos a través de los softwares comerciales disponibles, es necesario ingresar como parámetro de entrada los porcentajes en peso (%wt) de asfalteno precipitado a diferentes temperaturas ya que cada dato ingresado solo permite calcular una presión de la envolvente superior onset.
- El modelo desarrollado es eficiente, presenta resultados confiables, garantiza un amplio rango de aplicación y con alto grado de solidez ya que su base de creación es a partir de redes neuronales artificiales.
- Una de las principales ventajas desarrolladas en el modelo Neuross-Asph es que para su funcionamiento se requiere información mínima y de fácil acceso, lo que facilita que su aplicación sea extendida.
- El modelo Neuross-Asph presenta un excelente ajuste respecto a los datos que alimentaron el modelo; además los resultados generan mayor confiabilidad que los obtenidos a través de los modelos de Fahim y de mínimos cuadrados modificado.
- Para garantizar confiabilidad de los resultados, se establecieron tres restricciones: la composición química y el análisis SARA deben estar dentro de unos rangos fijados. La presión de burbuja debe ser ingresada para el rango de temperatura establecido (294.3 K-423.2K) y además hacer parte de la región delimitada.
- Un gran acierto en la construcción del modelo fue tener en cuenta los factores más influyentes en la precipitación de asfaltenos. En primer lugar, el agrupamiento según el cociente de Ponset/Pb, permitió establecer que la presión de burbuja es la

propiedad más dominante para predecir la envolvente de presiones onset. El segundo factor es la composición ya que su grado de incidencia es indirecta y complementaria a la clasificación previa.

- La categorización con el SOM en dos etapas fue conveniente debido a que permitió que las neuronas creadas agruparan muestras que relacionan correctamente la presión de burbuja, la presión onset, la composición y el análisis SARA.
- A partir de la información generada por el modelo propuesto se puede hacer la caracterización específica del fenómeno de precipitación de asfaltenos, así como identificar las condiciones operacionales seguras, toma de decisiones preventivas, cuantificación del daño de formación por precipitación-depositación.
- Aunque los avances en esta área de estudio han sido importantes, estos se han visto limitados porque la información requerida no es de fácil acceso, la cuantificación de algunas variables de entrada presenta alto grado de incertidumbre, la poca cantidad de información experimental existente, entre otras.
- El modelo puede generar resultados mucho más precisos si las RNA se entrenan con un mayor número de muestras, se descarta incertidumbre en los datos experimentales y/o si se logra establecer otro tipo de relaciones a las planteadas en la presente investigación.

6.2 RECOMENDACIONES

- El éxito de las RNA depende de la cantidad de información usada durante el entrenamiento, por lo tanto, se recomienda para mejorar el modelo propuesto, la búsqueda de muestras adicionales para ampliar el rango de aplicación.
- Comparar los resultados del modelo propuesto con otros que sean diferentes al numérico: modelo termodinámico coloidal, de solución polimérica, de solución regular, de sólido, de PC-Saft y de micelización.
- Incorporar un mayor número de variables de entrada que permitan identificar otro tipo de relaciones que influyen en la determinación de la presión onset.
- Realizar un estudio de sensibilidad a profundidad para establecer entre cada componente de la composición química y el análisis SARA, el grado de influencia sobre el comportamiento de la presión onset.
- Realizar proyectos investigativos interdisciplinarios que permitan la vinculación de diferentes programas académicos de la universidad.

BIBLIOGRAFÍA

- [1] S. Badre, C. Goncalves, K. Norinaga, G. Gustavson y O. C. Mullins, «Molecular size and weight of asphaltene and asphaltene solubility fractions from coals, crude oils and bitumen,» vol. 85, Fuel, 2006, pp. 1-11.
- [2] M. Alayon, «Asfaltenos: Ocurrencia y floculación,» 2004. [En línea]. Available: http://www.firp.ula.ve/archivos/cuadernos/S369PP_Asfaltenos.pdf.
- [3] V. Braco, G. Mansoori , X. L. Almeida, H. Manafi y S. Park , «Journal of Petroleum Science and Engineering,» vol. 217, nº 32, 2001.
- [4] H. Groenzin y O. Mullins, «Phys. Chem,» vol. 103, nº 11237, p. 50, 1999.
- [5] J. Speight, «Characterization of Heavy Crude Oils and Petroleum Residues,» de *Symposium*.
- [6] A. Mansoori, «Journal of Petroleum Science and Engineering,» de 17, 2001.
- [7] J. A. Sepúlveda, C. Pinzón, R. Parra y L. E. Mantilla, Estado del arte de la depositación de asfaltenos y parafinas, Neiva: Universidad Surcolombiana, 1998.
- [8] A. Hirschberg, L. N. De Jong, B. A. Schipper y J. G. Meyers, «Influence of Temperature and Pressure on Asphaltene Flocculation,» *SPE*, 26-29 Septiembre 1988.
- [9] N. E. Burke, R. E. Hobbs y S. F. Kashon, «Measurement and Modeling of Asphaltene Precipitation,» *Journal of Petroleum Technology*, pp. 1440-1446, Noviembre 1990.
- [10] S. Kawanaka, S. J. Park y G. A. Mansoori, «Organic Deposition From Reservoir Fluids: A Thermodynamic Predictive Technique,» *SPE Reservoir Engineering*, pp. 185-192, Mayo 1991.
- [11] R. B. Boer, K. Leerlooyer, M. R. Elgner y A. R. D. van Bergen, «Screening of Crude Oils for Asphalt Precipitation: Theory, Practice, and the Selection of Inhibitors,» *SPE Production & Facilities*, pp. 55-61, Febrero 1995.
- [12] T. Chung, «Thermodynamic Modeling for Organic Solid Precipitation,» *SPE*, nº 24851, 4-7 Octubre 1992.

- [13] H. W. Yarranton y J. H. Masliyah, «Molar Mass Distribution and Solubility Modeling of Asphaltenes,» *AIChE Journal*, vol. 42, nº 12, pp. 3533-3543, 1996.
- [14] L. X. Nghiem, M. S. Hassam, N. Nutakki y A. E. D. George, «Efficient Modeling of Asphaltene Precipitation,» *SPE*, nº 20530, 3-6 Octubre 1993.
- [15] J. Gross y G. Sadowski, «Perturbed-Chain SAFT: An Equation of state based on perturbation theory for chain molecules,» vol. 40, p. 1244–1260, 2001.
- [16] W. G. Chapman, K. E. Gubbins, G. Jackson y M. Radosz, «New reference equation of state for associating liquids,» *Eng. Chem*, vol. 29, p. 1709–1721, 1990.
- [17] A. I. Victorov y A. Firoozabadi, «Thermodynamics of asphaltene deposition using a micellization model,» *AIChE*, vol. 42, p. 1753–1764, 1996.
- [18] J. Wu, J. M. Prausnitz y A. Firoozabadi, «Molecular-thermodynamic framework for asphaltene-oil equilibria,» *AIChE*, vol. 44, p. 1188–1199, 1999.
- [19] J. G. Speight, «Petroleum asphaltenes - Part 1: Asphaltenes, resins and the structure of petroleum.,» *Oil & Gas Science and Technology*, p. 467–477, 2004.
- [20] K. Akbaezadeh, S. Allenson y J. Creek, «Los asfaltenos: Problemáticos pero ricos en potencial.,» *Nalco Energy Services*, 2007.
- [21] S. Asomaning, «Test Methods for Determining Asphaltene Stability in Crude Oils.,» *Petroleum Science and Technology*, vol. 21, nº 3-4, p. 581–590, 2003.
- [22] S. Asomaning y A. P. Watkinson, «Petroleum Stability and Heteroatom Species Effects in Fouling of Heat Exchangers by Asphaltenes.,» *Heat Transfer Eng*, vol. 21, pp. 10-16, 2000.
- [23] A. B. Stankiewicz, M. D. Flrnaery, N. A. Fuex, G. Broze, J. L. Couch, S. T. Dubey, S. D. Iyer, J. Ratulowski y J. T. Westerich, «Prediction of asphaltene deposition risk inE&Poperations.,» *AIChE*, p. 410–416, 10-14 Marzo 2002.
- [24] J. P. Bonilla y Y. Medina, redicción de la estabilidad de los asfaltenos mediante la utilización del análisis sara para petróleos puros, Neiva: Universidad Surcolombiana, 2010.
- [25] J. A. Sepúlveda, J. P. Bonilla y Y. Medina, «Predicción de la estabilidad de los asfaltenos mediante lautilización del análisis SARA para petróleos puros,» *Revista Ingeniería y Región*, vol. 7, 2007.

- [26] C. D. Cundar, Modelamiento escalado del daño de precipitación-depositación de asfaltenos en un Yacimiento de Petróleo, Medellín: Universidad Nacional de Colombia, 2013.
- [27] S. F. Alkafeef, R. J. Gochin y A. L. Smith, «The Effect of Double Layer Overlap on Measured Streaming Currents for Toluene Flowing through Sandstone Rock Cores,» *Colloid and Surfaces, A, Physicochemical and Engineering Aspects*, vol. 195, p. 77–80, 2001.
- [28] A. F. Alta'ee y T. Wan Ru, «Investigation of Asphaltene Onset Pressure (AOP) in Low Asphaltenic Light Oil Samples,» de *Proceedings of the International Conference on Integrated Petroleum Engineering and Geosciences*, Malasya, Springer, 2014, pp. 23-45.
- [29] M. G. Trbovich y G. E. King, «Asphaltene Deposit Removal: Long – Lasting Treatment with a Co-Solvent.,» *SPE*, nº 21038, 1991.
- [30] D. J. Matich , *Redes Neuronales: Conceptos Básicos y Aplicaciones*, Rosario: Universidad Tecnológica Nacional, 2001.
- [31] X. Basogain Olabe , *Redes neuronales artificiales y sus aplicaciones*, Bilbao: Escuela Superior de Ingeniería de Bilbao.
- [32] G. Boeree, «Psicología Online,» Clínica Psicológica V. Mars, [En línea]. Available: <http://www.psicologia-online.com/ebooks/general/neuronas.htm>.
- [33] A. Huerta , J. C. Quispe , E. Ramos y Y. Molina , «Sector Electricidad,» 2012. [En línea]. Available: <http://www.sectorelectricidad.com/2625/aplicacion-de-redes-neuronales-para-el-pronostico-de-demanda-a-corto-plazo/>.
- [34] A. H. Mohammadi y D. Richon, «Estimating Onset of Precipitation of Dissolved Asphaltene in the Solution of Solvent + Precipitant Using Artificial Neural Network Technique,» *The Open Thermodynamics Journal*, nº 2, pp. 82-88, 2008.
- [35] A. Abedini , S. Ashoori y Y. Saki, «Application of Neural Network Model for Prediction of Asphaltene Precipitation,» *SPE*, nº SPE 132760, 2010.
- [36] M. A. Ahmadi, «Neural network based unified particle swarm optimization for prediction of asphaltene precipitation,» *Elsevier*, vol. 314, pp. 46-51, 2011.
- [37] M. A. Ahmadi y S. R. Shadzadeh, «New approach for prediction of asphaltene precipitation due to natural depletion by using evolutionary algorithm concept,» *Elsevier*, 2012.

- [38] S. Zendejboudia, A. Shafieib y A. Bahad, «Asphaltene precipitation and deposition in oil reservoirs – Technical aspects, experimental and hybrid neural network predictive tools,» *Elsevier*, vol. 92, pp. 857-875, 2014.
- [39] A. Hemmati-Sarapardeha , R. Alipour, Y. Marandb, A. Naserib, A. Safiabadib, F. Gharagheizic, P. Ilani-Kashkouli y A. H. Mohammadi, «Asphaltene precipitation due to natural depletion of reservoir: Determination using a SARA fraction based intelligent model,» *Elsevier*, vol. 354, pp. 177-184, 2013.
- [40] A. Kamari , A. Safiri y A. H. Mohammadi, «Compositional Model for Estimating Asphaltene Precipitation Conditions in Live Reservoir Oil Systems,» *Journal of Dispersion Science and Technology*, vol. 36, pp. 301-309, 2015.
- [41] C. M. Group, *Win prop*, Calgary, 2012.
- [42] A. K. Jamaluddin, J. Creek, C. S. Kabir, J. D. McFadden, D. D’Cruz, M. T. Joseph, N. Joshi y B. Ross, «A Comparison of Various Laboratory Techniques to Measure Thermodynamic Asphaltene Instability,» *SPE*, nº 72154, 2001.
- [43] Systat Software Inc, *Table curve 2d v 5.01*, San Jose California, 2016.
- [44] Mathworks, *Matlab*, Natick, Massachusetts: Licencia Estudiantes Universidad Surcolombiana, 2013.
- [45] J. M. Marín, «Los mapas auto-organizados de Kohonen,» [En línea]. Available: <http://halweb.uc3m.es/esp/Personal/personas/jmmarin/esp/DM/tema5dm.pdf>.
- [46] A. M. Gomez, «Redes neuronales artificiales: the self-organizing maps (SOM) para el reconocimiento de patrones,» vol. 1, nº 1.
- [47] M. F. Fernandez, «Mapas auto-organizables (SOM),» [En línea]. Available: http://www.gsi.dec.usc.es/~delgado/cfc/som/6_som.pdf.
- [48] V. L. Juan , red neuronal feedforward como estimador de patrones de corrientes en el interior del puerto de manzanillo, Sanfandila: Instituto mexicano del transporte, 2014.
- [49] M. A. Fahim, «Empirical Equations for Estimating ADE of Crude Oils,» *Petroleum Science and Technology*, nº 25, p. 49–965, 2007.

- [50] J. M. Del Rio, E. Ramirez-Jaramillo y C. Lira-G, «Equations to Predict Precipitation Onset and Bubblepoint Pressures of Asphaltenic Reservoir Fluids,» *AIChE Journal*, vol. 55, nº 7, 2009.
- [51] S. Punnapala y F. M. Vargas, «Revisiting the PC-SAFT characterization procedure for an improved asphaltene precipitation prediction,» *Elsevier*, pp. 417-429, 2013.
- [52] H. Yonebayashi, T. Masuzawa, C. Dabbouk y D. Urasaki, «Ready for Gas Injection: Asphaltene Risk Evaluation by Mathematical Modeling of Asphaltene Precipitation Envelope (APE) With Integration of all Laboratory Deliverables,» *SPE*, nº 125643, 2009.
- [53] D. L. Gonzalez, E. Mahmoodaghdam, F. Lim y N. Joshi, «Effects of Gas Additions to Deepwater Gulf of Mexico Reservoir Oil: Experimental Investigation of Asphaltene Precipitation and Deposition,» *SPE*, nº 159098, 2012.
- [54] W. A. Cañas , *Información experimental ICP*, Barrancabermeja, 2015.
- [55] S. R. Panuganti , F. M. Vargas , D. L. Gonzalez , K. S. Anjushri y W. G. Chapman, «PC-SAFT characterization of crude oils and modeling of asphaltene phase behavior,» *Elsevier*, nº 93, p. 658–669, 2012.
- [56] M. Hassanvand, B. Shahsavani y A. Anoooshe, «Study of temperature effect on asphaltene precipitation by visual and quantitative methods,» *Journal of Petroleum Technology and Alternative Fuels*, vol. 3, pp. 8-18, 2012.
- [57] G. P. Oskui, M. Salman, E. F. Gholoum, A. Rashed, B. S. Al Matar, M. Al- Bahar y K. Kahali, «Laboratory Technique for Screening Asphaltene Inhibitors for Kuwaiti Reservoirs,» *SPE*, nº 106361, 2006.
- [58] A. . K. Tharanivasan, «Modeling of Asphaltene Precipitation from Crude Oil Blends,» de *Asphaltene Precipitation from Crude Oil Blends, Conventional Oils, and Oils with Emulsified Water*, Calgary, University of Calgary, 2012, pp. 83-106.
- [59] E. F. Gholoum, G. P. Oskui y M. K. Salman, «Investigation of Asphaltene Precipitation onset Conditions for Kuwaiti Reservoirs,» *SPE*, nº 81571, 2003.
- [60] S. Takahashi, Y. Hayashi, S. Takahashi, N. Yazawa y H. Sarma, «Characteristics and Impact of Asphaltene Precipitation During CO₂ Injection in Sandstone and Carbonate Cores: An Investigative Analysis Through Laboratory Tests and Compositional Simulation,» *SPE*, nº 84895, 2003.

- [61] T. J. Behbahani, C. Ghotbia, V. Taghikhania y A. Shahrabadi, «A modified scaling equation based on properties of bottom hole live oil for asphaltene precipitation estimation under pressure depletion and gas injection conditions,» *Elsevier*, nº 358, p. 212– 219, 2013.
- [62] A. Al-Qattan, M. J. Blunt, O. Gharbi, A. Badamchizadeh, J. M. Al-Kanderi, M. Al-Jadi, H. H. Dashti, V. Chimmalgi, D. J. Bond y F. Skoreyko, «Evaluation of the Effect of Asphaltene Deposition in the Reservoir for the Development of the Magwa Marrat Reservoir,» *SPE*, nº 163331, 2012.
- [63] M. Jamshidnezhad, «Prediction of Asphaltene Precipitation in an Iranian South Oil Field,» *Petroleum Society*, nº 15, 2005.
- [64] S. Negahban, N. Joshi, K. M. Jamaluddin y J. Nighswander, «A Systematic Approach for Experimental Study of Asphaltene Deposition for an Abu Dhabi Reservoir Under WAG Development Plan,» *SPE*, nº 80261, 2003.
- [65] T. Uetani, T. Matsuoka y H. Honda, «Investigation of the Conditions Required for Improved Oil Recovery by an Earthquake,» *SPE*, nº 168137, 2016.
- [66] G. A. Roshanaei Zadeh, S. Moradi, I. Azad, B. Dabir, M. A. Emadi y D. Rashtchian, «Comprehensive Study of Asphaltene Precipitation due to Gas Injection: Experimental Investigation and modeling,» *SPE*, nº 143454, 2011.
- [67] S. M. Moqadam, H. Firoozinia, , R. Kharrat,, M. H. Ghazanfari y A. R. Alamatsaz, «Effect of Pressure and CO2 Composition Changes on Distribution of Asphaltene Molecular Weight in Heavy Crude Oil,» *Petroleum Society*, nº 37, 2009.

ANEXOS

ANEXO 1: COMPOSICIONES DE LAS MUESTRAS UTILIZADAS EN LA CONSTRUCCIÓN DEL MODELO

	N ₂	CO ₂	H ₂ S	C ₁	C ₂	C ₃	C ₄	C ₅	C ₆	C ₇₊
Muestra 1	0,06	32,58	3,69	32,09	3,75	2,95	2,78	2,23	2,49	17,22
Muestra 2	0,27	2,9	8,26	26,45	8,04	6,66	5,32	4,14	4,29	33,66
Muestra 3	0,33	10,16	0	32,16	7,97	6,14	1,1	3,42	7,23	31,49
Muestra 4	0,49	11,37	3,22	27,36	9,41	6,7	3,98	3,2	2,49	31,79
Muestra 5	0,07	22,94	4,22	36,67	4,28	3,37	3,18	2,55	2,85	19,68
Muestra 6	0,34	0,16	0	32,9	8,15	6,28	4,63	3,7	4	39,85
Muestra 7	0,37	0,17	0	35,73	8,85	6,82	1,23	3,8	8,04	34,98
Muestra 8	0,08	13,31	4,74	41,26	4,82	3,79	3,57	2,87	3,2	22,14
Muestra 9	0,16	1,94	0	33,6	7,56	6,74	6,58	5,18	5,05	32,63
Muestra 10	0,02	2,76	0,51	54,92	7,55	4,9	3,57	2,58	2,68	20,49
Muestra 11	0,04	2,23	0,25	50,74	8,59	5,66	4	2,88	3,2	22,42
Muestra 12	0,24	2,64	0	45,86	9,01	6,93	5,42	3,71	2,48	23,73
Muestra 13	0,24	2,56	0	48,99	7,74	5,5	4,62	3,38	2,64	24,35
Muestra 14	0,01	0,99	0	43,09	10,72	7,08	4,1	2,77	2,18	29,06
Muestra 15	0,56	0,81	0	41,87	10,7	7,3	4,26	3,09	2,46	28,96
Muestra 16	0,39	0,01	0	50,34	4,54	4,85	3,77	3,36	3,56	29,18
Muestra 17	0,33	1,11	0	42,19	9,54	6,61	4,66	2,67	1,99	30,84
Muestra 18	0,2	2,38	0	40,4	8,39	6,87	5,85	4,25	2,92	28,77
Muestra 19	0,56	0,13	0	46,9	6,13	4,67	3,05	2,25	2,5	33,82
Muestra 20	0,19	2,29	0	38,59	8,18	6,85	5,99	4,43	3,07	30,44

Continuación...

	N₂	CO₂	H₂S	C₁	C₂	C₃	C₄	C₅	C₆	C₇₊
Muestra 21	1,28	1,15	0	35,98	10,3	8,44	4,83	2,33	2,36	33,34
Muestra 22	1,41	3,95	6,37	41,95	8,74	5,21	3,45	4,39	2,41	22,12
Muestra 23	0,18	2,2	0	36,77	7,98	6,83	6,13	4,61	3,35	32
Muestra 24	0,17	2,11	0	34,95	7,77	6,81	6,27	4,79	3,5	33,67
Muestra 25	0,16	1,94	0	33,53	7,66	7,27	6,58	5,18	5,05	32,66
Muestra 26	0,08	30,5	0	8,78	3,95	4,81	2,82	6,2	2,42	40,44
Muestra 27	0,09	25,54	0	9,41	4,24	5,15	3,02	6,64	2,59	43,33
Muestra 28	0,09	20,58	0	10,03	4,52	5,5	3,22	7,08	2,76	46,22
Muestra 29	0,1	15,61	0	10,66	4,8	5,84	3,43	7,52	2,93	49,1
Muestra 30	0,1	10,65	0	11,29	5,08	6,18	3,63	7,97	3,11	51,99
Muestra 31	0,11	5,68	0	11,92	5,37	6,53	3,83	8,41	3,28	54,88
Muestra 32	0,12	0,72	0	12,54	5,65	6,87	4,03	8,85	3,45	57,77
Muestra 33	0,3	1,83	0	22,7	8,24	6,14	4,8	2,97	6,95	46,09
Muestra 34	5,08	11,12	0,06	30,99	6,41	5,04	3,56	3	3,26	31,48
Muestra 35	0,19	9,34	0,06	31,39	7,43	5,73	3,94	3,32	3,61	34,99
Muestra 36	0,19	9,76	0,06	32,34	7,57	5,71	3,85	3,21	3,49	33,82
Muestra 37	0,24	1,67	0,06	27,9	8,99	8,65	5,39	3,96	4,07	39,07
Muestra 38	0,2	1,43	0,06	33,01	7,91	6,23	4,37	3,7	4,03	39,07
Muestra 39	4,31	1,45	0,07	34,94	8,09	5,98	3,95	3,27	3,55	34,4
Muestra 40	0,09	1,02	0,05	42,41	10,78	6,92	4,47	3,29	2,86	28,11

Continuación...

	N₂	CO₂	H₂S	C₁	C₂	C₃	C₄	C₅	C₆	C₇₊
Muestra 41	0,03	0,89	0,03	41,95	10,68	7,11	4,44	3,32	2,89	28,66
Muestra 42	0,04	0,78	0	40,91	10,72	6,64	4,44	2,62	2,51	31,34
Muestra 43	0,04	0,86	0,03	40,38	10,48	7,17	4,58	3,47	3,02	29,95
Muestra 44	0,24	1,62	0,09	41,13	9,16	6,23	3,78	3,02	3,25	31,49
Muestra 45	0,3	1,97	0,08	34,01	10,67	9,59	5,21	3,38	3,31	31,49
Muestra 46	0,23	1,58	1,74	39,89	8,92	6,12	3,76	3,01	3,25	31,49
Muestra 47	0,1	3,71	1,85	46,53	8,76	4,98	3,32	1,92	2,64	26,19
Muestra 48	0,48	0,92	0	43,43	11,02	6,55	4,49	3,53	2,7	26,88
Muestra 49	0,8	0,05	0	51,02	8,09	6,02	3,97	3,21	2,67	24,17
Muestra 50	0,21	2,56	0	25,2	7,08	6,56	6,2	4,92	3,94	43,33
Muestra 51	0,44	3,4	0,9	46,91	7,86	6,07	4,94	3,26	2,33	23,89
Muestra 52	0,37	3,23	0,3	48,66	6,73	4,97	4,44	3,34	2,51	25,45
Muestra 53	0,49	3,65	0,9	57,41	7,46	5,15	4,07	2,59	1,76	16,52
Muestra 54	0,26	17,57	0	37,65	5,41	4,15	3,93	3,15	2,46	25,43
Muestra 55	0,15	0,27	0	26,79	6,8	8,37	5,97	3,95	5,47	42,23
Muestra 56	0,06	2,45	0,59	38,65	6,66	5,33	3,93	2,75	4,67	34,92
Muestra 57	0,21	5,14	2,7	22	7,1	5,34	3,77	2,53	5,55	45,66
Muestra 58	0,13	2,07	0,02	17,06	8,05	6,88	5,76	5,17	3,35	51,52

ANEXO 2: ANÁLISIS SARA DE LAS MUESTRAS UTILIZADAS EN LA CONSTRUCCIÓN DEL MODELO

	SAT	ARM	RES	ASF
Muestra 1	73,4	19,3	7,1	0,2
Muestra 2	54,3	40,3	4,5	0,9
Muestra 3	39,2	35,9	9,0	15,5
Muestra 4	57,4	30,8	10,4	1,4
Muestra 5	73,4	19,3	7,1	0,2
Muestra 6	41,7	35,2	8,3	14,8
Muestra 7	39,2	35,9	9,0	15,5
Muestra 8	73,4	19,3	7,1	0,2
Muestra 9	66,3	25,6	5,4	2,8
Muestra 10	70,9	24,2	3,9	1,0
Muestra 11	74,8	21,6	2,6	1,0
Muestra 12	75,6	20,1	4,1	0,2
Muestra 13	73,4	19,3	7,1	0,2
Muestra 14	63,8	31,7	2,6	0,9
Muestra 15	63,9	32,2	2,5	1,2
Muestra 16	50,3	30,5	14,6	4,0
Muestra 17	69,4	22,7	6,8	1,1
Muestra 18	75,6	20,1	4,1	0,2
Muestra 19	57,5	30,4	8,3	3,7
Muestra 20	75,6	20,1	4,1	0,2
Muestra 21	54,8	34,5	7,4	3,3
Muestra 22	59,3	37,0	2,7	0,9
Muestra 23	75,6	20,1	4,1	0,2
Muestra 24	75,6	20,1	4,1	0,2
Muestra 25	66,3	25,6	5,4	2,8
Muestra 26	38,8	49,6	7,7	3,9
Muestra 27	38,8	49,6	7,7	3,9
Muestra 28	38,8	49,6	7,7	3,9
Muestra 29	38,8	49,6	7,7	3,9
Muestra 30	38,8	49,6	7,7	3,9

Continuación...

	SAT	ARM	RES	ASF
Muestra 31	38,8	49,6	7,7	3,9
Muestra 32	38,8	49,6	7,7	3,9
Muestra 33	32,6	43,5	7,6	16,3
Muestra 34	59,4	22,6	14,0	1,7
Muestra 35	59,4	22,6	14,0	1,7
Muestra 36	59,4	22,6	14,0	1,7
Muestra 37	59,4	22,6	14,0	1,7
Muestra 38	59,4	22,6	14,0	1,7
Muestra 39	59,4	22,6	14,0	1,7
Muestra 40	66,5	26,1	6,3	1,1
Muestra 41	69,5	21,8	8,3	0,4
Muestra 42	65,3	26,8	7,2	0,6
Muestra 43	70,6	20,2	8,5	0,5
Muestra 44	59,4	22,6	14,0	1,7
Muestra 45	59,4	22,6	14,0	1,7
Muestra 46	59,4	22,6	14,0	1,7
Muestra 47	26,9	68,0	4,5	0,7
Muestra 48	68,3	11,6	18,8	1,3
Muestra 49	65,6	16,3	13,5	4,6
Muestra 50	54,2	40,3	4,6	0,9
Muestra 51	54,2	40,3	4,6	0,9
Muestra 52	61,3	31,8	6,4	0,5
Muestra 53	61,3	31,8	6,4	0,5
Muestra 54	61,3	31,8	6,4	0,5
Muestra 55	57,8	34,3	6,9	1,0
Muestra 56	65,5	19,4	6,4	8,7
Muestra 57	30,1	42,1	13,4	13,8
Muestra 58	44,8	34,8	12,2	8,1

ANEXO 3: PRESIÓN ONSET Y PRESIÓN DE BURBUJA DE LAS MUESTRAS UTILIZADAS EN LA CONSTRUCCIÓN DEL MODELO

	Temperatura (°F)	Presión Onset (psia)	Presión de burbuja (psia)	Temperatura (K)	Presión Onset (Mpa)	Presión de burbuja (Mpa)
Muestra 1 [51]	120	9000	3100	322	62,05	21,37
	175	7000	3600	353	48,26	24,82
	250	6500	4000	394	44,82	27,58
Muestra 2 [52]	75	6250	1375	297	43,09	9,48
	100	5300	1500	311	36,54	10,34
	150	4600	1795	339	31,72	12,38
	200	4100	2000	366	28,27	13,79
	245	3750	2180	391	25,86	15,03
Muestra 3 [53]	70	11000	1819	294	75,84	12,54
	100	8800	2115	311	60,67	14,58
	150	7100	2419	339	48,95	16,68
	208	6200	2722	371	42,75	18,77
Muestra 4 [54]	190	5400	2500	361	37,23	17,24
	230	4050	2700	383	27,92	18,62
	260	3650	2900	400	25,17	19,99
Muestra 5 [51]	120	8000	3100	322	55,16	21,37
	175	6500	3600	353	44,82	24,82
	250	5700	4000	394	39,3	27,58
Muestra 6 [54]	80	8600	1700	300	59,29	11,72
	88	7200	1750	304	49,64	12,07
	100	5900	1850	311	40,68	12,76
	150	5050	2128	339	34,82	14,67
	250	4600	2420	394	31,72	16,69
Muestra 7 [53]	80	8585	1685	300	59,19	11,62
	88	7500	1735	304	51,71	11,96
	100	6400	1835	311	44,13	12,65
	150	5300	2113	339	36,54	14,57
	208	4585	2405	371	31,61	16,58
Muestra 8 [51]	120	7500	3100	322	51,71	21,37
	170	5100	3600	350	35,16	24,82
	250	4200	4000	394	28,96	27,58

Continuación...

	Temperatura (°F)	Presión Onset (psia)	Presión de burbuja (psia)	Temperatura (K)	Presión Onset (Mpa)	Presión de burbuja (Mpa)
Muestra 9 [55]	130	4100	1710	328	28,27	11,79
	160	3000	1850	344	20,68	12,76
	250	2400	2000	394	16,55	13,79
Muestra 10 [56]	194	9181	3900	363	63,3	26,89
	248	7900	4150	393	54,47	28,61
	289	7300	4283	416	50,33	29,53
Muestra 11 [56]	194	9585	4515	363	66,09	31,13
	248	8000	4617	393	55,16	31,83
	289	6900	4843	416	47,57	33,39
Muestra 12 [51]	165	9200	3000	347	63,43	20,68
	250	7000	3450	394	48,26	23,79
Muestra 13 [51]	170	8600	3540	350	59,29	24,41
	250	6500	3700	394	44,82	25,51
Muestra 14 [57]	156	8600	2797	342	59,29	19,28
	159	7800	2830	344	53,78	19,51
	194	6900	2913	363	47,57	20,08
	231	6200	3050	384	42,75	21,03
	235	5800	3100	386	39,99	21,37
Muestra 15 [57]	159	9300	2767	344	64,12	19,08
	198	7500	2921	365	51,71	20,14
	237	6500	3073	387	44,82	21,19
	240	6200	3100	389	42,75	21,37
Muestra 16 [58]	176	10733	4047	353	74	27,9
	212	9863	4076	373	68	28,1
	248	9282	4090	393	64	28,2
Muestra 17 [54]	120	7000	3514	322	48,26	24,23
Muestra 18 [51]	165	4400	2230	347	30,34	15,38
	250	3800	2610	394	26,2	18
Muestra 19 [53]	70	8200	3015	294	56,54	20,79
	100	5985	3200	311	41,27	22,07
	150	5285	3445	339	36,44	23,75

Continuación....

	Temperatura (°F)	Presión Onset (psia)	Presión de burbuja (psia)	Temperatura (K)	Presión Onset (Mpa)	Presión de burbuja (Mpa)
Muestra 20 [51]	130	4600	1900	328	31,72	13,1
	165	3800	2200	347	26,2	15,17
	250	3100	2500	394	21,37	17,24
Muestra 21 [59]	140	3120	2210	333	21,51	15,24
	168	2800	2300	349	19,31	15,86
	196	2580	2460	364	17,79	16,96
Muestra 22 [38]	212	9552	1176	373	65,86	8,11
	302	8377	2057	423	57,76	14,19
Muestra 23 [51]	130	3450	1770	328	23,79	12,2
	165	2900	2010	347	19,99	13,86
	250	2500	2215	394	17,24	15,27
Muestra 24 [51]	130	2350	1550	328	16,2	10,69
	165	2200	1800	347	15,17	12,41
	250	2070	1950	394	14,27	13,44
Muestra 25 [51]	130	4000	1700	328	27,58	11,72
	165	3100	1900	347	21,37	13,1
	250	2500	2050	394	17,24	14,13
Muestra 26 [60]	212	3400	1600	373	23,44	11,03
Muestra 27 [60]	212	2900	1500	373	19,99	10,34
Muestra 28 [60]	212	2900	1200	373	19,99	8,27
Muestra 29 [60]	212	2100	1100	373	14,48	7,58
Muestra 30 [60]	212	1200	950	373	8,27	6,55
Muestra 31 [60]	212	900	850	373	6,21	5,86
Muestra 32 [60]	212	785	689	373	5,41	4,75
Muestra 33 [61]	205	4017	1392	369	27,7	9,6
Muestra 34 [51]	212	5400	3900	373	37,23	26,89
Muestra 35 [51]	212	3900	2700	373	26,89	18,62
Muestra 36 [51]	212	5000	3200	373	34,47	22,06
Muestra 37 [51]	212	3000	2300	373	20,68	15,86
Muestra 38 [51]	212	2900	2200	373	19,99	15,17
Muestra 39 [51]	212	4900	4000	373	33,78	27,58

Continuación...

Nombre	Temperatura (°F)	Presión Onset (psia)	Presión de burbuja (psia)	Temperatura (°K)	Presión Onset (Mpa)	Presión de burbuja (Mpa)
Muestra 40 [62]	241	6015	3250	389	41,47	22,41
Muestra 41 [62]	237	5728	3175	387	39,49	21,89
Muestra 42 [62]	241	6215	3150	389	42,85	21,72
Muestra 43 [62]	237	5627	3050	387	38,79	21,03
Muestra 44 [51]	212	5400	3780	373	37,23	26,06
Muestra 45 [51]	212	4900	3000	373	33,78	20,68
Muestra 46 [51]	212	5300	3900	373	36,54	26,89
Muestra 47 [63]	250	6000	3725	394	41,37	25,68
Muestra 48 [42]	210	6854	3221	372	47,26	22,21
	219	6588	3284	377	45,42	22,64
	230	6419	3276	383	44,26	22,59
	241	6225	3289	389	42,92	22,68
Muestra 49 [42]	190	5300	4260	361	36,54	29,37
Muestra 50 [64]	130	3800	1230	328	26,2	8,48
Muestra 51 [64]	250	12500	4010	394	86,18	27,65
	130	14500	3220	328	99,97	22,2
Muestra 52 [64]	250	7092	4103	394	48,9	28,29
	130	8087	3657	328	55,76	25,21
Muestra 53 [64]	250	11889	5193	394	81,97	35,8
Muestra 54 [64]	130	4400	3243	328	30,34	22,36
Muestra 55 [65]	299	3410	1915	421	23,51	13,2
Muestra 56 [66]	185	4200	2747	358	28,96	18,94
Muestra 57 [66]	255	6700	1722	397	46,19	11,87
Muestra 58 [67]	205	7700	1067	369	53,09	7,36

**ANEXO 4: LISTADO COMPLETO DE PRESIONES ONSET Y DE BURBUJA
CON LA QUE SE CONSTRUYÓ EL MODELO PARA UNA MUESTRA
EJEMPLO (MUESTRA 48).**

Temperatura (°K)	Presión de burbuja (Mpa)	Presión Onset (Mpa)
294,3	19,55	91,00
295	19,58	90,25
296	19,63	89,19
297	19,68	88,15
298	19,73	87,14
299	19,78	86,14
300	19,83	85,17
301	19,88	84,22
302	19,92	83,29
303	19,97	82,38
304	20,02	81,48
305	20,06	80,61
306	20,11	79,75
307	20,15	78,91
308	20,20	78,09
309	20,24	77,28
310	20,28	76,49
311	20,33	75,71
312	20,37	74,95
313	20,41	74,21
314	20,45	73,48
315	20,49	72,76
316	20,54	72,06
317	20,58	71,37
318	20,62	70,69
319	20,66	70,03
320	20,70	69,38

Temperatura (°K)	Presión de burbuja (Mpa)	Presión Onset (Mpa)
321	20,73	68,74
322	20,77	68,11
323	20,81	67,49
324	20,85	66,89
325	20,89	66,30
326	20,92	65,71
327	20,96	65,14
328	21,00	64,58
329	21,03	64,02
330	21,07	63,48
331	21,11	62,95
332	21,14	62,42
333	21,18	61,91
334	21,21	61,40
335	21,25	60,90
336	21,28	60,41
337	21,31	59,93
338	21,35	59,46
339	21,38	58,99
340	21,41	58,53
341	21,45	58,08
342	21,48	57,64
343	21,51	57,20
344	21,54	56,78
345	21,57	56,35
346	21,61	55,94
347	21,64	55,53
348	21,67	55,13

Temperature (°K)	Presión de burbuja (Mpa)	Presión Onset (Mpa)
349	21,70	54,73
350	21,73	54,34
351	21,76	53,96
352	21,79	53,58
353	21,82	53,21
354	21,85	52,85
355	21,87	52,48
356	21,90	52,13
357	21,93	51,78
358	21,96	51,44
359	21,99	51,10
360	22,02	50,76
361	22,04	50,43
362	22,07	50,11
363	22,10	49,79
364	22,12	49,47
365	22,15	49,16
366	22,18	48,86
367	22,20	48,56
368	22,23	48,26
369	22,25	47,97
370	22,28	47,68
371	22,31	47,39
372	22,33	47,11
373	22,36	46,83
374	22,38	46,56
375	22,40	46,29
376	22,43	46,03
377	22,45	45,76
378	22,48	45,50
379	22,50	45,25
380	22,52	45,00

Temperature (°K)	Presión de burbuja (Mpa)	Presión Onset (Mpa)
381	22,55	44,75
382	22,57	44,50
383	22,59	44,26
384	22,62	44,02
385	22,64	43,79
386	22,66	43,56
387	22,68	43,33
388	22,71	43,10
389	22,73	42,88
390	22,75	42,66
391	22,77	42,44
392	22,79	42,22
393	22,81	42,01
394	22,84	41,80
395	22,86	41,59
396	22,88	41,39
397	22,90	41,19
398	22,92	40,99
399	22,94	40,79
400	22,96	40,60
401	22,98	40,40
402	23,00	40,22
403	23,02	40,03
404	23,04	39,84
405	23,06	39,66
406	23,08	39,48
407	23,10	39,30
408	23,12	39,12
409	23,13	38,95
410	23,15	38,78
411	23,17	38,61
412	23,19	38,44

Temperature (°K)	Presión de burbuja (Mpa)	Presión Onset (Mpa)
418	23,30	37,47
413	23,21	38,27
414	23,23	38,11
415	23,24	37,94
416	23,26	37,78
417	23,28	37,62

Temperature (°K)	Presión de burbuja (Mpa)	Presión Onset (Mpa)
419	23,32	37,31
420	23,33	37,16
421	23,35	37,00
422	23,37	36,85
423	23,38	36,71
423,2	23,39	36,68