

TRABAJO ESPECIAL DE GRADO

**IMPLEMENTACIÓN DE REDES NEURONALES PARA PREDECIR
PRESIÓN DE MISCIBILIDAD EN LA INYECCIÓN DE DIÓXIDO DE
CARBONO**

Presentado ante la Ilustre
Universidad Central de Venezuela
Por la Br. Barreiro P., Johanna N.
Para optar al Título
De Ingeniero de Petróleo

Caracas, 2012

TRABAJO ESPECIAL DE GRADO

**IMPLEMENTACIÓN DE REDES NEURONALES PARA PREDECIR
PRESIÓN DE MISCIBILIDAD EN LA INYECCIÓN DE DIÓXIDO DE
CARBONO**

TUTOR ACADÉMICO: Prof. Alexis Gammiero

Presentado ante la Ilustre
Universidad Central de Venezuela
Por la Br. Barreiro P., Johanna N.
Para optar al Título
De Ingeniero de Petróleo

Caracas, 2012

Caracas, Junio de 2012

Los abajo firmantes, miembros del Jurado designado por el Consejo de Escuela de Ingeniería de Petróleo, para evaluar el Trabajo Especial de Grado presentado por la Bachiller Johanna N. Barreiro P., titulado:

**“IMPLEMENTACIÓN DE REDES NEURONALES PARA PREDECIR
PRESIÓN DE MISCIBILIDAD EN LA INYECCIÓN DE DIÓXIDO DE
CARBONO”.**

Consideran que el mismo cumple con los requisitos exigidos por el plan de estudios conducente al Título de Ingeniero de Petróleo, y sin que ello signifique que se hacen solidarios con las ideas expuestas por los autores, lo declaran APROBADO.



**Prof. Evelyn Azuaje
Jurado Principal**



**Prof. Carlos Gil
Jurado Principal**



**Prof. Alexis Gammiero
Tutor Académico**





Escuela de Ingeniería de Petróleo
Facultad de Ingeniería-UCV

ACTA

Quienes suscriben, integrantes de la totalidad del jurado examinador del Trabajo Especial de Grado, titulado: **“IMPLEMENTACIÓN DE REDES NEURONALES PARA PREDECIR PRESIÓN DE MISCIBILIDAD EN LA INYECCIÓN DE DIÓXIDO DE CARBONO”**, presentado por la Br. JOHANNA BARREIRO, titular de la Cédula de Identidad No. 17.389.978. Para optar al título de Ingeniero de Petróleo, acordaron por unanimidad solicitarles a las autoridades correspondientes de la Facultad de Ingeniería, tengan a bien otorgar **MENCIÓN HONORÍFICA** al Trabajo de Grado antes mencionado.

Esta solicitud se hace con base a la originalidad del enfoque utilizado para tratar el tema presentado y a la excelencia, tanto de su contenido como de su presentación formal, atributos que lo convierten en una fuente de referencia útil.

Se levanta la presente Acta en Caracas, al primer (01) días del mes de junio del año dos mil doce.

Prof. Carlos Gil
Jurado Principal

Prof. Evelyn Azuaje
Jurado Principal

Prof. Alexis Gammiero
Tutor Académico



A mi abuela querida María Esther Cortizo que por su valioso esfuerzo, amor, confianza y apoyo incondicional que me brindó desde el primer momento, me ha dado energía para alcanzar mis metas y seguir adelante. Gracias por estar a mi lado en todo momento y cuando más lo necesito. Siempre serás mi ángel guardián.

¡Te quiero muchísimo!

AGRADECIMIENTOS

A ti Dios por permitirme venir a este mundo, por darme salud y la oportunidad de crecer, por darme estos años que hoy reflejan el primer fruto de muchos que estarán por venir. Gracias por escuchar mis oraciones y estar ahí en los momentos que más te necesito.

A mi abuela María Esther Cortizo que ha sido como una madre para mí, gracias de corazón por todo lo que has luchado y sigues haciendo por mí. Que Dios te bendiga y te de mucha salud para que sigas a mi lado.

A mis padres y demás familiares que me impulsaron, apoyaron y confiaron en mí en todo momento. A mis padrinos que desde pequeña me educaron y fueron de gran apoyo para seguir adelante. ¡Gracias por todo, los quiero!

A la familia Araya García y en especial a mi novio Hugo Araya, que mas que un novio eres un gran amigo, has sido mi soporte cuando he caído y siempre has estado cuando más lo he necesitado. Gracias por tu apoyo incondicional. Eres especial y esencial en mi vida. ¡Te amo!

A todos mis compañeros del equipo de natación UCV Máster por las experiencias vividas y que con sus locuras me han hecho reír como nunca. En especial a la mejor entrenadora y amiga que existe en el mundo Celia Palencia. Gracias por existir. ¡Son lo máximo, los quiero un montón!

A mis amigos Keith Contreras, Reina Pérez, Lennies Guevara, Robersy Hernández, María Vargas, Diana Rodríguez, Raúl Rodríguez, Efraín Aristimuño, César Briceño, Sergio Cabrales, Jorge Jarohue y Eduardo Morante quienes me acompañaron durante la carrera. Gracias por todo el apoyo brindado. ¡Éxito para ustedes!

A la Universidad Central de Venezuela por abrirme las puertas y hacer de mí un ser integral. Fue en ella donde pase los mejores momentos de mi vida. Gracias por llenarme de tan hermosos recuerdos.

A los profesores de la Escuela de Ingeniería de Petróleo quienes con su esfuerzo y dedicación nos apoyaron durante nuestra carrera, en especial a la profesora Evelyn Azuaje, gracias por todo el apoyo que me brindaste. ¡Un millón de gracias por toda su ayuda!

A mi tutor académico el profesor Alexis Gammiero, gracias por brindarme la oportunidad de realizar este Trabajo Especial de Grado y por todo el apoyo que me brindaste durante su desarrollo. Estoy enormemente agradecida por todo. ¡Gracias por tu apoyo! Te aprecio y valoro mucho.

Barreiro P., Johanna N.

**IMPLEMENTACIÓN DE REDES NEURONALES PARA PREDECIR
PRESIÓN DE MISCIBILIDAD EN LA INYECCIÓN DE DIÓXIDO DE
CARBONO**

**Tutor Académico: Prof. Alexis Gammiero. Tesis. Caracas, U.C.V. Facultad de
Ingeniería. Escuela de Ingeniería de Petróleo. Año 2012. 342p.**

Palabras clave: Miscibilidad, Presión Mínima de Miscibilidad, Dióxido de Carbono, Redes Neuronales Artificiales.

Resumen. La Presión Mínima de Miscibilidad (PMM) es uno de los parámetros claves en el diseño y aplicabilidad de los desplazamientos miscibles cuando se tienen campos que pudieran estar bajo un esquema de inyección de Dióxido de Carbono (CO₂). La presente investigación se llevó a cabo con el propósito de generar una correlación por medio de Redes Neuronales Artificiales (RNA) para predecir la PMM en la inyección de CO₂. Inicialmente, se realizó una documentación sobre los conceptos básicos en desplazamientos miscibles, redes neuronales y las correlaciones asociadas al cálculo de la PMM en la inyección de CO₂ puro e impuro. Posteriormente, se recolectaron datos de artículos técnicos publicados por diversos autores. Se definen los parámetros para desarrollar la correlación como la temperatura del yacimiento, fracción de los componentes volátiles e intermedios presentes en el crudo, peso molecular de la fracción de C₅₊, concentración de CO₂ y de las impurezas presentes en el mismo tales como el N₂, CH₄, C₂-C₄ y H₂S. Para el entrenamiento de la red, se seleccionó la función entrenamiento y transferencia, número de capas ocultas y la tolerancia del error cuadrático medio. Luego se llevó a cabo una fase donde se realizó un análisis de sensibilidad respecto a distintos conjuntos de datos y al número de neuronas en cada capa oculta, con el fin de definir la arquitectura final de la red. Se evaluó la consistencia en la física de los sistemas propuestos, donde el aumento de la temperatura del yacimiento, la fracción de componentes volátiles presentes en el crudo, el peso molecular de la fracción de C₅₊ al igual que la concentración de componentes tales como el N₂ y CH₄ en el gas, influyen en el incremento de la PMM. Un efecto inverso se espera al incrementar la fracción de componentes intermedios en el crudo, la concentración de H₂S y fracción de C₂-C₄ presentes en el gas de inyección. Finalmente, se estableció una comparación entre el error promedio obtenido por la red neuronal propuesta y las ecuaciones de la literatura, donde se encontró que la red neuronal resultó ser más exacta en sus predicciones.

ÍNDICE GENERAL

DEDICATORIA	v
AGRADECIMIENTOS	vi
RESUMEN.....	viii
LISTA DE TABLAS	xiii
LISTA DE FIGURAS	xv
LISTA DE ECUACIONES.....	xix
INTRODUCCIÓN	1
 CAPÍTULO I: PLANTEAMIENTO DEL PROBLEMA	
1.1. PLANTEAMIENTO DEL PROBLEMA	4
1.2. OBJETIVOS DE LA INVESTIGACIÓN.....	5
1.2.1. Objetivo General	5
1.2.2. Objetivos Específicos	5
1.3. ALCANCE.....	5
1.4. JUSTIFICACIÓN	5
 CAPÍTULO II: MARCO TEÓRICO	
2.1. CONCEPTOS BÁSICOS SOBRE MISCIBILIDAD PARA SISTEMAS CRUDO/GAS.....	8
2.1.1. Diagrama Ternario	8
2.1.2. Concepto de Miscibilidad.....	10
2.2. TIPOS DE DESPLAZAMIENTOS MISCIBLES	11
2.2.1. Miscibilidad al Primer Contacto.....	11
2.2.2. Miscibilidad por Múltiples Contactos	12
2.3. MÉTODOS PARA ESTIMAR LA PRESIÓN MÍNIMA DE MISCIBILIDAD.	16

2.3.1. Métodos Experimentales	16
2.3.2. Métodos Analíticos.....	23
2.4. FACTORES QUE AFECTAN LA EFICIENCIA DE DESPLAZAMIENTO	23
2.4.1. Movilidad y Razón de Movilidad.....	23
2.4.2. Adedamiento viscoso	24
2.4.3. Eficiencia de desplazamiento	25
2.4.4. Barrido Vertical	25
2.4.5. Barrido Areal	27
2.5. FACTORES QUE AFECTAN LA MISCIBILIDAD.....	27
2.5.1. Mezcla de fluidos por dispersión.....	27
2.5.2. Composición del Crudo y del Gas.....	30
2.5.3. Presión y Temperatura.....	30
2.6. REDES NEURONALES ARTIFICIALES	32
2.6.1. Definición de una red neuronal artificial.....	33
2.6.2. Características de las Redes Neuronales Artificiales	35
2.6.3. Elementos de una red neuronal artificial	38
2.6.4. Clasificación de las redes neuronales artificiales	42
2.6.5. Algoritmos neuronales	43
2.6.6. Topología de una red neuronal artificial	48
2.6.7. Perceptrón simple	52
2.6.8. Aplicaciones de las redes neuronales artificiales en ingeniería de petróleo.	54
 CAPÍTULO III: MARCO METODOLÓGICO	
3.1. TIPO DE INVESTIGACIÓN	56
3.2. DISEÑO DE LA INVESTIGACIÓN	57
3.3. METODOLOGÍA DE LA INVESTIGACIÓN	57
3.3.1. FASE I: REVISIÓN BIBLIOGRÁFICA	58

3.3.2. FASE II: BASE DE DATOS.....	60
3.3.3. FASE III: REDES NEURONALES.....	61
3.3.4. FASE IV: ARQUITECTURA FINAL DE LA RED NEURONAL	67
3.3.5. FASE V: COMPARACIÓN DE LA CORRELACIÓN GENERADA POR RNA Y LAS CORRELACIONES DE LA LITERATURA	69
3.4. OPERACIONALIZACIÓN DE LOS OBJETIVOS	70
CAPÍTULO IV: ANÁLISIS DE RESULTADOS	
4.1. CORRELACIONES PARA PREDECIR PMM EN LA INYECCIÓN DE CO ₂ PURO E IMPURO	73
4.2. ANÁLISIS ESTADÍSTICO.....	84
4.2.1. Análisis estadístico básico.....	85
4.3. REDES NEURONALES	93
4.3.1. Selección de datos de entrenamiento y prueba.....	93
4.3.2. Preprocesamiento de los datos	94
4.3.3. Entrenamiento de la red neuronal.....	94
4.4. SELECCIÓN DE LA ARQUITECTURA FINAL DE LA RED NEURONAL	103
4.4.1. Selección de la red neuronal.....	104
4.4.2. Validación de la red neuronal.....	114
4.5. COMPARACION DE LAS CORRELACIÓN GENERADA POR RNA Y LAS CORRELACIONES DE LA LITERATURA.....	121
CONCLUSIONES	128
RECOMENDACIONES	130
APÉNDICES	
APÉNDICE A: ESTADÍSTICA BÁSICA	143
APÉNDICE B: HISTOGRAMAS Y DIAGRAMAS DE DISPERSIÓN.....	149

APÉNDICE C: CORRELACIONES PARA PREDECIR PMM EN LA INYECCIÓN DE CO₂ 161

APÉNDICE D: CÓDIGO DE LA RED NEURONAL “*FEEDFORWARD BACKPROPAGATION*” 190

LISTA DE TABLAS

Tabla 3.1:	Operacionalización de los objetivos 1 y 2	71
Tabla 3.2:	Operacionalización del objetivo 3	72
Tabla 4.1:	Resultados estadísticos de los datos	86
Tabla 4.2:	Valores de covarianza entre cada variable	90
Tabla 4.3:	Valores del coeficiente de correlación entre cada variable.....	91
Tabla 4.4:	Parámetros fijos para la fase de optimización de la red	103
Tabla 4.5:	Redes neuronales optimizadas	104
Tabla 4.6:	Rango de aplicación, parámetros de entrenamiento y arquitectura del la red neuronal desarrollada.....	109
Tabla 4.7:	Vector de tendencias o <i>bias</i> de las neuronas en la primera capa oculta	111
Tabla 4.8:	Matriz de pesos entre la capa de entrada y la primera capa oculta	112
Tabla 4.9:	Vector de tendencias o <i>bias</i> de las neuronas en la segunda capa oculta	113
Tabla 4.10:	Matriz de pesos entre la primera capa oculta y la segunda capa oculta	113
Tabla 4.11:	Vector de tendencias o <i>bias</i> de la neurona en la capa de salida	114
Tabla 4.12:	Matriz de pesos entre la segunda capa oculta y la capa de salida	114
Tabla 4.13:	Modelo de selección de datos para la validación de la red neuronal final	115
Tabla 4.14:	Comparación de la correlación obtenida por la red neuronal desarrollada en esta investigación y las correlaciones por redes neuronales de la literatura	122

Tabla 4.15:	Comparación de la correlación obtenida por la red neuronal desarrollada en esta investigación y las correlaciones de la literatura	126
-------------	--	-----

LISTA DE FIGURAS

Figura 2.1:	Diagrama ternario a una presión y temperatura constante	9
Figura 2.2:	Esquema del efecto de la presión sobre la envolvente de fases ...	10
Figura 2.3:	Esquema del proceso de miscibilidad al primer contacto	12
Figura 2.4:	Esquema de un proceso miscible por Vaporización	13
Figura 2.5:	Esquema de un proceso miscible por Condensación	15
Figura 2.6:	Esquema del mecanismo de Tubo Delgado	17
Figura 2.7:	Determinación de la presión mínima de miscibilidad mediante la curva del petróleo recuperado en función de la presión	19
Figura 2.8:	Esquema del aparato de burbuja ascendente	20
Figura 2.9:	Comportamiento de la burbuja para un proceso por condensación	21
Figura 2.10:	Comportamiento de la burbuja para un proceso por vaporización	22
Figura 2.11:	Modelo simplificado de la inestabilidad frontal	24
Figura 2.12:	Regímenes de flujo para un desplazamiento miscible.....	27
Figura 2.13:	Dispersión longitudinal y transversal para una mezcla Crudo/Solvente	28
Figura 2.14:	Dispersión microscópica convectiva	30
Figura 2.15:	Esquema de una red neuronal biológica	34
Figura 2.16:	Comparación entre una neurona artificial y una neurona biológica	35
Figura 2.17:	Esquema de los tipos de capa presentes en una red neuronal	38
Figura 2.18:	Proceso de una red neuronal	40
Figura 2.19:	Funciones transferencia a) <i>Hardlim</i> , b) <i>Hardlims</i>	41

Figura 2.20:	Función transferencia a) lineal y b) mixta	41
Figura 2.21:	Funciones transferencia a) Sigmoidal y b) Tangente Hiperbólica	42
Figura 2.22:	Función transferencia gaussiana	42
Figura 2.23:	Clasificación de las redes neuronales artificiales	43
Figura 2.24:	Dinámica básica de retro propagación de errores	46
Figura 2.25:	Estructura de un sistema basado en redes neuronales	49
Figura 2.26:	Red con propagación hacia adelante o <i>feedforward</i>	50
Figura 2.27:	Red con propagación hacia atrás o <i>feedback</i>	51
Figura 2.28:	Red recurrente	51
Figura 2.29:	Red de Hopfield	52
Figura 2.30:	Perceptrón Simple	53
Figura 3.1:	Esquema de la metodología empleada en la investigación	58
Figura 3.2:	Esquema para el entrenamiento de una red neuronal	61
Figura 3.3:	Diagrama de parámetros a evaluar en la red neuronal	64
Figura 3.4:	(a) RNA con dos capas ocultas.(b) RNA con una capa oculta...	67
Figura 3.5:	Esquema de la fase de optimización de la red neuronal	68
Figura 3.6:	Modelo de gráfica del error relativo porcentual en función del número de neuronas para dos capas ocultas de la red neuronal final	69
Figura 4.1:	Evolución de los precios del petróleo en función del número de proyectos de CO ₂	73
Figura 4.2:	Representación gráfica del año de las correlaciones para predecir la presión mínima de miscibilidad en la inyección de CO ₂	75

Figura 4.3:	Representación gráfica del origen de la correlación para predecir la presión mínima de miscibilidad en la inyección de CO ₂	76
Figura 4.4:	Representación gráfica del tipo de correlación para predecir la presión mínima de miscibilidad en la inyección de CO ₂	77
Figura 4.5:	Representación gráfica del tipo de correlación evaluada en función del tiempo	78
Figura 4.6:	Representación gráfica del tipo de gas usado en las correlaciones para predecir la presión mínima de miscibilidad en la inyección de CO ₂	79
Figura 4.7:	Representación grafica del porcentaje de correlaciones según el tipo de gas en función del tiempo.....	80
Figura 4.8:	Representación grafica de los parámetros usados en las correlaciones para predecir la presión mínima de miscibilidad en la inyección de CO ₂	81
Figura 4.9:	Representación gráfica de las impurezas usadas en las correlaciones para predecir la presión mínima de miscibilidad en la inyección de CO ₂	83
Figura 4.10:	Gráfica del error relativo porcentual de prueba en función del error cuadrático medio y el número de neuronas para una capa oculta	97
Figura 4.11:	Caso <i>a</i>) Rendimiento de la red para la función de entrenamiento <i>trainscg</i> . Caso <i>b</i>) Rendimiento de la red para la función de entrenamiento <i>trainlm</i>	98
Figura 4.12:	Gráfica del error relativo porcentual de prueba en función del número de neuronas y la función transferencia	100
Figura 4.13:	Gráfica del error relativo porcentual de prueba en función del número de neuronas para dos capas ocultas	102

Figura 4.14:	Gráfica del error relativo porcentual de prueba en función del número de neuronas para dos capas ocultas de la red neuronal optimizada	106
Figura 4.15:	PMM estimada en función de la PMM teórica para la prueba de la red	107
Figura 4.16:	PMM estimada en función de la PMM teórica para el entrenamiento de la red	107
Figura 4.17:	Gráfica del error cuadrático medio en función del número de épocas de la red neuronal	108
Figura 4.18:	Arquitectura final de la Red Neuronal para predecir la PMM en la inyección de CO ₂	110
Figura 4.19:	Gráfica de la predicción de la Presión Mínima de Miscibilidad en función de la temperatura del yacimiento	116
Figura 4.20:	Gráfica de la predicción de la Presión Mínima de Miscibilidad en función de la fracción de los componentes volátiles	117
Figura 4.21:	Gráfica de la predicción de la Presión Mínima de Miscibilidad en función de la fracción de los componentes intermedios	118
Figura 4.22:	Gráfica de la predicción de la Presión Mínima de Miscibilidad en función del peso molecular de la fracción de C ₅₊	119
Figura 4.23:	Gráfica de la predicción de la Presión Mínima de Miscibilidad en función de la concentración de contaminantes presentes en el gas de inyección	120

LISTA DE ECUACIONES

Ecuación 2.1:	Razón de movilidad	23
Ecuación 2.2:	Entrada neta en cada unidad de la red neuronal	39
Ecuación 2.3:	Valor de la salida de la red neuronal	39
Ecuación 2.4:	Regla de aprendizaje por corrección de error	44
Ecuación 2.5:	Variación en el peso de la conexión entre las neuronas i y j ..	44
Ecuación 2.6:	Error global cometido en el proceso de entrenamiento	45
Ecuación 2.7:	Variación de los pesos en el aprendizaje Delta	45
Ecuación 2.8:	Salida de la red neuronal (Perceptrón simple)	53
Ecuación 2.9:	Función activación de las neuronas de salida (Perceptrón simple)	53
Ecuación 3.1:	Normalización de los datos	61
Ecuación 3.2:	Error cuadrático medio	64
Ecuación 4.1:	Ecuación matricial que representa la red neuronal	110

INTRODUCCIÓN

Durante las dos últimas décadas la inyección de Dióxido de Carbono (CO_2) ha demostrado ser un método efectivo en la recuperación mejorada de crudos livianos y medianos. Por otra parte, el cambio climático es un problema de proporciones globales y una de sus causas está relacionada a la emisión de gases del efecto invernadero tales como el CO_2 . Los puntos mencionados previamente hacen que para crudos livianos y medianos, la inyección de CO_2 sea uno de los principales métodos de recuperación mejorada y lo cual se refleja en una diversidad de aplicaciones a nivel mundial de este proceso con el fin de incrementar la producción del crudo y reducir las emisiones de dicho gas.

El comportamiento de fases de los sistemas CO_2 /crudo ha sido investigado ampliamente desde los años 60. Aunque su mayor auge ocurrió a finales de los años 70 y principio de los 80 con el aumento de los precios del petróleo y el inicio de muchos proyectos de inyección de CO_2 . Estudios para entender el desarrollo y la predicción de la presión de miscibilidad para la inyección de CO_2 puro e impuro se han venido desarrollando en los últimos 30 años.

En los procesos de inyección de gases se puede lograr la disminución de la saturación residual del petróleo al obtener condiciones miscibles donde la tensión interfacial entre el gas y el crudo se hacen igual a cero, formándose una fase homogénea sin la existencia de una interfase entre ellos. De esta forma se logran vencer las fuerzas capilares que retienen al crudo en el medio poroso.

Un concepto importante asociado con la inyección de CO_2 es la Presión Mínima de Miscibilidad (PMM). A esta presión, se puede alcanzar las condiciones miscibles y el desplazamiento del crudo llega a ser eficiente. Existen dos tipos de desplazamientos miscibles: la miscibilidad al primer contacto, cuando un hidrocarburo de peso molecular intermedio como propano, butano o cualquier Gas Licuado del Petróleo (GLP) se pone en contacto con el crudo y se mezclan en todas sus proporciones

formando una sola fase entre ellos, o la miscibilidad por múltiples contactos cuando el petróleo y el gas inyectado como nitrógeno, dióxido de carbono y gas natural no entran en equilibrio inmediatamente, requieren de una transferencia de componentes hidrocarburos entre ambos fluidos. Esta transferencia de masa puede ocurrir mediante el enriquecimiento del gas a través de la vaporización de las fracciones intermedias del crudo (Miscibilidad por vaporización) o mediante el enriquecimiento del crudo a través de la condensación de las fracciones intermedias del gas rico (Miscibilidad por condensación).

Cuando se inicia un proyecto de recuperación mejorada por inyección de CO₂, deben tomarse en cuenta ciertos factores que afectan la miscibilidad como la presión, temperatura del yacimiento, composición del crudo y gas de inyección. Este último factor depende de la fuente del CO₂, ya sea natural o de plantas de proceso, y de la cantidad de contaminantes como N₂, CH₄, H₂S y de las fracciones de C₂ - C₅ presentes. También la composición del crudo es un parámetro de gran importancia, ya que en la inyección de CO₂ ocurre miscibilidad por vaporización y la cantidad de componentes intermedios presentes en el petróleo controlan el proceso de transferencia de masa hacia el gas.

La PMM se puede estimar por medio de pruebas experimentales como el método de Tubo Delgado (*Slim Tube*) o Burbuja Ascendente (*Rising Bubble*), así como también por medio de modelos analíticos tales como correlaciones matemáticas y gráficas. El método de tubo delgado es una de las técnicas más utilizadas y aceptadas en la industria petrolera. Sin embargo, para la misma se requiere de largos tiempos de ensayos y costos elevados. Debido a esto, un gran número de correlaciones se han desarrollado utilizando como base los datos obtenidos por pruebas de tubo delgado. Un enfoque alternativo para generar correlaciones en la predicción de la PMM es la aplicación de Redes Neuronales Artificiales (RNA). Las RNA son herramientas para el modelado de sistemas complejos que han sido utilizadas ampliamente en la solución de problemas en la industria petrolera asociados a programas de perforación, completación, evaluación de formaciones, producción, geología, geofísica, ingeniería

de yacimientos y en el análisis económico del mercado petrolero. Sin embargo, existen pocas aplicaciones de esta herramienta y con escasa información en la predicción de la PMM.

Para el desarrollo de este Trabajo Especial de Grado (TEG) se ha dividido la investigación en cuatro capítulos. En el Capítulo I se plantea el problema a resolver, justificación, objetivo general, objetivos específicos y alcance de esta investigación. El Capítulo II corresponde al Marco Teórico que consta de una revisión bibliográfica que abarca los conceptos sobre desplazamientos miscibles y redes neuronales artificiales. El capítulo III comprende el marco metodológico donde se muestra detalladamente las actividades realizadas en esta investigación para alcanzar los objetivos propuestos. El Capítulo IV muestra los resultados obtenidos y su análisis en la comparación de los resultados arrojados por el sistema y los valores que se obtienen de correlaciones publicadas en la literatura. Finalmente, se muestran las conclusiones y recomendaciones de esta investigación.

CAPÍTULO I

En este capítulo se plantea la problemática a resolver durante el desarrollo de la investigación y las razones por las cuales se realiza la misma. Se plantea el objetivo general y los objetivos específicos con el fin de establecer las metas a cumplir en el presente Trabajo Especial de Grado.

1.1. PLANTEAMIENTO DEL PROBLEMA

La principal preocupación con las técnicas estadísticas convencionales tales como regresiones lineales, son las dificultades en la satisfacción de muchas suposiciones rígidas que son esenciales para justificar su aplicación como el tamaño de la muestra, linealidad y continuidad. Una alternativa basada en la teoría de la inteligencia artificial son las Redes Neuronales Artificiales (RNA), que pueden considerarse como modelos de cálculo caracterizados por algoritmos muy eficientes y a su vez han demostrado ser más eficaces que los métodos estadísticos convencionales en el reconocimiento de patrones, problemas de clasificación y ajuste de funciones.

Por otra parte, se han desarrollado pocas investigaciones acerca de la implementación de redes neuronales en la predicción de la presión mínima de miscibilidad para la inyección de CO₂. Además, existen restricciones en la construcción de estos modelos, ya que no se reporta en cada uno de los trabajos previos, la arquitectura o parámetros necesarios que permiten implementar la misma, tales como el número de capas ocultas y neuronas respectivas, además de los pesos y el *bias* de la red neuronal. Es por esto que surge el principal problema de esta investigación.

El presente Trabajo Especial de Grado plantea la necesidad de generar correlaciones con redes neuronales que permitan predecir la presión de mínima miscibilidad en la inyección de dióxido de carbono.

1.2. OBJETIVOS DE LA INVESTIGACIÓN

1.2.1. Objetivo General

Generar correlaciones con redes neuronales para la predicción de la presión mínima de miscibilidad en la inyección de dióxido de carbono.

1.2.2. Objetivos Específicos

1. Realizar una revisión bibliográfica de las correlaciones existentes para predecir presión mínima de miscibilidad con dióxido de carbono puro e impuro.
2. Generar correlaciones con redes neuronales artificiales para predecir la presión mínima de miscibilidad en la inyección de CO₂.
3. Establecer una comparación entre las correlaciones matemáticas ya existentes y el valor predicho por medio de la herramienta computacional.

1.3. ALCANCE

El desarrollo de esta investigación permitirá implementar las redes neuronales como una herramienta de gran utilidad para predecir la presión mínima de miscibilidad en desplazamientos miscibles con CO₂. Por otra parte, puede ayudar a los ingenieros de petróleo en la toma de decisiones en proyectos de recuperación mejorada que involucre este tipo de desplazamiento.

1.4. JUSTIFICACIÓN

Entre los procesos de desplazamientos miscibles, la inyección de CO₂ es uno de los métodos más atractivos, debido a su menor costo y su alta eficiencia de desplazamiento. La presión mínima de miscibilidad es uno de los parámetros más críticos en los procesos de recuperación que estén bajo un esquema de inyección de

CO₂. Una predicción de la misma con poca precisión puede traer severas consecuencias en los proyectos.

Los métodos experimentales como la prueba de tubo delgado utilizada para predecir la presión mínima de miscibilidad, requieren de grandes costos y tiempo. Debido a este, un gran número de correlaciones matemáticas han sido desarrolladas por varios autores con datos arrojados por esta prueba.

Las redes neuronales han sido utilizadas ampliamente en la solución de problemas en la industria petrolera asociados a programas de perforación, completación, evaluación de formaciones, producción, geología, geofísica, ingeniería de yacimientos y en el análisis económico del mercado petrolero con mucho éxito. Se ha demostrado que con el uso de esta herramienta, se pueden obtener resultados más razonables y con mayor precisión que aquellos obtenidos por modelos estadísticos en la predicción de la presión mínima de miscibilidad. Mientras la precisión del modelo en la predicción aumente, el mismo podría ayudar a identificar los niveles de operación deseados para procesos miscibles.

Existen pocos trabajos acerca de redes neuronales para predecir la presión mínima de miscibilidad. Huang et al. (2003) desarrolló por primera vez un modelo por RNA para predecir la PMM en la inyección de CO₂ puro e impuro, donde evaluó el impacto del peso molecular de la fracción de C₅₊, la temperatura del yacimiento, concentración de volátiles (CH₄, N₂) e intermedios (C₂ – C₄) y la concentración de contaminantes (N₂, CH₄, H₂S y SO₂). Igualmente, existen estudios más recientes implementando redes neuronales, tal es el caso de Mousavi et al. (2006) que hacen un híbrido entre un Algoritmo Genético (AG) y una red neuronal, Askbari y Kasiri (2010) desarrollan una red universal para predecir la presión mínima de miscibilidad con CO₂ puro e impuro y gases hidrocarburos, y el estudio más reciente realizado por Nezhad et al. (2011). Tanto Nezhad et al. (2011) y Mousavi et al. (2006) evalúan parámetros muy similares a los utilizados en la investigación de Huang et al. (2003), a diferencia de Askbari y Kasiri (2010) que emplea un método conocido como regla de mezclado

para reducir la dimensión de las variables de entrada ya que debe tomar en cuenta una gran cantidad de las mismas por el tipo de red que desarrolla. Sin embargo, para estos modelos no se reportan los parámetros de la red que permiten implementar la misma.

CAPÍTULO II

MARCO TEÓRICO

Este capítulo consta de una revisión bibliográfica que abarca los conceptos básicos sobre desplazamientos miscibles, tipos de desplazamiento, métodos para estimar Presión Mínima de Miscibilidad (PMM) y los factores que afectan la misma. Igualmente, se define lo referente a Redes Neuronales Artificiales (RNA) tales como sus características, elementos, clasificación y algoritmos de aprendizaje, todo esto con el fin de tener una base teórica para el desarrollo de esta investigación.

2.1. CONCEPTOS BÁSICOS SOBRE MISCIBILIDAD PARA SISTEMAS CRUDO/GAS

2.1.1. Diagrama Ternario

Un diagrama ternario se utiliza en el análisis de los desplazamientos miscibles para determinar si dos mezclas son miscibles al primer contacto o múltiples contactos (Curtis y Brule, 2000). El comportamiento de fases para una mezcla a una temperatura y presión constante se representa en un diagrama ternario como se muestra en la Figura 2.1. Cada vértice del triángulo representa un componente (o pseudocomponente) y corresponde a los livianos como el metano (CH_4) y el nitrógeno (N_2), los intermedios que comprenden dióxido de carbono (CO_2), sulfuro de hidrógeno (H_2S) y componentes desde el etano hasta el propano ($\text{C}_2\text{--C}_5$) y finalmente el heptano y las fracciones más pesadas (C_{7+}) que conforman los componentes pesados.

Cuando dos fluidos de composiciones diferentes son mezclados, la conexión por medio de una línea entre ambos es el resultado de la mezcla. Para el caso de las mezclas binarias son representadas por líneas que conectan dos esquinas como es el caso del punto D de la Figura 2.1, mientras que las mezclas de tres componentes se

encuentran en algún lugar dentro del diagrama como el caso del punto M y las proporciones de cada uno de los componentes se miden respecto a las esquinas. La composición es usualmente medida en términos de fracción molar o porcentaje molar.

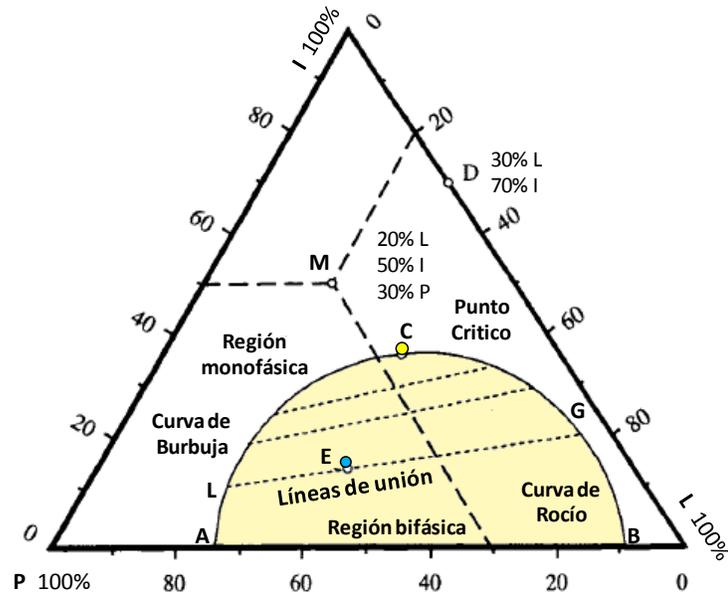


Figura 2.1. Diagrama ternario a una presión y temperatura constante (Danesh, 1998)

En la Figura 2.1 se muestra una zona que delimita una región de dos fases conocida como envolvente de fases y se define por la curva ACB. Para la mezcla E que se encuentre dentro de esta región forma una fase de gas G y una de líquido L en equilibrio, donde la línea LG que conecta ambas fases líquido/gas es conocida como la línea de unión o *tie line*. Igualmente, la curva AC ubicada en la parte izquierda de la envolvente representa el líquido saturado, mientras que la curva CB del lado derecho representa el gas saturado, lo que corresponde a la curva de burbuja y curva de rocío respectivamente. Estas últimas, convergen en un punto conocido como el punto crítico C, donde las propiedades intensivas del gas y el líquido llegan a ser iguales, mientras que la tangente que pasa por dicho punto es conocida como la línea de unión crítica y determina la condición límite de miscibilidad. Igualmente, se muestra una zona fuera de la envolvente de fases donde cualquier mezcla a una

condición de presión y temperatura corresponde a un fluido monofásico subsaturado. La región correspondiente a la fase gaseosa se encuentra sobre la curva de rocío, mientras que la fase líquida se ubica en la parte izquierda de la curva de burbuja. De esta manera, la envolvente de fases permite delimitar en el diagrama ternario la región bifásica y monofásica de una determinada mezcla.

En la Figura 2.2 se muestra como la presión y la temperatura influyen directamente en el tamaño de la región bifásica. Generalmente a medida que aumenta la presión la envolvente de fases disminuye y viceversa.

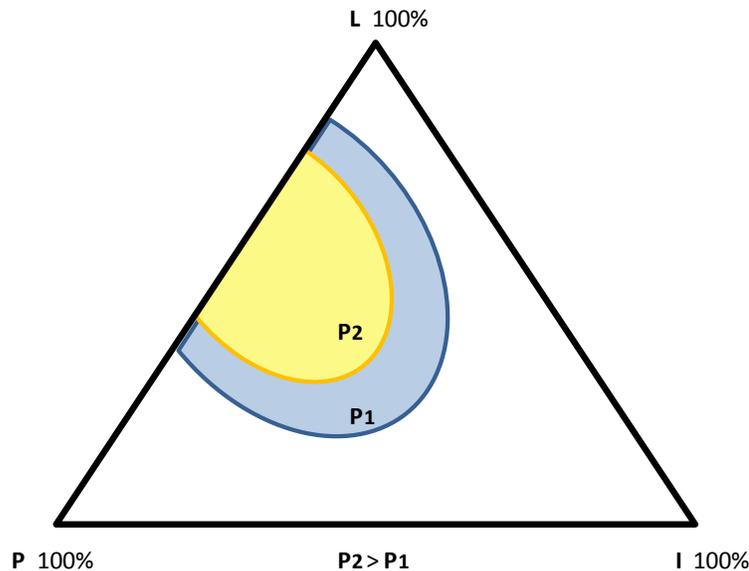


Figura 2.2. Esquema del efecto de la presión sobre la envolvente de fases (Marín, 2002)

2.1.2. Concepto de Miscibilidad

La miscibilidad es referida a aquellos desplazamientos donde dos fluidos al entrar en contacto pueden formar una sola fase al ser mezclados en cualquier proporción. Para yacimientos de petróleo, la miscibilidad es definida como la condición física entre dos o más fluidos que permitan una mezcla en cualquier proporción sin la existencia de una interfase (Holm, 1986). Para el caso de los desplazamientos miscibles la

tensión interfacial entre el crudo y el fluido desplazante debe ser igual a cero y lograr así vencer las fuerzas capilares que retienen al crudo en el medio poroso. Cabe destacar que la tensión interfacial es la cantidad de energía por unidad de área (Dinas/cm^2) necesaria para formar una interfase. A medida que esta se reduce se disminuye la saturación residual de crudo en el medio poroso.

Los procesos miscibles son aplicados en yacimientos donde la presión de operación sea mayor a la presión mínima de miscibilidad, de lo contrario si las presiones están por debajo de esta, resulta un desplazamiento inmisible y como consecuencia se tiene bajos recobros (Elsharkawy, 1992).

2.2. TIPOS DE DESPLAZAMIENTOS MISCIBLES

Existen básicamente dos tipos de desplazamientos miscibles. La miscibilidad al primer contacto, lo cual ocurre cuando un hidrocarburo de peso molecular intermedio se pone en contacto con el crudo y se mezclan en todas sus proporciones formando una sola fase entre ellos, o la miscibilidad por múltiples contactos cuando el petróleo y el fluido inyectado no entran en equilibrio inmediatamente, es decir, requieren una transferencia de componentes hidrocarburos entre el fluido inyectado y el petróleo bajo condiciones dinámicas (Holm, 1986). A continuación se explica a detalle el proceso para cada tipo de desplazamiento miscible.

2.2.1. Miscibilidad al Primer Contacto

La miscibilidad al primer contacto es el método más simple y rápido para obtener un desplazamiento miscible entre el crudo y el solvente. Esta condición de miscibilidad ocurre cuando el fluido inyectado de peso molecular intermedio, ya sea propano, butano o cualquier Gas Licuado del Petróleo (GLP), se pone en contacto con el crudo y se mezclan en todas sus proporciones formando una sola fase entre ellos.

En la Figura 2.3 se muestra el proceso de miscibilidad al primer contacto, donde se inyecta un gas compuesto solo por el componente I. Se puede observar que el mismo es miscible cuando entra en contacto con el Crudo B, a diferencia del Gas A donde no puede ser alcanzada dicha condición de miscibilidad. Sin embargo, podría llegar a ser miscible si se aumenta la presión del sistema para reducir la envolvente de fases o enriqueciendo el componente A hasta A', pero estos últimos resultan ser muy costosos y por lo tanto lo hace un proceso no aplicable a nivel de campo. Finalmente, dos fluidos son miscibles al primer contacto cuando la línea de unión entre ambos componentes no pasa a través de la región bifásica del diagrama ternario.

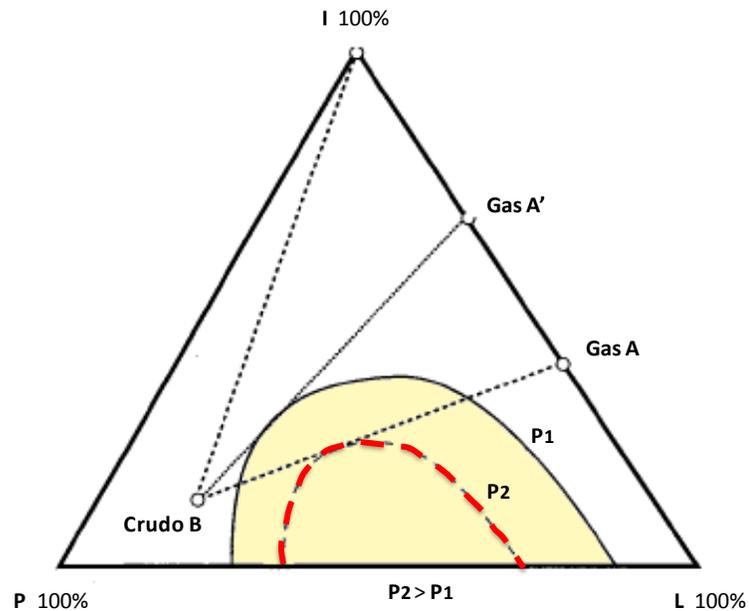


Figura 2.3. Esquema del proceso de miscibilidad al primer contacto (Danesh, 1998)

2.2.2. Miscibilidad por Múltiples Contactos

Cuando un gas no es miscible al primer contacto, se puede lograr la miscibilidad mediante múltiples contactos a través de la transferencia de masa entre el petróleo y el fluido de inyección que puede ser dióxido de carbono, nitrógeno o gas natural. Para el caso del CO₂, se puede lograr la miscibilidad por un proceso de múltiples

contactos que vaporizan o extraen hidrocarburos del crudo presente en el yacimiento. Este gas de inyección extrae más hidrocarburos que el gas natural, gases de combustión o el nitrógeno, que principalmente toman componentes desde C_2 hasta C_5 . Según Holm (1982) cuando ciertas presiones son alcanzadas, el CO_2 inyectado es enriquecido con hidrocarburos desde el C_5 al C_{20} formando así una unidad eficiente de desplazamiento que permite la producción del crudo a través de un proceso miscible.

La transferencia de masa entre ambos fluidos puede ocurrir mediante el enriquecimiento del gas a través de la vaporización de las fracciones intermedias presentes en el crudo. Este proceso es conocido como *Miscibilidad por Vaporización*.

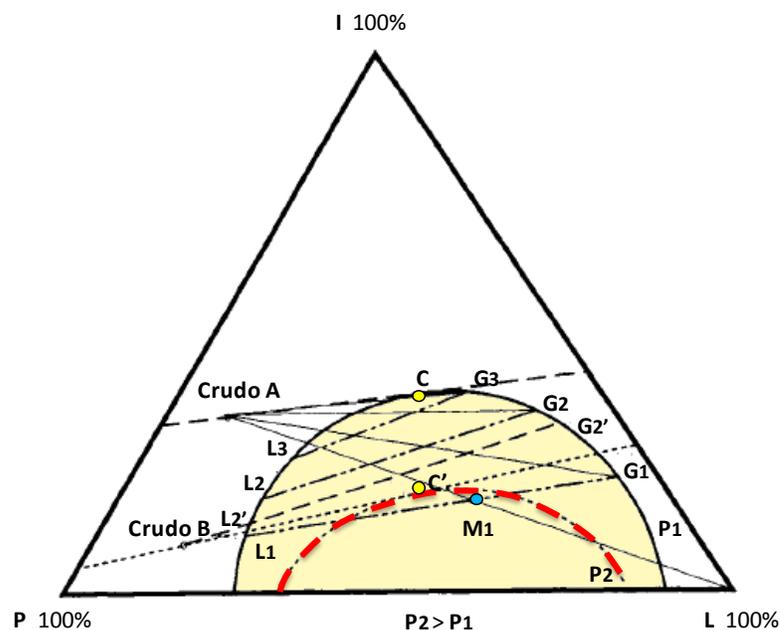


Figura 2.4. Esquema de un proceso miscible por Vaporización (Danesh, 1998)

En la Figura 2.4 se muestra el proceso de miscibilidad por vaporización, donde el gas de inyección L comprendido por un fluido ligero después del contacto con el crudo A forma dos fases equilibradas, una de líquido L_1 y una de gas G_1 , que resultan en una mezcla M_1 . Esta fase G_1 es el gas original L después de haber recogido algunas

fracciones intermedias y pesadas del crudo. Posteriormente, la fase G_1 avanza hasta formar nuevos contactos con el petróleo fresco y progresivamente es enriquecido de componentes intermedios como se observa en G_2 y G_3 . Finalmente, el desplazamiento comienza cuando el gas se vuelve miscible con el crudo en el punto C, es decir, cuando la línea de unión coincide con la línea de unión limitante y la extensión de la misma pasa a través del punto crítico y de la composición del crudo A. Sin embargo, este gas inyectado no lograría la miscibilidad por múltiples contactos con el Crudo B, el enriquecimiento del gas se limita por la línea de unión $G_2' L_2'$, ya que al ser extendida la misma pasará a través del Crudo B. La miscibilidad por vaporización para el Crudo B puede ser alcanzada aumentando la presión de P_1 a P_2 a una temperatura constante para disminuir la envolvente de fases y lograr la miscibilidad. Finalmente, se tiene que la miscibilidad en el proceso de vaporización, es controlada por la composición del crudo más no por el gas de inyección.

Cuando la composición del gas no logra la miscibilidad al primer contacto o el proceso de vaporización está totalmente controlado por el crudo, se puede alcanzar la miscibilidad por múltiples contactos mediante la inyección de un gas rico, donde sus fracciones intermedias son transferidas al crudo. Este proceso se conoce como *Miscibilidad por Condensación*. En este proceso la miscibilidad es alcanzada en el punto de inyección del fluido del diagrama ternario, gradualmente la composición del crudo va variando luego de contactarlo, desde la original hasta composición crítica para iniciar el desplazamiento.

En la Figura 2.5 se muestra el proceso de miscibilidad por condensación, donde el gas rico A forma dos fases, una de gas G_1 y una de crudo L_1 en equilibrio después del contacto con el petróleo en el yacimiento. La fase gaseosa se va movilizandoy deja al crudo enriquecido L_1 atrás para luego hacer contacto con el gas fresco A, lo que resulta en un petróleo más rico en componentes intermedios como se muestra en L_2 . Este proceso continua hasta que el crudo es lo suficientemente enriquecido para alcanzar la composición crítica en el punto C, donde la línea de unión limitante se vuelve la línea de unión crítica y logra la miscibilidad. La presión a la cual la

extensión de la línea de unión crítica pasa a través de la composición del gas, es la presión mínima necesaria para lograr la miscibilidad. Cabe destacar que el nivel de enriquecimiento en el cual la extensión de la línea de unión crítica pasa a través de la composición del gas inyectado se conoce como *Enriquecimiento Mínimo de Miscibilidad (EMM)*.

A diferencia del gas A, el gas de inyección B, que posee menos cantidad de componentes intermedios, no logra la miscibilidad a la presión P_1 y el enriquecimiento del crudo es limitado a la composición a la que llega la extensión de la línea de unión del Gas B con el crudo. Sin embargo, la miscibilidad puede ser alcanzada aumentando la presión a P_2 para disminuir la envolvente de fases. Finalmente, la miscibilidad en el proceso de condensación, es controlada por la composición del gas de inyección más no por la composición original del crudo.

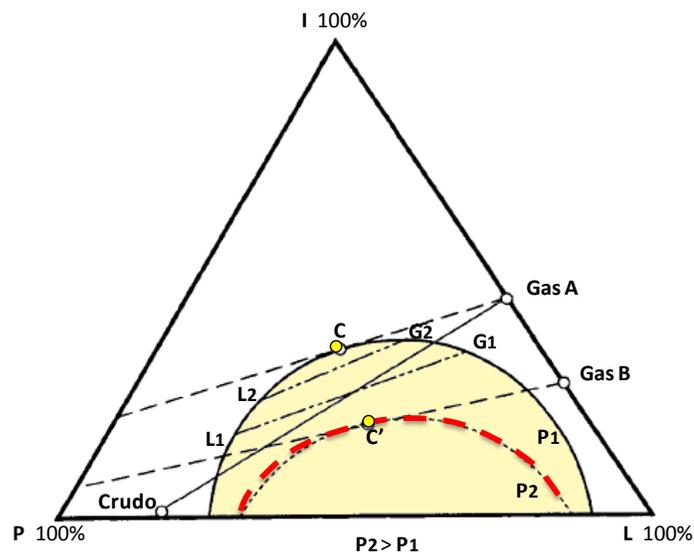


Figura 2.5. Esquema de un proceso miscible por Condensación (Danesh, 1998)

Igualmente, se puede desarrollar una combinación entre el proceso de vaporización y condensación para lograr la miscibilidad. Así como ocurre en el proceso de condensación donde los componentes intermedios del gas condensado son

transferidos al crudo, sucede con los componentes intermedios del crudo que se vaporizan en la fase gaseosa. Puede ser que con esta combinación la miscibilidad no sea lograda, sin embargo, el proceso puede resultar en una saturación de petróleo residual baja (Elsharkawy, 1992).

2.3. MÉTODOS PARA ESTIMAR LA PRESIÓN MÍNIMA DE MISCIBILIDAD

Entre los métodos que existen para estimar la presión mínima de miscibilidad se encuentran las pruebas de laboratorio tales como el método de tubo delgado y burbuja ascendente, además de los métodos analíticos como correlaciones matemáticas y gráficas. Ambos se explican con más detalle a continuación.

2.3.1. Métodos Experimentales

(a) Tubo Delgado o *Slim Tube*

El tubo delgado o *Slim Tube* es un mecanismo que proporciona información acerca del comportamiento de fases en procesos de inyección de gas, adicionalmente a la presión o enriquecimiento mínimo de miscibilidad.

En la figura 2.6 se muestra un esquema de la configuración básica de un sistema de tubo delgado. La mayoría consisten en tubos de 0,25 pulgadas de diámetro y de 25 a 75 pies de tubería flexible llenos de granos de arena o vidrio uniformes, que se encuentran alojados en un recipiente a temperatura constante (Curtis y Brule, 2000). El diámetro de la tubería es un parámetro importante, se usan tubos delgados para minimizar el adedamiento viscoso y los efectos de pared a lo largo del tubo. Igualmente, el diámetro máximo de grano debe ser menor que 1/10 del diámetro interno del tubo para evitar los efectos de pared, de lo contrario la porosidad será mayor cerca de la pared y el flujo tendrá lugar preferentemente por esta región (Danesh, 1998).

Al inicio de cada prueba, el tubo delgado limpio se satura con petróleo con la ayuda de una bomba de alta presión, luego el gas se inyecta a una tasa constante a través del tubo. El resultado final deseado en un experimento de tubo delgado es la recuperación de crudo a una presión determinada, por lo tanto la caída de presión que ocurre en el tubo debe ser pequeña y la misma es controlada mediante un regulador colocado aguas abajo para mantenerla constante a la salida del tubo. Si se tiene una permeabilidad alta, la caída de presión es baja mientras que se opera a una velocidad de desplazamiento frontal alta. Posteriormente, la bureta recibe el petróleo producido para controlar dicha producción, seguido de un cromatógrafo de gas que se configura para determinar la composición del gas producido antes de pasar por el medidor del mismo.

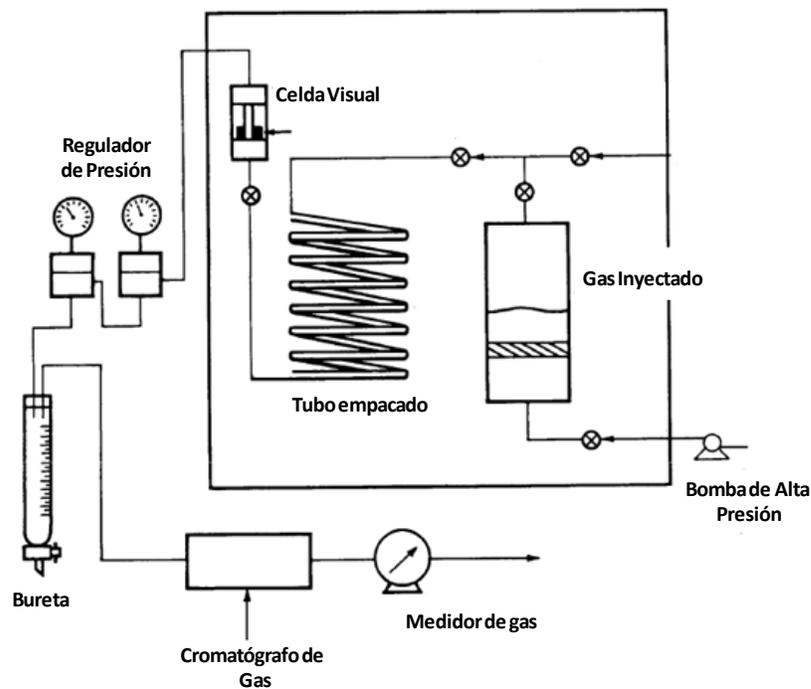


Figura 2.6. Esquema del mecanismo de Tubo Delgado (Kovarik, 1985)

Las condiciones de miscibilidad se determinan llevando a cabo el desplazamiento a varias presiones o inyectando el gas en distintos niveles de enriquecimiento y

monitoreando el recobro del crudo. También puede ser ayudado por la observación del flujo a través de una celda visual colocada en la salida del tubo aguas abajo, donde los datos visuales pueden reflejar si existe todavía la interfase del fluido proveniente del tubo delgado (Elsharkawy, 1992). El logro de la miscibilidad ocurre por un cambio gradual del color del fluido en la zona de transición, que va desde un color oscuro, pasando por rojo, naranja, hasta un fluido amarillento o claro. Sin embargo, si se observan dos fases y que hay un volumen de burbujas considerable, probablemente el desplazamiento es inmisible.

En otros casos, se define la condición de miscibilidad a la presión cuando la recuperación del petróleo es de 90 por ciento o mayor en el momento donde el gas inyectado es 1,2 veces el volumen poroso (VP) (Wu y Batycky, 2006). Para el caso de un sistema CO₂/Crudo, Holm y Josendal (1980) usan una definición para dicha condición que requiere de un 94 por ciento de recobro en una relación Gas-Petróleo (RGP) de 40000 PCN/BN, esto ocurre aproximadamente cuando el volumen de gas inyectado es 1,1 a 1,3 veces el volumen poroso.

Los desplazamientos llevados a cabo por el método de tubo delgado no simulan el proceso real que ocurre en el yacimiento. Por lo tanto, los recobros de este último no son los mismos que los obtenidos por el método experimental. El desplazamiento en un yacimiento depende de ciertos factores como el adedamiento viscoso, heterogeneidad del yacimiento, segregación gravitacional y dispersión física que son imposibles de simular en un tubo delgado, ya que no cuenta con un criterio, diseño y procedimiento operacional.

En la Figura 2.7 se muestra una gráfica del petróleo recuperado en función de la presión de desplazamiento para dos gases tipo, donde se puede observar que la curva comienza a aplanarse cuando el desplazamiento se encuentra cerca de la condición de miscibilidad. Dependiendo del tipo de desplazamiento, la temperatura, el gas inyectado y otros factores, hacen que el cambio desde la inmiscibilidad hasta la miscibilidad sea abrupto o gradual (Curtis y Brule, 2000).

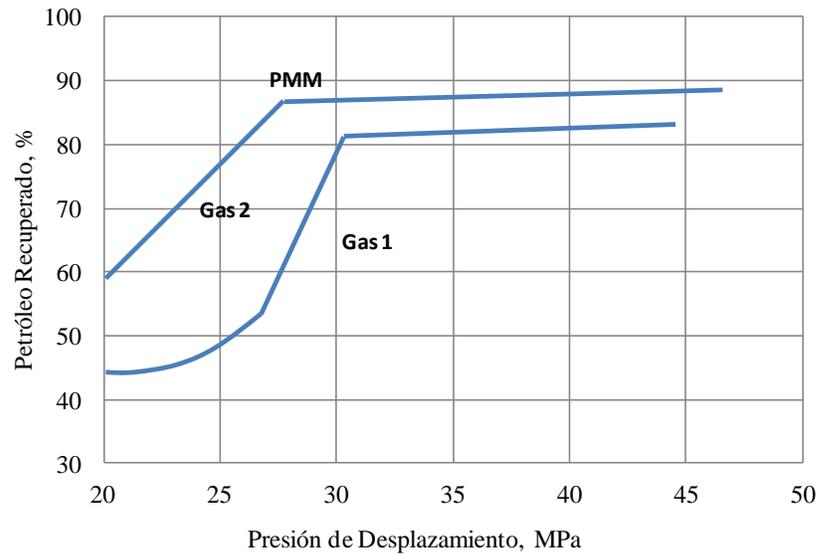


Figura 2.7. Determinación de la presión mínima de miscibilidad mediante la curva del petróleo recuperado en función de la presión (Curtis y Brule, 2000)

(b) Burbuja Ascendente o *Rising Bubble*

El método de la Burbuja Ascendente o *Rising Bubble* fue desarrollado por Christiansen and Kim en el año 1986. A diferencia del método de tubo delgado, este permite una observación directa del comportamiento de fases en procesos de inyección de gas y requiere menos de dos horas para determinar la PMM con menor consumo de petróleo y gas.

En la Figura 2.8 se muestra un esquema del aparato implementado en dicho proceso. Este mecanismo consta de un tubo de vidrio plano colocado verticalmente donde la sección interna rectangular del tubo es de 0,04 pulgadas por 0,20 pulgadas (1x5 mm) y la sección visible es alrededor de 8 pulgadas (20 cm). En la parte inferior de la celda visual hay una aguja para la inyección de la burbuja de gas que controla su tamaño dependiendo del diámetro. Además, el aparato cuenta con una cámara de video que registra los cambios de forma y movimientos de la burbuja mientras asciende. Puede operar hasta 300°F y presiones hasta 5000 psi (Elsharkawy, 1992).

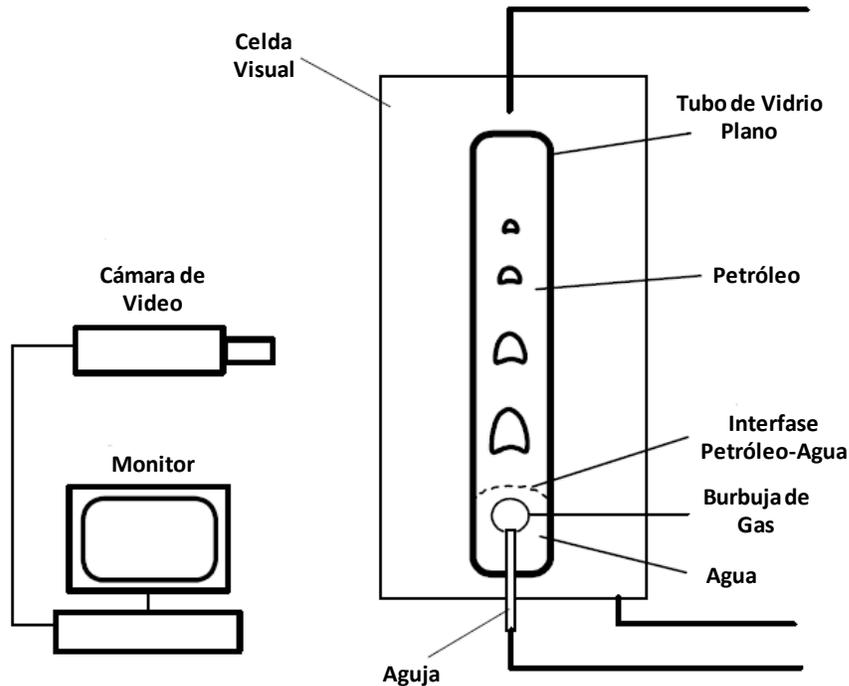


Figura 2.8. Esquema del aparato de Burbuja Ascendente (Dong et al, 2000)

Para llevar a cabo la prueba, una pequeña burbuja de gas se introduce en la parte inferior del tubo a través de la fase acuosa (agua destilada). La burbuja de gas realiza un viaje de ascenso a través del tubo manteniendo el contacto con el petróleo y la misma es monitoreada en su movimiento ascendente hasta alcanzar la miscibilidad dependiendo de la presión de prueba. Cabe destacar que para este mecanismo se realizan una serie de pruebas a diferentes presiones, de esta manera se observa el comportamiento de la burbuja para distintas condiciones.

La miscibilidad es determinada por el cambio en la forma de la burbuja a medida que asciende a través del crudo. A presiones muy por debajo de la PMM, la burbuja conserva su forma casi esférica, pero su tamaño es reducido ya que el gas se disuelve parcialmente en el crudo. Cuando está ligeramente por encima o en la PMM, la burbuja desarrolla en su parte inferior una cresta ondulada con la interfase gas/petróleo que va desapareciendo desde el fondo de la burbuja. En cambio, para

presiones superiores a la PMM, la burbuja se dispersa rápidamente en el crudo sin la aparición de una interfase.

En la Figura 2.9 se muestra el comportamiento de la burbuja para un proceso por condensación. Para el caso a) se observa que al inyectar la burbuja de gas su forma inicial indica una tensión interfacial baja en el primer contacto con el petróleo, sin embargo, después de subir un tramo corto a través del crudo la forma de la burbuja nos demuestra lo contrario. En cambio a medida que se aumenta la presión, la fase inicial de la burbuja se observa más degradada e incluso al ir ascendiendo a través del tubo la misma se dispersa como se demuestra en el caso c).

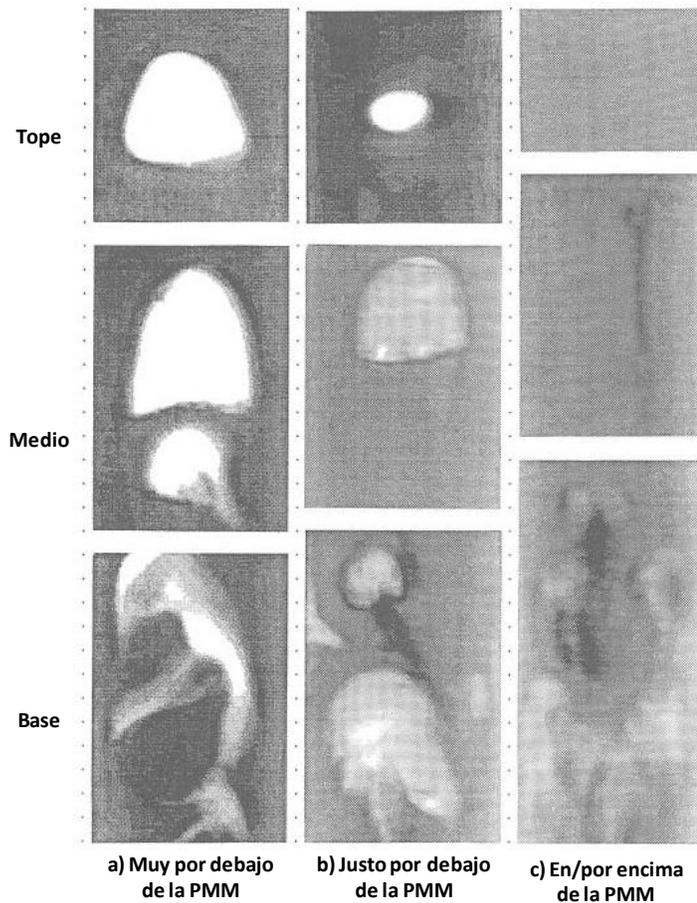


Figura 2.9. Comportamiento de la burbuja para un proceso por condensación (Elsharkawy, 1992)

En la Figura 2.10 se muestra el comportamiento de la burbuja para un proceso por vaporización. Para el caso a) se observa la evolución de su forma para presiones por debajo de la PMM y se muestra que la burbuja ira progresando de una forma esférica a elipsoidal y tapa elipsoidal a medida que la tensión interfacial va disminuyendo. En cambio al ir aumentado la presión del sistema, la burbuja se dispersa con mayor facilidad tal como se muestra en el caso b).

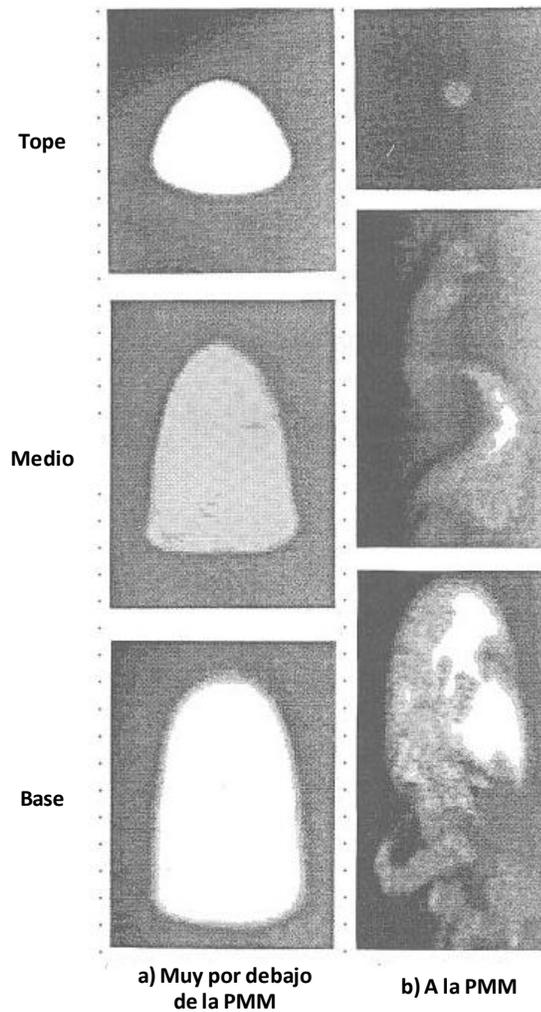


Figura 2.10. Comportamiento de la burbuja para un proceso por vaporización (Elsharkawy, 1992)

2.3.2. Métodos Analíticos

Los métodos analíticos comprenden correlaciones matemáticas y gráficas publicadas en la literatura que son comúnmente utilizadas para predecir de una forma rápida y sencilla la presión mínima de miscibilidad en desplazamientos miscibles. Existen correlaciones para calcular la presión mínima de miscibilidad en la inyección de CO₂ puro, impuro o ambos. Estas se pueden observar con más detalle en el Apéndice C.

2.4. FACTORES QUE AFECTAN LA EFICIENCIA DE DESPLAZAMIENTO

2.4.1. Movilidad y Razón de Movilidad

La movilidad se define como la relación entre la permeabilidad efectiva y la viscosidad de un fluido determinado. Cuando un fluido desplaza a otro, la razón de movilidad se expresa como la relación entre el fluido desplazante sobre el desplazado y es uno de los parámetros más importantes en un desplazamiento miscible ya que tiene gran influencia en el barrido volumétrico. Esta relación se puede representar por medio de la ecuación 2.1:

$$M = \frac{K_d / \mu_d}{K_D / \mu_D} \quad 2.1$$

Donde:

K_d : Permeabilidad efectiva al fluido desplazante

μ_d : Viscosidad del fluido desplazante

K_D : Permeabilidad efectiva al fluido desplazado

μ_D : Viscosidad del fluido desplazado

En la mayoría de los desplazamientos miscibles el movimiento del frente no es solo afectado por la razón de movilidad, sino también por las movilidades de otras zonas que se encuentran detrás y adelante del frente, al igual que por el tamaño relativo de

las diferentes regiones de flujo. Por lo tanto, la movilidad de un fluido es la facilidad con la cual este se desplaza en el yacimiento

2.4.2. Adedamiento viscoso

Para condiciones donde la relación de movilidad es menor o igual a uno ($M \leq 1$), el frente de desplazamiento es estable y el crudo es eficientemente desplazado y no penetra en el petróleo excepto por dispersión. En cambio, si la razón de movilidad es mayor a uno ($M > 1$), el frente de desplazamiento se hace inestable y una región del mismo avanza a mayor velocidad que las regiones adyacentes, de esta manera se desarrollan múltiples canales de gas entre el crudo debido a la diferencia de las fuerzas viscosas entre los fluidos. Este fenómeno se conoce como adedamiento viscoso y dichos canales traen como consecuencia la irrupción temprana del fluido inyectado y bajo recobro del crudo.

En la Figura 2.11 se muestra un modelo simplificado de inestabilidad frontal, donde se observa que el solvente desplaza linealmente al crudo que se encuentra inicialmente en el medio poroso. En este caso la relación de movilidad es exactamente la relación entre la viscosidad del crudo y el solvente. Mientras no exista heterogeneidad en el yacimiento, el frente se mantiene plano a lo largo del desplazamiento, pero si existe una región que sea más permeable en el frente que su alrededor, este se desplazara preferencialmente hacia esa zona más rápido originando una pequeña región que sobresale una distancia (ϵ) o un canal de gas (Stalkup, 1983).

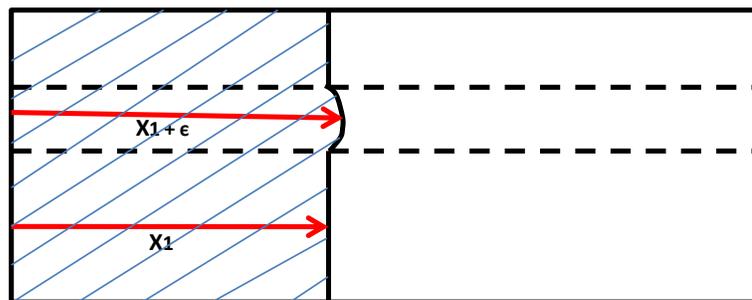


Figura 2.11. Modelo simplificado de la inestabilidad frontal (Stalkup, 1983)

2.4.3. Eficiencia de desplazamiento

La *eficiencia de desplazamiento macroscópica* o volumétrica es una medida de la eficiencia con la cual los fluidos se desplazan en el yacimiento en un sentido volumétrico, es decir, cuan efectivo es el desplazamiento del fluido contactado en un yacimiento tanto areal como vertical. Esta eficiencia es regida por las heterogeneidades en el yacimiento, los patrones de flujo, además de las diferencias en las propiedades del fluido inyectado y el crudo.

A diferencia de este último desplazamiento, la *eficiencia de desplazamiento microscópica* se refiere a la movilización del crudo a escala de poro y es medida por la saturación de petróleo inicial S_{oi} y la saturación de petróleo residual S_o en las regiones de contacto con el fluido. Este tipo de desplazamiento puede ser afectado por la presión, temperatura, composición del crudo y pureza del CO_2 en caso de ser el fluido inyectado (Stalkup, 1983).

2.4.4. Barrido Vertical

El barrido vertical en desplazamientos miscibles es influenciado principalmente por la gravedad y la permeabilidad. La diferencia de densidad entre el fluido inyectado y el crudo es la principal consecuencia del barrido vertical, ya que el gas inyectado puede segregar y no desplaza al crudo presente en el yacimiento, resultando desfavorable en el desplazamiento. Por lo general los solventes son menos densos que el crudo o el agua, aunque el CO_2 puede ser más denso que algunos crudos dependiendo de la temperatura y la presión del yacimiento.

La segregación gravitacional ocurre cuando existe una diferencia entre la densidad del solvente inyectado y el crudo del yacimiento, tal es el caso de la diferencia que hay entre el crudo y los gases que son menos densos que otros solventes. Igualmente, los valores bajos en la relación entre las fuerzas viscosas y gravitacionales ($R_{v/g}$) traen como consecuencia que el desplazamiento horizontal sea inestable y que la eficiencia de barrido areal disminuya creando un efecto conocido como *gravity tongue* tal como

se muestra en el caso a) de la Figura 2.12. Este efecto puede provocar una irrupción temprana del gas disminuyendo la recuperación del crudo. Sin embargo, la segregación gravitacional puede ser perjudicial o beneficiosa para el éxito de un proceso de inyección. Tal es el caso de los yacimientos que presentan cierto buzamiento, donde la segregación gravitacional puede ser usada como una ventaja para mejorar el barrido y el recobro del crudo (Stalkup, 1983).

Por otra parte, los valores altos de las fuerzas viscosas respecto a las gravitacionales y la razón de movilidad desfavorable, afectan en gran medida el barrido y cobertura areal por la canalización del solvente, es decir, el desplazamiento va siendo dominado por múltiples canales de gas en la sección transversal tal como se muestra en el caso b) y c) de la Figura 2.12. Finalmente, tanto la heterogeneidad del yacimiento, la relación de las fuerzas viscosas y gravitacionales, además de la relación de movilidad, afectan el potencial y distribución de las líneas de flujo.

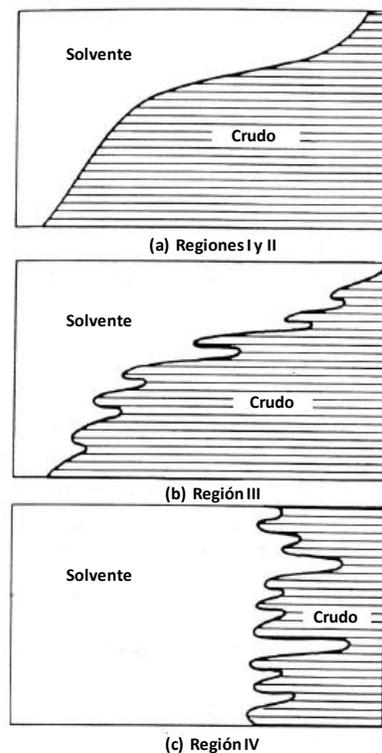


Figura 2.12. Regímenes de flujo para un desplazamiento miscible (Stalkup, 1983)

Una razón de movilidad desfavorable en desplazamientos miscibles puede empeorar la tendencia de los fluidos inyectados a entrar en los estratos más permeables. Esto ocurre para el caso de los yacimientos estratificados donde el fluido inyectado se desplaza preferencialmente hacia el estrato de mayor permeabilidad, lo que trae como consecuencia la irrupción del solvente en los pozos productores antes que otros estratos de permeabilidad más baja sean barridos completamente. Finalmente, cuando la relación entre la permeabilidad vertical y horizontal es mayor que uno, el barrido vertical es mayor de lo que sería en el caso de una permeabilidad isotrópica ya que la restricción en la permeabilidad vertical retarda la segregación del solvente.

2.4.5. Barrido Areal

Es la fracción de área que ha sido invadida por el fluido inyectado. El barrido areal está afectado por el grado en que se mezcla este último con el crudo, geometría del arreglo de los pozos, razón de movilidad y heterogeneidad del yacimiento.

2.5. FACTORES QUE AFECTAN LA MISCIBILIDAD

2.5.1. Mezcla de fluidos por dispersión

La dispersión física es un fenómeno responsable de la transferencia de masa entre el crudo y el gas de inyección. En un medio poroso pueden existir dos tipos de dispersión: longitudinal donde se mezcla en la dirección de flujo y transversal donde se mezcla en la dirección perpendicular al flujo.

En la Figura 2.13 se muestra la dispersión longitudinal y transversal para una mezcla Crudo/Solvente en un modelo bidimensional con dos capas de arena, donde el solvente es inyectado por la parte izquierda del modelo. Para este caso, se observa que la capa superior es más permeable que la capa inferior y por lo tanto el solvente penetra mayormente en ella. A su vez, se observa que la mezcla no ocurre únicamente

por dispersión longitudinal en la dirección del flujo, también se mezcla con el crudo transversalmente en la capa menos permeable.

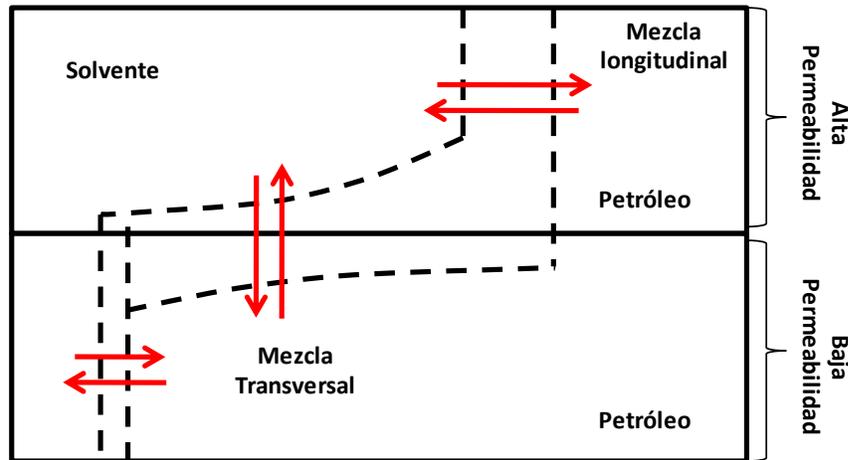


Figura 2.13. Dispersión longitudinal y transversal para una mezcla Crudo/Solvente (Stalkup, 1983)

En la mayoría de los desplazamientos miscibles no estabilizados por gravedad, la dispersión transversal juega un papel más importante que la dispersión longitudinal, ya que en muchos desplazamientos los canales exponen una gran superficie a lo largo del medio poroso, afectando también el crecimiento del adedamiento viscoso y el barrido. A diferencia de la dispersión transversal, la dispersión longitudinal ocurre únicamente en el extremo de los canales. Sin embargo, ambos tipos de dispersión pueden influenciar fuertemente un desplazamiento miscible. A su vez, la mezcla por dicho fenómeno también modera la diferencia de viscosidad y densidad entre el crudo y el solvente, pero en algunas situaciones estos contrastes entre la viscosidad y la densidad pueden alterar el comportamiento del flujo significativamente.

Existen tres mecanismos que contribuyen a la mezcla de los fluidos miscibles: difusión molecular, dispersión por convección microscópica y macroscópica. La *difusión molecular* es el resultado del movimiento aleatorio de las moléculas de una zona de mayor concentración a una de menor concentración. La *dispersión por convección microscópica* es el resultado de las trayectorias de flujo causadas por

heterogeneidades rocosas pequeñas, en cambio la *dispersión por convección macroscópica* ocurre en las trayectorias de flujo causados por heterogeneidad en la permeabilidad (Stalkup, 1983).

En la Figura 2.14 se muestra un ejemplo de difusión molecular, donde las líneas de flujo uno, dos y tres siguen un camino tortuoso a través del medio poroso a pesar que la dirección promedio de flujo es en la dirección central. Suponiendo diferentes concentraciones en los fluidos que pasan a lo largo de cada línea de flujo, las concentraciones asociadas a las líneas uno y dos entran en el poro A, donde a través de la difusión molecular se igualan las concentraciones del solvente. Posteriormente, esta concentración fluye por la línea dos alterando su composición para luego mezclarse con la línea tres en el poro C y nuevamente igualar las concentraciones. De esta manera continua la mezcla de las líneas del flujo a través del medio poroso.

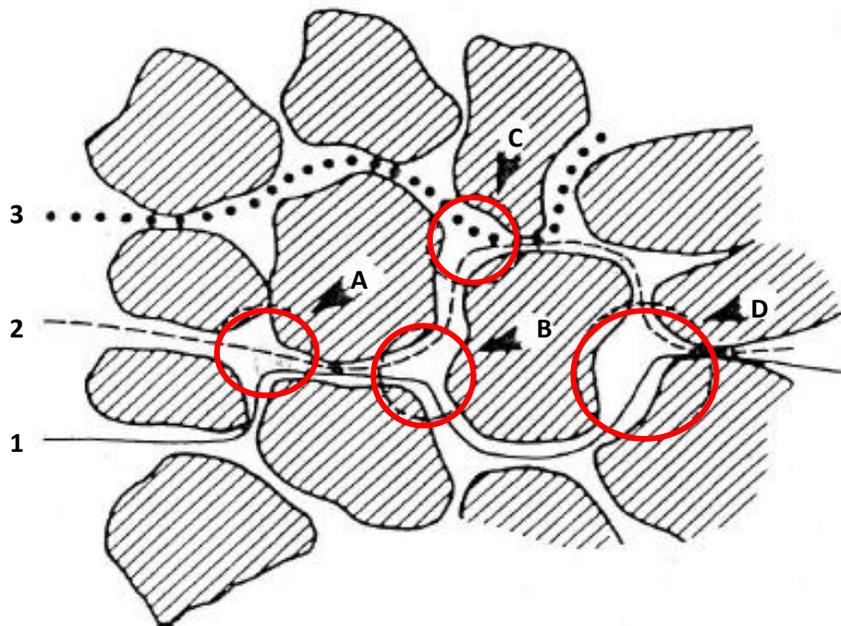


Figura 2.14. Dispersión microscópica convectiva (Stalkup, 1983)

2.5.2. Composición del Crudo y del Gas

La presión mínima de miscibilidad para el proceso de vaporización es controlada por la composición del crudo. El tamaño de la región bifásica dependerá de las altas concentraciones de hidrocarburos de peso molecular intermedio desde el C₂ hasta el C₅ presentes en el crudo y de las fracciones de hidrocarburos más pesadas. Por lo tanto, un aumento de la fracción de componentes pesados y la disminución de la gravedad API, resulta en una región bifásica más grande y en consecuencia se requiere una presión más alta para alcanzar la condición de miscibilidad, ya que la cantidad de componentes extraíbles es mucho menor. Para un proceso de condensación, la presión y la concentración requerida del gas de inyección depende de la composición del crudo, de los componentes intermedios contenidos en el gas rico y de la temperatura. Por lo tanto, la composición del crudo y la composición del gas son factores importantes que afectan un proceso miscible.

Holm y Josendal (1987) según estudios experimentales usando como fluido de inyección el CO₂, llegaron a la conclusión que la presión mínima de miscibilidad es proporcional a la cantidad total de hidrocarburos de C₅ a C₃₀ presentes en el crudo. A su vez, la PMM aumenta cuando existe un mayor porcentaje de fracciones volátiles en el crudo como el metano, mientras que decrece con el aumento de las fracciones más pesadas de los componentes intermedios desde el C₂ hasta el C₄. A diferencia de Holm y Josendal (1986), Stalkup (1983) indica un aumento de la PMM a medida que la gravedad API es más baja o incrementan las fracciones más pesadas del crudo.

2.5.3. Presión y Temperatura

La presión y temperatura son variables que afectan la miscibilidad en una mezcla gas/crudo. Cuando se tienen altas presiones la solubilidad y la densidad del gas aumenta, lo que permite que el proceso de transferencia de masa se vea favorecido para lograr el desplazamiento miscible. Igualmente, a medida que la presión aumenta la región bifásica en un diagrama ternario es reducida y es posible lograr el

desplazamiento miscible. El caso contrario ocurre para un gas hidrocarburo pobre, donde la PMM aumenta con el incremento de la temperatura, ya que la solubilidad de los gases es menor y a su vez hace que la región bifásica incremente su tamaño. Finalmente, ambos parámetros son indispensables en el análisis de los desplazamientos miscibles.

2.6. REDES NEURONALES ARTIFICIALES

Diversos estudios han sido desarrollados para problemas en ciencia e ingeniería que implican la extracción de información a partir de datos complejos e inciertos. Para muchos de estos casos, las aproximaciones tradicionales no resultaron ser la mejor opción y es por esto que las Redes Neuronales Artificiales (RNA) fueron implementadas en la solución de este tipo de problemas.

El primero en estudiar el cerebro desde el punto de vista computacional fue Alan Turing en 1936. Sin embargo, los pioneros para la construcción de modelos matemáticos que imitasen el comportamiento de las neuronas biológicas fueron Warren McCulloch y Walter Pitts, neurofísico y matemático respectivamente, que presentaron en 1943 uno de los primeros modelos abstractos de una neurona artificial. Luego en el año 1949, Donald Hebb propuso una técnica de entrenamiento para redes neuronales artificiales (RNA).

A partir de estos estudios, Frank Rosenblatt (1958) desarrolló un modelo sencillo conocido como perceptrón o perceptrón simple que tenía la capacidad de reconocer patrones. Sin embargo, la limitación de este tipo de red es que solo resolvía una limitada clase de problemas. Posteriormente, Bernard Widrow y Ted Hoff (1960) desarrollaron un nuevo algoritmo de aprendizaje con una capacidad y estructura similar al perceptrón de Rosenblatt, pero ambos modelos coincidieron en la misma limitación.

Para la década de los 60 el interés en las RNA disminuyó debido a la falta de ideas y computadoras aptas para experimentar con esta herramienta. Sin embargo, durante los 80 ambos impedimentos fueron superados y nuevos estudios fueron desarrollados para esta época. Es por esto que para el año 1982, John Hopfield desarrolló una red monocapa basada en los modelos de redes de McCulloch y Pitts. Posteriormente, Teuvo Kohonen (1984) desarrolló redes basadas en el aprendizaje competitivo, donde las unidades aprendieron a representar patrones de entrada similares. Finalmente para esta década de los 80, fue descubierto por varios autores un algoritmo de

entrenamiento para redes multicapa, pero el estudio que mayor influencia tuvo fue el publicado por David Rumelhart y James McClelland, donde desarrollaron un algoritmo de aprendizaje supervisado conocido como *Backpropagation* que permitía una solución poderosa en la construcción de RNA más complejas y evitar problemas desarrollados en el aprendizaje del perceptrón simple.

2.6.1. Definición de una red neuronal artificial

La definición de RNA más aceptada entre las personas que trabajan en este campo se debe a Robert Hetch-Nielsen (1988), donde define una red neuronal artificial como un sistema de computación constituido por un gran número de elementos simples de procesamiento muy interconectados, que procesan información por medio de su estado dinámico como respuesta a entradas externas. También, Kohonen (1988) (citado en Flórez y Fernández, 2008) definió que las redes neuronales artificiales son redes interconectadas masivamente en paralelo de elementos simples y con organización jerárquica, las cuales intentan interactuar con los objetos del mundo real del mismo modo que lo hace el sistema nervioso biológico. Por lo tanto, las redes neuronales artificiales pueden considerarse como modelos de cálculo caracterizados por algoritmos muy eficientes que operan de forma masivamente paralela y permiten desarrollar tareas cognitivas como el aprendizaje de patrones, la clasificación o la optimización.

Las redes neuronales artificiales son modelos que tratan de simular el comportamiento del cerebro humano y se caracterizan por el aprendizaje a través de la experiencia y la extracción de conocimiento genérico a partir de un conjunto de datos.

El cerebro humano está formado por unos cien mil millones de elementos conectados llamados neuronas. Las neuronas tienen tres componentes principales: las dendritas, el cuerpo celular y el axón como se muestra en la Figura 2.15. Las dendritas son ramificaciones fibrosas que transportan las señales eléctricas en el cuerpo celular y

reciben señales de entrada procedentes de otras neuronas. El axón es una única fibra larga que lleva la señal desde el cuerpo celular hacia otras neuronas y para transmitir la información, dicho axón se conecta a través de sus ramificaciones con las dendritas de otras neuronas que reciben las señales y las combinan para producir nuevas salidas. El punto de contacto entre las dendritas y el axón de una neurona es llamado sinapsis y este determina la fuerza y tipo de relación entre ellas. Cabe destacar que la sinapsis es unidireccional, es decir, la información fluye siempre en un único sentido.

Finalmente, desde el punto de vista funcional, las neuronas constituyen procesadores de información sencillos integrados por un canal de recepción de información (dendritas), un órgano de cómputo (núcleo) y un canal de salida (axón).

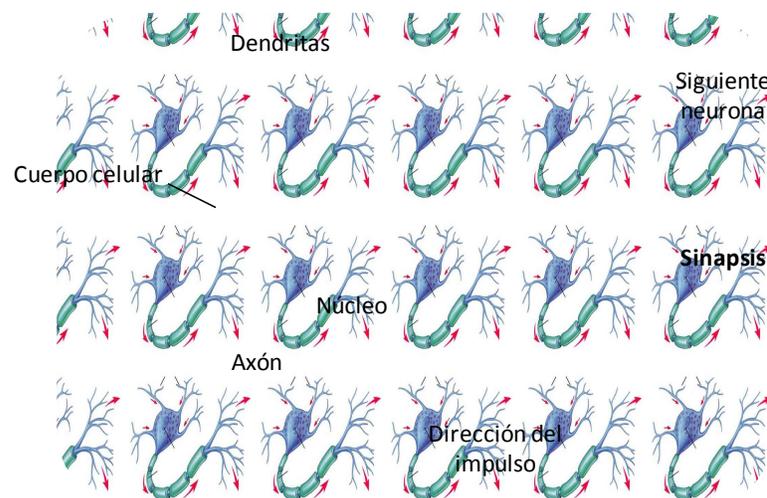


Figura 2.15. Esquema de una red neuronal biológica (<http://www.ibiblio.org>)

Las redes neuronales artificiales no se acercan a la complejidad del cerebro humano. Sin embargo, existen ciertas semejanzas entre lo biológico y lo artificial tal como se muestra en la Figura 2.16 donde se observa una analogía entre una neurona artificial y una biológica.

A través de las dendritas, las entradas X_i representan las señales que provienen de otras neuronas, que a su vez están conectadas a las salidas de otras neuronas por

medio de la sinapsis. La sinapsis, altera la efectividad con la que la señal es transmitida a través de un parámetro conocido como peso sináptico (w_i). Los pesos sinápticos equivalen en la neurona biológica a los mecanismos que existen en la misma para transmitir la señal, amplían o atenúan el valor del estímulo por el cual es multiplicado, posteriormente se combinan con la función transferencia que nos dará el nivel de potencial de la neurona para que luego se transmita la información a lo largo de la red. La salida de la función de red es evaluada en la función de activación que da lugar a la salida de la unidad de proceso.

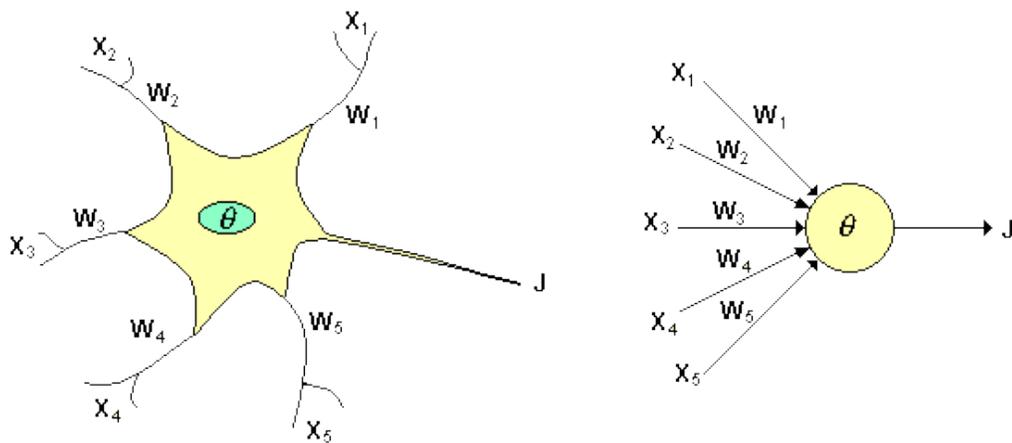


Figura 2.16. Comparación entre una neurona artificial y una neurona biológica
(<http://proton.ucting.udg.mx>).

2.6.2. Características de las Redes Neuronales Artificiales

Las conexiones entre las redes neuronales permiten la interacción con el mundo real tratando de emular al sistema nervioso biológico. A diferencia de la computación tradicional, un sistema basado en neuronas permite desarrollar sistemas que resuelvan problemas complejos. Esto se puede lograr tomando en cuenta ciertas propiedades que suelen resultar fundamentales en la resolución de determinados problemas como:

(a) Procesamiento en paralelo

El procesamiento distribuido en paralelo es una teoría sobre el aprendizaje que propone una explicación a la adquisición del conocimiento, basado en procesos neuronales que tienen lugar en el cerebro. La información no se procesa únicamente en forma secuencial sino simultáneamente en un extenso conjunto de redes neuronales. Esto ocurre debido a que el conocimiento se encuentra distribuido en diferentes neuronas, es decir, todas las neuronas aprenden distintos rasgos de los patrones que fueron presentados y cada una de ellas se encarga de calcular una función elemental sin necesidad de cooperar con las demás.

(b) Memoria distribuida

En un sistema convencional de computación la información está en posiciones de memoria bien definidas, en cambio en las RNA la información se encuentra distribuida por la sinapsis de la red, es decir, un dato no se encuentra en un único sitio sino repartido a lo largo de toda la estructura. Por lo tanto, se redundancia para evitar pérdida de información al resultar dañada la comunicación entre neuronas.

(c) Aprendizaje adaptativo

El aprendizaje adaptativo es una de las características más importantes y atractivas de este tipo de herramientas, ya que pueden tener cierto comportamiento en función de un entrenamiento con una serie de ejemplos ilustrativos o parámetros específicos.

Las redes neuronales se consideran sistemas dinámicos auto-adaptativos. Son adaptables debido a la capacidad de autoajuste de los elementos de procesamiento (neuronas) que componen el sistema y finalmente son dinámicos, ya que son capaces de estar constantemente cambiando para adaptarse a las nuevas condiciones de trabajo y a los datos que se le va proporcionando.

(d) Auto-organización

La auto-organización consiste en la modificación de toda la red neuronal con el propósito de llevar a cabo un objetivo específico. Este término quiere decir generalización y por lo tanto una red debe ser capaz de responder a datos o a situaciones que no ha experimentado antes, pero que puede inferir en base su entrenamiento. La auto-organización es una característica muy útil cuando la información de entrada no es muy clara o la misma esta especificada de forma incompleta.

(e) Tolerancia a fallas

Las redes neuronales poseen una alta capacidad de tolerancia a fallas, puede ser con respecto a los datos (distorsión, ruido o datos incompletos) o tener fallas con respecto a la estructura. En los sistemas computacionales tradicionales, cuando estos tienen errores de memoria pierden parte de su funcionalidad, además de almacenar la información en espacios únicos localizados. A diferencia de estos sistemas tradicionales, las redes neuronales no sufren una caída repentina de la misma si llegan a tener fallas en algunas de sus neuronas por alto el grado de redundancia con que trabajan.

(f) Operación en tiempo real

Las redes neuronales pueden realizar procesos con datos de forma muy rápida y es una de las características que se busca en muchas áreas de aplicación. A pesar de que las redes sean adaptables a distintas condiciones, para que puedan operar de manera rápida, la necesidad en el cambio de los pesos entre las conexiones debe ser mínima.

2.6.3. Elementos de una red neuronal artificial

(a) Neurona Artificial

La distribución de las neuronas dentro de la red depende de los niveles o números de capas que contenga tal como se muestra en la Figura 2.17, donde cada nodo o neurona únicamente está conectada con neuronas de un nivel superior. Comúnmente una neurona, aunque con muchas entradas, no es suficiente y por lo tanto se necesitan una serie de ellas que funcionen en paralelo en una capa o nivel, cuyas entradas provienen de otra capa de neuronas y cuyas salidas se dirigen al mismo destino. Las neuronas se encuentran interconectadas entre sí formando diferentes topologías para resolver distintos problemas. Una RNA típica tiene tres tipos de neuronas:

- **Neuronas de entrada:** se encuentran en la capa de entrada y reciben la información de fuentes externas a la propia red.
- **Neuronas ocultas:** sus señales permanecen dentro de la red, no tienen ninguna relación directa con la información de entrada ni con la de salida. Este tipo de neuronas pueden formar una o más capas ocultas.
- **Neuronas de salida:** ofrecen señales o información fuera de la red dando respuesta al sistema una vez que se haya procesado la información.

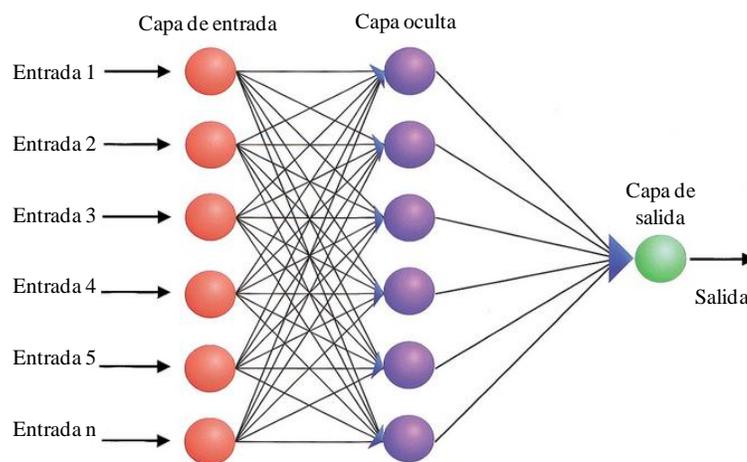


Figura 2.17. Esquema de los tipos de capas presentes en una red neuronal (<http://iticsoftware.com>)

En la Figura 2.18 se ilustra un esquema del proceso que se lleva a cabo en una red neuronal, donde se puede observar que la misma cuenta con cierta cantidad de parámetros de entrada ($x_0, x_1 \dots x_n$) que provienen del exterior o de otras neuronas. A su vez, cuenta con una salida que transmite la información al exterior de la red o a otras neuronas. La señal de salida se calculará en función de las entradas, para lo cual cada una de ellas es afectada por una ganancia o peso que determina la fuerza de la conexión, conocido como *peso sináptico* ($w_0, w_1 \dots w_n$). Estos pesos pueden ser positivos (excitatorios) o negativos (inhibitorios) y van cambiando libremente en función del tiempo y en cada una de las neuronas que se encuentran en la red, es decir, estos pesos no tienen un valor constante, sino que van variando en función de un determinado algoritmo hasta que adoptan un valor constante. Esto se conoce como regla de aprendizaje y es de gran importancia, ya que el conocimiento de la red estará en dichos pesos.

Posteriormente, el nodo realiza una suma de todas las señales de entrada multiplicadas por los pesos y luego el resultado es evaluado por la función transferencia para generar la salida de la red. La entrada neta en cada unidad del sistema viene representada por la suma de los pesos, multiplicado por los parámetros de entrada ($x_0, x_1 \dots x_n$), resultando en la Ecuación 2.2:

$$X_{neta} = \sum_{i=1}^n w_i \times x_i \quad 2.2$$

Luego que se ha calculado la activación del nodo, el valor de la salida sería:

$$y_i = f_i(X_{neta}) \quad 2.3$$

Donde f_i viene siendo la función activación para esa capa y depende de la función que sea utilizada para transformar la entrada X_{neta} en un valor de salida y_i .

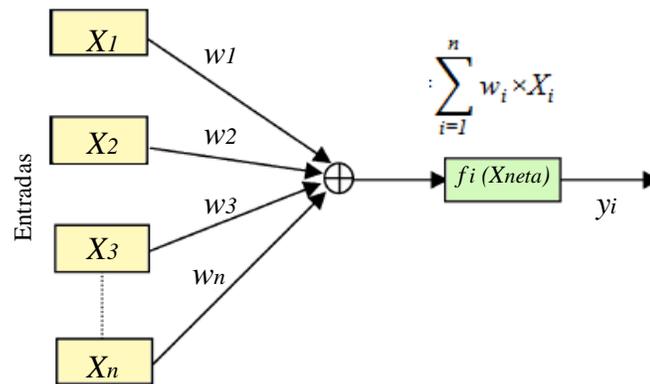


Figura 2.18. Proceso de una red neuronal (Huang et al, 2003)

(b) Función transferencia

Además de los pesos y las conexiones, cada neurona tiene asociada una función matemática denominada función transferencia. Dicha función genera la señal de salida de la neurona a partir de las señales de entrada.

Entre las funciones más utilizadas en los distintos tipos de neuronas tenemos:

- Función Escalón o *Heaviside*
- Función Identidad o Lineal
- Función Sigmoidal
- Función Gaussiana
- Función Tangente Hiperbólica

La función escalón o también conocida como *Heaviside* se asocia a neuronas binarias en donde la salida de la misma solo se activa cuando dicho estado de activación es mayor o igual que el umbral de la neurona, tal como se muestra en el caso a) de la Figura 2.19 donde la función lleva la salida de la red a cero si el argumento es menor que cero o la lleva a uno si argumento es mayor o igual a la unidad. También existe una modificación de esta función que puede observarse en el caso b) donde la función de transferencia escalón simétrica restringe el espacio de salida a valores entre uno y menos uno.

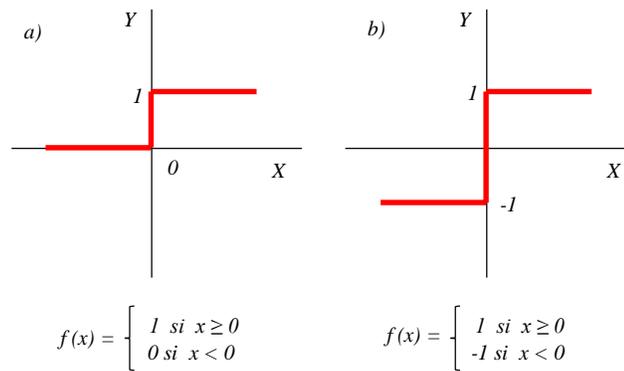


Figura 2.19. Funciones transferencia. a) *Hardlim*, b) *Hardlims* (Demuth et al, 1996)

La función lineal o identidad, es una función útil para realizar una regresión lineal. También, es una de las más sencillas y se muestra en el caso a) de la Figura 2.20. Para este caso la salida de la función es igual a su entrada.

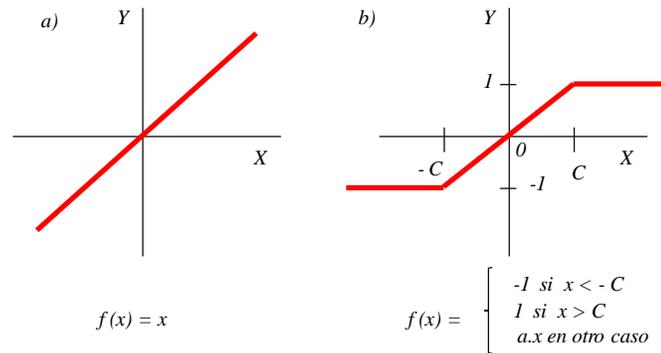


Figura 2.20. Función transferencia a) lineal y b) mixta (Demuth et al, 1996)

Las funciones transferencia mixta, sigmoideal, tangencial y gaussiana, son las más apropiadas cuando se requiere una salida de información analógica no lineal. Algunas de estas funciones poseen parámetros que modifican su forma ya sea por dilatación o contracción. La función *sigmoideal* toma valores de entrada que pueden oscilar entre más y menos infinito, y restringe los valores de la salida entre cero y uno de acuerdo la expresión que se muestra en el caso a) de la Figura 2.21. Es una función muy usada en redes multicapa, como la *Backpropagation*. Para el caso b) se muestra la función

tangente hiperbólica y por último la función *gaussiana* en la Figura 2.22, donde el parámetro A es la altura de la campana centrada en el punto b .

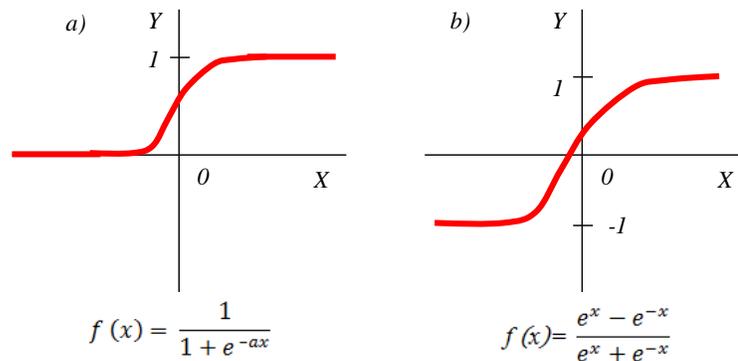


Figura 2.21. Funciones transferencia a) Sigmoidal, donde a es constante y b) Tangente Hiperbólica (Demuth et al, 1996)

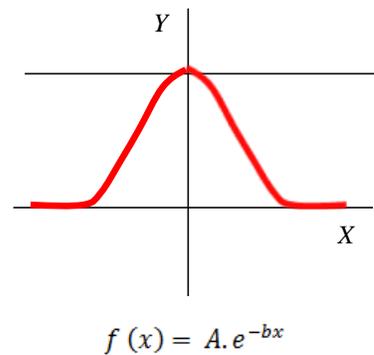


Figura 2.22. Función transferencia gaussiana, donde A y b son constantes (Demuth et al, 1996)

2.6.4. Clasificación de las redes neuronales artificiales

Las redes neuronales artificiales se pueden clasificar según su algoritmo de aprendizaje (supervisado o no supervisado), tipo de función activación y según los valores de entrada (binaria o continua). A su vez, se pueden clasificar según su topología o estructura de red de acuerdo al número de capas, tipo de capas (ocultas o visibles) y la direccionalidad de las conexiones. Un resumen de esta clasificación es mostrada en la Figura 2.23.

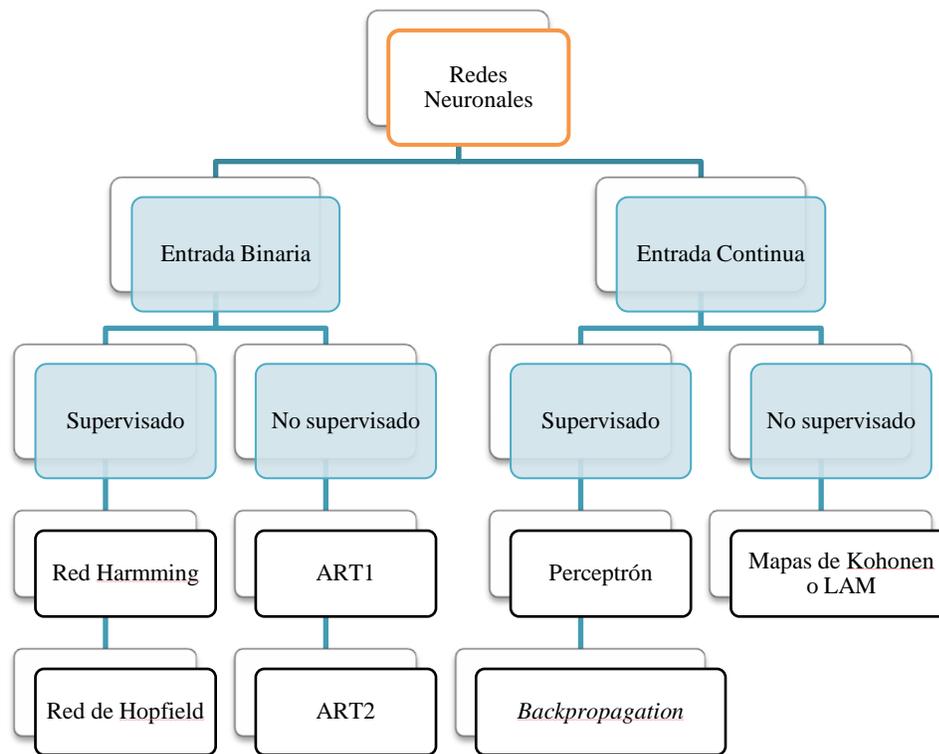


Figura 2.23. Clasificación de las redes neuronales artificiales (<http://proton.ucting.udg.mx>)

2.6.5. Algoritmos neuronales

El aprendizaje es un proceso por el cual una red neuronal suele modificar sus pesos como respuesta a una información de entrada y uno de los aspectos más importantes es determinar cuáles son los criterios que se siguen para cambiar el valor asignado o peso de cada conexión. Se pueden considerar dos tipos de reglas: aprendizaje supervisado y no supervisado. Básicamente, la diferencia entre ambos tipos está en la existencia o no de un agente externo que controle el proceso.

(a) Aprendizaje supervisado

Este tipo de redes se caracterizan porque el proceso de aprendizaje se realiza mediante un entrenamiento controlado por un agente externo que determina la respuesta que debería generar la red a partir de una entrada determinada.

Posteriormente, se comprueba la salida generada por el sistema y debe ser lo más próxima posible a la salida deseada, en el caso de que no coincida con la esperada, se procede al ajuste de los pesos de las conexiones. Este tipo de aprendizaje puede llevarse a cabo de tres formas: por corrección de error, por refuerzo y aprendizaje estocástico.

- Aprendizaje por corrección de error

Este aprendizaje consiste en ajustar los pesos de las conexiones de la red en función de la diferencia que existe entre los valores deseados y los obtenidos en la salida, aparte del error cometido. Un algoritmo o regla simple de aprendizaje por error podría ser empleado por medio de la siguiente ecuación:

$$\Delta w_{ji} = \alpha \cdot y_i (d_j - y_j) \quad 2.4$$

Donde:

Δw_{ji} : Variación en el peso de la conexión entre las neuronas i y j

$$\Delta w_{ji} = \Delta w_{ji}^{actual} - \Delta w_{ji}^{anterior} \quad 2.5$$

y_i : Valor de salida para la neurona i

y_j : Valor de salida para la neurona j

d_j : Valor de salida deseado para la neurona j

α : Factor de aprendizaje ($0 < \alpha \leq 1$) que regula la velocidad del aprendizaje

Un ejemplo de este tipo de algoritmo es la regla de aprendizaje del Perceptrón utilizada en el entrenamiento de la red de Rosenblat en 1958, donde a cada una de las neuronas de la capa de salida se le calcula el error local y posteriormente es utilizado en el ajuste de los pesos sobre la conexión de la neurona precedente.

Otro algoritmo es la regla de aprendizaje Delta o regla del mínimo error cuadrado, donde toma en consideración todas las neuronas precedentes para poder cuantificar el

error global cometido en el proceso de entrenamiento de la red y mejorar así la regla de aprendizaje del perceptrón. Luego el error calculado es igualmente repartido entre las conexiones de las neuronas precedentes y se puede expresar de la siguiente manera:

$$Error_{global} = \frac{1}{2P} \times \sum_{k=1}^P \sum_{j=1}^N (y_j^k - d_j^k)^2 \quad 2.6$$

Donde:

N : Número de neuronas de salida

P : Número de patrones que debe aprender la red

$\frac{1}{2} \times \sum_{j=1}^N (y_j^k - d_j^k)^2$: Error cometido en el aprendizaje de la información k-ésima

El proceso trata de encontrar los pesos para las conexiones de la red que minimicen esta función de error. Es por esto que el ajuste de los mismos en las conexiones de la red, se hace de forma proporcional a la variación relativa del error para minimizarlo y se obtiene al variar el peso correspondiente:

$$\Delta w_{ji} = k \times \frac{\partial Error_{global}}{\partial w_{ji}} \quad 2.7$$

Por último, la regla de aprendizaje de propagación hacia atrás o *Backpropagation*, es una generalización de la regla de aprendizaje Delta propuesta en el año 1986. El algoritmo *Backpropagation* constituye el modelo de aprendizaje del perceptrón multicapa más utilizado, debido a su sencillez y eficacia para la resolución de problemas arbitrariamente complejos. Para este algoritmo se emplean dos fases: la primera es la fase de aprendizaje (hacia adelante), donde los patrones de entrada son presentados a la primera capa de la red y posteriormente se propaga dicho estímulo a través de todas las capas posteriores hasta generar una salida en el sistema. La segunda fase de aprendizaje (hacia atrás), es a partir de la comparación de la salida de

la red y la deseada, donde se calcula un error para cada neurona de la última capa. Estos errores se transmiten desde la capa de salida hacia las neuronas de la capa precedente y este proceso se repite capa por capa hasta que todas las neuronas de la red hayan recibido un error que describa su aporte relativo a la salida final. A partir de este valor de error se reajustan los pesos de cada neurona para minimizarlo. Si el aprendizaje ha sido eficaz, la red debe generar una salida próxima a la deseada ante la presencia de un nuevo estímulo o dato de entrada desconocido. En la Figura 2.24 se muestra la dinámica básica de un modelo de retro propagación de errores.

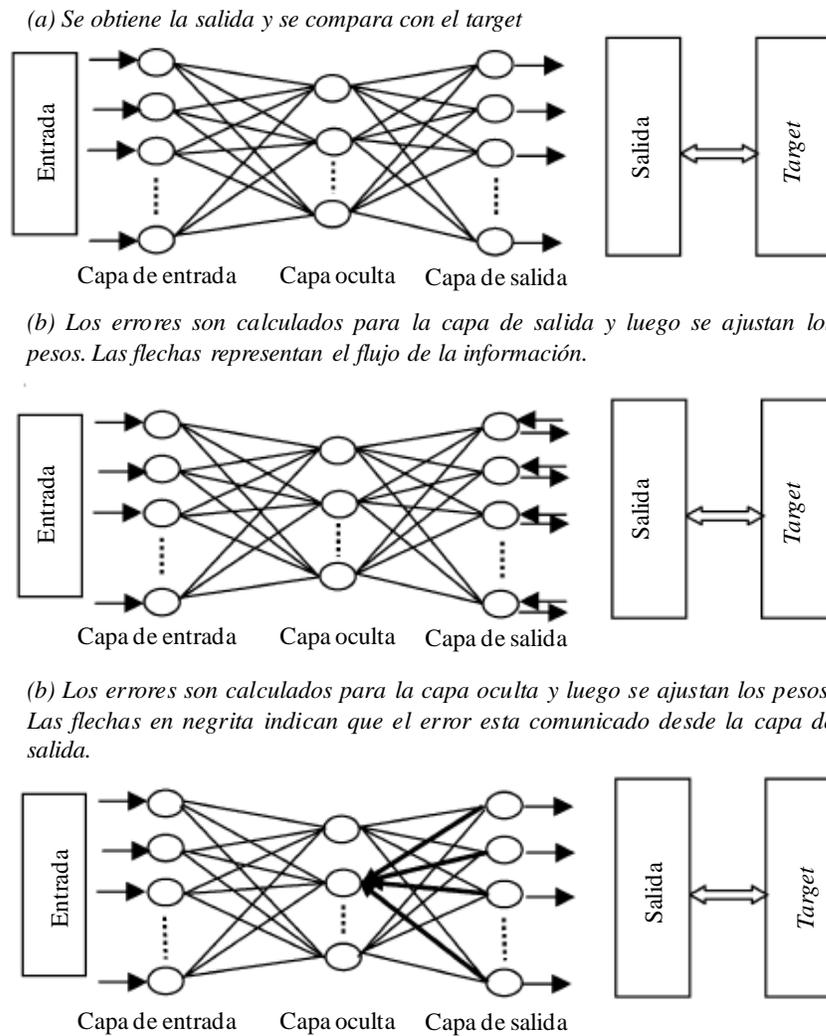


Figura 2.24. Dinámica básica de retro propagación de errores (Huang et ál, 2003)

- **Aprendizaje por refuerzo**

Es un aprendizaje más lento que por corrección de error y se basa en la idea de no disponer de un ejemplo completo del comportamiento deseado, es decir, no se indica durante el entrenamiento la salida exacta que se desea que proporcione la red ante una determinada entrada. Aquí la función se reduce a indicar mediante una señal de refuerzo si la salida obtenida en la red se ajusta a la deseada, siendo éxito igual a uno y fracaso igual a menos uno, y en función de ello se ajustan los pesos basándose en un mecanismo de probabilidades.

- **Aprendizaje estocástico**

Este tipo de aprendizaje consiste básicamente en realizar cambios aleatorios en los valores de los pesos y evaluar su efecto a partir del objeto deseado y de distribuciones de probabilidad. Si el comportamiento de la red se acerca al deseado y la energía de la red es menor, se acepta el cambio, de lo contrario se acepta el cambio en función de una determinada y preestablecida distribución de probabilidades.

(b) Aprendizaje no supervisado o Auto-organizado

Este tipo de redes con aprendizaje no supervisado, no necesitan de la influencia de un agente externo para poder ajustar los pesos de las conexiones entre sus neuronas, únicamente se le suministra datos de entrada para que extraiga los rasgos característicos esenciales. Esta red no recibe ningún tipo de información por parte del entorno que le pueda decir si la salida generada es o no correcta. Por lo tanto, la interpretación de su salida depende del algoritmo empleado y de la estructura de la red. A su vez, deben encontrar las características, regularidades, correlaciones o categorías que se pueden establecer entre los datos de entrada. En algunos casos, la salida representa el grado de similitud entre las entradas y la información que se ha mostrado. En otros, se establecen categorías donde a la salida se le indica la categoría a la cual pertenecen los datos de entrada, siendo la misma red quien encuentre las

categorías apropiadas a partir de correlaciones entre la información presentada. El aprendizaje no supervisado puede ser de dos tipos: Hebbiano, competitivo o comparativo.

- **Aprendizaje Hebbiano**

La regla de aprendizaje de Hebb se originó a partir de la neurona biológica que puede tener únicamente dos estados, activa o inactiva. Esta es la base de otras reglas de aprendizaje y pretende medir la familiaridad o extraer características de los datos de entrada. Se fundamenta en que si dos neuronas toman el mismo estado a la vez (ambas activas o inactivas), el peso de la conexión entre ambas aumenta.

- **Aprendizaje competitivo o comparativo**

Es un aprendizaje orientado a la clasificación de los datos de entrada. En el aprendizaje competitivo si un patrón nuevo se determina que pertenece a una clase reconocida previamente, la inclusión de este patrón matiza la representación de la misma. De lo contrario, la estructura y los pesos de la red neuronal serán ajustados para reconocer la nueva clase.

2.6.6. Topología de una red neuronal artificial

La topología o arquitectura de una red neuronal consiste en la organización y disposición de las neuronas para formar capas con varias de ellas tal como se muestra en la Figura 2.25. Para esto se debe tomar en cuenta los parámetros fundamentales en una red tales como el número de capas, número de neuronas, grado de conectividad y el tipo de conexión entre las neuronas.

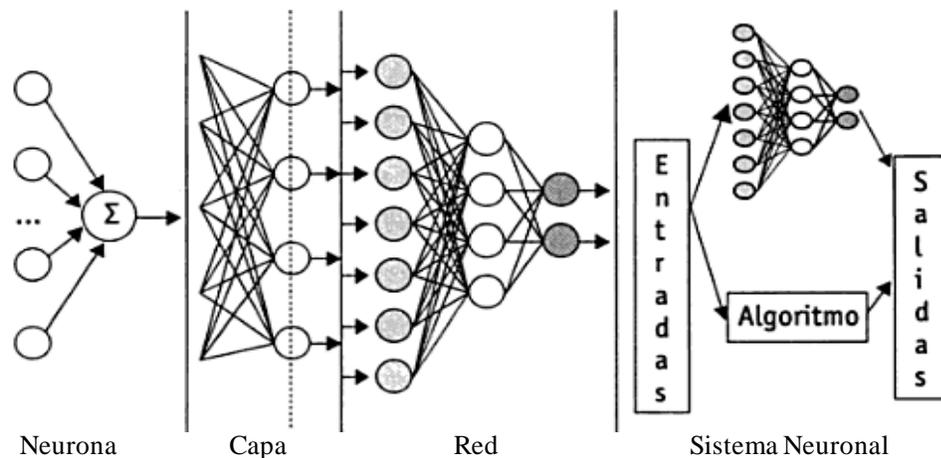


Figura 2.25. Estructura de un sistema basado en redes neuronales (Flórez y Fernández, 2008)

El sistema neuronal artificial son un conjunto de procesadores elementales (neuronas artificiales), conectados a otras neuronas o bien a entradas externas con una salida que permite propagar señales por múltiples caminos. Un conjunto de neuronas artificiales cuyas entradas provienen de la misma fuente y las salidas se dirigen al mismo destino, comprenden un conjunto de neuronas que constituyen una capa o nivel. Un sistema neuronal está formado básicamente por los siguientes elementos:

- Un conjunto de procesadores elementales o neuronas artificiales.
- Un patrón de conectividad, arquitectura o topología.
- Una dinámica de activaciones.
- Una regla dinámica de aprendizaje.
- El entorno donde estas operan.

(a) Conexión entre neuronas

La conexión entre las neuronas viene relacionada con la forma en que las salidas de las mismas están canalizadas para convertirse en entradas de otras neuronas y estas conexiones funcionan como caminos unidireccionales. La señal de salida de una neurona puede ser una entrada de otro elemento de proceso o incluso ser una entrada de sí mismo (conexión auto-recurrente).

Las redes multicapa están formadas por varios niveles de neuronas. Cuando la salida de las mismas no es entrada de otras neuronas del mismo nivel o de niveles precedentes, es decir, los datos de las neuronas de una capa inferior son propagados hacia las neuronas de la capa superior de la red, se le conoce como propagación hacia adelante o *feedforward* como se muestra en la Figura 2.27.

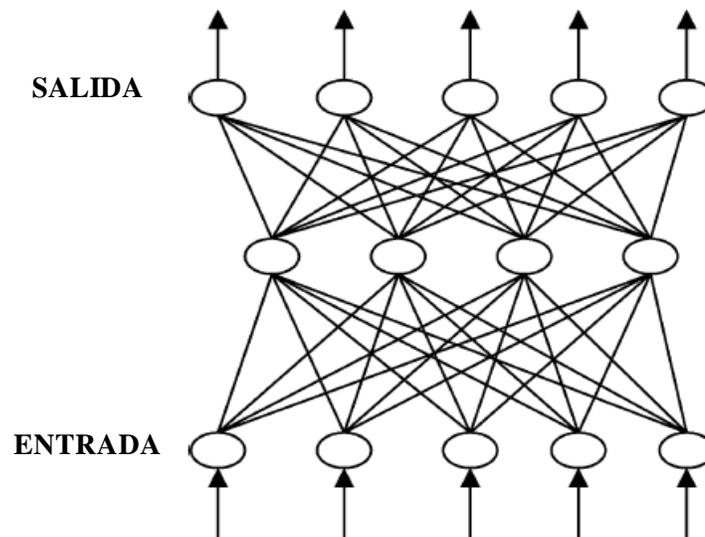


Figura 2.26. Red con propagación hacia adelante o *feedforward* (Huang et al., 2003)

En el caso contrario, si las neuronas se encuentran conectadas en las entradas de otras de niveles previos o del mismo nivel y las conexiones llevan datos de las neuronas de una capa superior a otras de la capa inferior, la red es de propagación hacia atrás o *feedback* como se observa en la Figura 2.27. Por otra parte, existen redes de propagación hacia atrás que tienen lazos cerrados. Estas redes son conocidas como sistemas recurrentes y se muestra en la Figura 2.28.

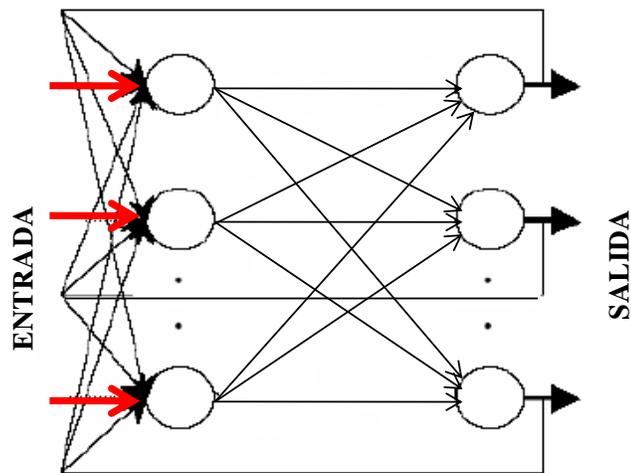


Figura 2.27. Red con propagación hacia atrás o *feedback* (Hilera, 1995; citada en Moya, Herrero y Guerrero)

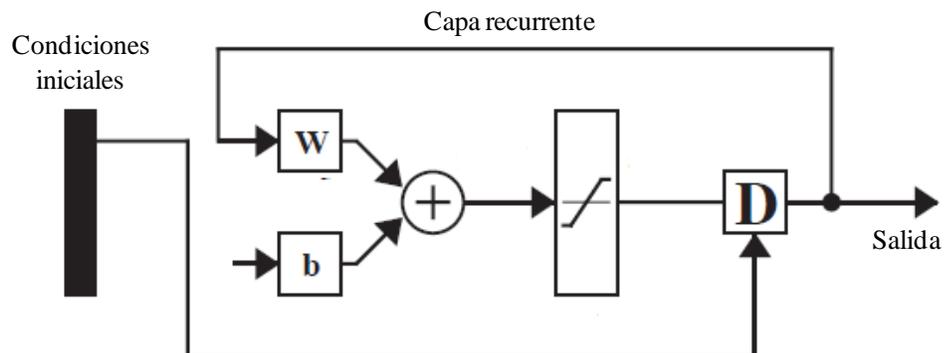


Figura 2.28. Red recurrente (Demuth et al, 1996)

Las redes monocapa son redes que poseen un solo nivel. La unión entre las neuronas se lleva a cabo mediante conexiones laterales y de esta manera se conectan unas con otras en una misma capa como se muestra en la Figura 2.29. Las más representativas son las redes de Hopfield y las máquinas estocásticas de Boltzmann y Cauchy.

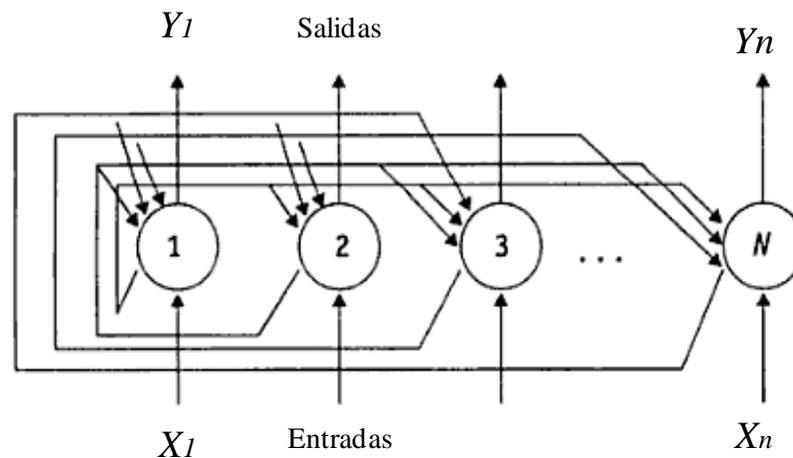


Figura 2.29. Red de Hopfield (Flórez y Fernández, 2008)

Finalmente, cuando la salida de una neurona de una capa es entrada de todas las neuronas de la capa siguiente se denomina *red totalmente conectada*, si se conecta solamente con algunas neuronas estamos en presencia de una *red localmente conectada*.

2.6.7. Perceptrón simple

El modelo de RNA conocido como Perceptrón o Perceptrón Simple, fue introducido por Rosenblatt en el año 1958. Fue inspirado en las primeras etapas de procesamiento del sistema sensorial animal y basado en el modelo de McCulloch y Pitts, junto con la regla de aprendizaje por corrección de error.

El perceptrón simple es una red que consta de dos capas de neuronas. La primera capa tiene como función hacer de sensor, es decir, por ella van a entrar las señales a la red y la segunda capa realiza todo el procesamiento. Cada neurona del primer nivel está unida con todas las del segundo nivel.

Generalizando, esta red de naturaleza unidimensional, se organiza en dos capas de neuronas con n neuronas de entrada y m neuronas de salida, calculando cada salida de la red de la siguiente forma (considerando la presencia de umbrales):

$$y_j = f \left(\sum_{i=1}^n w_{ji} x_i \right), \quad \forall j, 1 \leq j \leq n \quad 2.8$$

La función de activación de las neuronas de salida es de tipo escalón tal como se muestra en la estructura del perceptrón de la Figura 2.30. A su vez, la operación de un perceptrón simple puede escribirse como:

$$y_j = H \left(\sum_{i=0}^n w_{ji} x_i \right), \quad y_j = \begin{cases} 1, & \text{si } \sum_{i=0}^n w_{ji} x_i \geq 0, \\ 0, & \text{si } \sum_{i=0}^n w_{ji} x_i < 0 \end{cases} \quad \forall j, 1 \leq j \leq n \quad 2.9$$

Donde H es la función escalón o *Heaviside*.

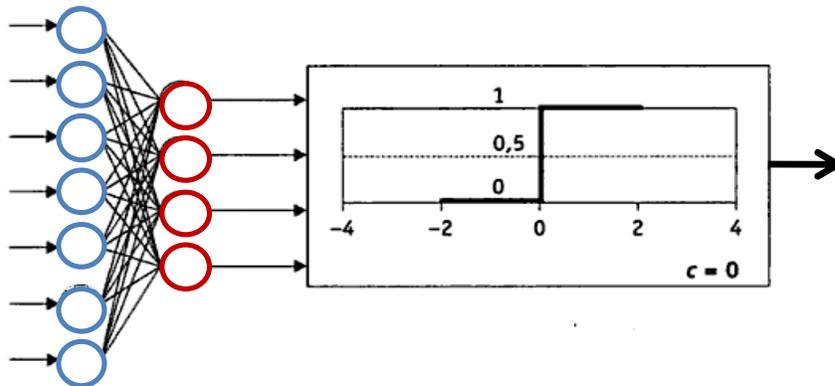


Figura 2.30. Perceptrón simple (Flórez y Fernández, 2008)

Este tipo de red básicamente utiliza dos funciones de transferencia, *Hardlim* con salidas $[0,1]$ o *Hardlims* con salidas $[-1,1]$ si las entradas de la red son binarias. Su

uso depende del valor de salida que se espera para la red (unipolar o bipolar). Debido a que no existen capas ocultas, tanto la función *Hardlim* como *Hardlims* tienen el mismo efecto en el algoritmo de entrenamiento.

2.6.8. Aplicaciones de las redes neuronales artificiales en ingeniería de petróleo

Tomando en cuenta que en ingeniería se presentan problemas de gran complejidad que requieren de un manejo matemático para obtener los mejores resultados, se muestran a continuación algunas aplicaciones de las redes neuronales artificiales para la solución de problemas encontrados en la industria del petróleo.

(a) Geología y Geofísica

- Estimación de reservas
- Identificación de mineralogía en registros de pozos
- Localización de intervalos en datos petrofísicos
- Identificación de litofacies
- Reconocimiento de patrones sísmicos
- Sedimentología – Secuencia estratigráfica

(b) Perforación y Completación

- Análisis de mediciones durante la perforación
- Diagnóstico de mechas de perforación
- Selección y monitoreo de mechas y lodos de perforación

(c) Evaluación de formaciones

- Predicción de porosidad – extrapolación
- Predicción de permeabilidades en registros
- Detección y orientación de fracturas
- Determinación de la presión con registros petrofísicos

(d) Producción

- Análisis y optimización de procesos en superficie
- Tuberías – Inspección de calidad
- Monitoreo y control de producción
- Diagnóstico de fallas
- Planificación automática

(e) Ingeniería de Yacimientos

- Predicciones de producción
- Cotejo histórico automático
- Reconocimiento de patrones en datos de prueba de presión
- Predicción de propiedades físicas del yacimiento

(f) Economía y finanzas

- Análisis del mercado de petróleo y gas
- Análisis de riesgo
- Caracterización de mercados

CAPÍTULO III

MARCO METODOLÓGICO

En este capítulo se desarrolla la metodología empleada para cumplir con los objetivos de esta investigación, es decir, los pasos o etapas realizados para llevarla a cabo. Básicamente se describe el tipo y diseño de la investigación, al igual que cada una de las fases que comprende dicho estudio.

3.1. TIPO DE INVESTIGACIÓN

El siguiente estudio tiene como objetivo predecir la presión mínima de miscibilidad en la inyección de dióxido de carbono mediante la implementación de redes neuronales. A su vez, permitirá caracterizar las correlaciones existentes para calcular PMM y comparar las más adecuadas con la correlación generada en esta investigación.

Según Carlos Sabino (1992), las investigaciones descriptivas utilizan criterios sistemáticos que permiten poner de manifiesto la estructura o el comportamiento de los fenómenos en estudio, proporcionando de ese modo información sistemática y comparable con la de otras fuentes. Por otra parte, según Hernández et al. (2003) en las investigaciones experimentales se manipulan una o más variables independientes para analizar las consecuencias de esa manipulación sobre una o más variables dependientes dentro de una situación de control para el investigador. Es por esto que la metodología empleada en esta investigación se lleva a cabo bajo un esquema descriptivo – experimental ya que se manipulan variables para generar la correlación por medio de redes neuronales y a su vez obtener resultados comparables con las correlaciones de otras fuentes.

3.2. DISEÑO DE LA INVESTIGACIÓN

Arias (1999) plantea que el diseño de la investigación es la estrategia que plantea el investigador para resolver el problema planteado. Por otra parte, señala que una investigación de tipo experimental es un proceso que consiste en someter a un objeto a determinadas condiciones o estímulos, denominadas variables independientes, para observar los efectos que se producen sobre otras variables conocidas como dependientes.

El diseño empleado para cumplir con los objetivos propuestos se lleva a cabo bajo un esquema experimental debido a que existe manipulación de variables obtenidas de otras fuentes. En esta investigación se manipulan variables tales como la composición del crudo y gas utilizada en pruebas experimentales de tubo delgado y burbuja ascendente con CO₂ puro e impuro por diversos autores. Esto se realiza con el fin de obtener una base de datos para generar una correlación por medio de redes neuronales que permita predecir la presión mínima de miscibilidad en la inyección de CO₂.

3.3. METODOLOGÍA DE LA INVESTIGACIÓN

La metodología de la investigación es realizada con el fin de llevar a cabo los objetivos propuestos en este estudio. Para cumplir con dichos objetivos, la misma se ha dividido en cinco fases como se esquematiza en la Figura 3.3. Igualmente, cada una de estas fases son descritas con más detalle a continuación.

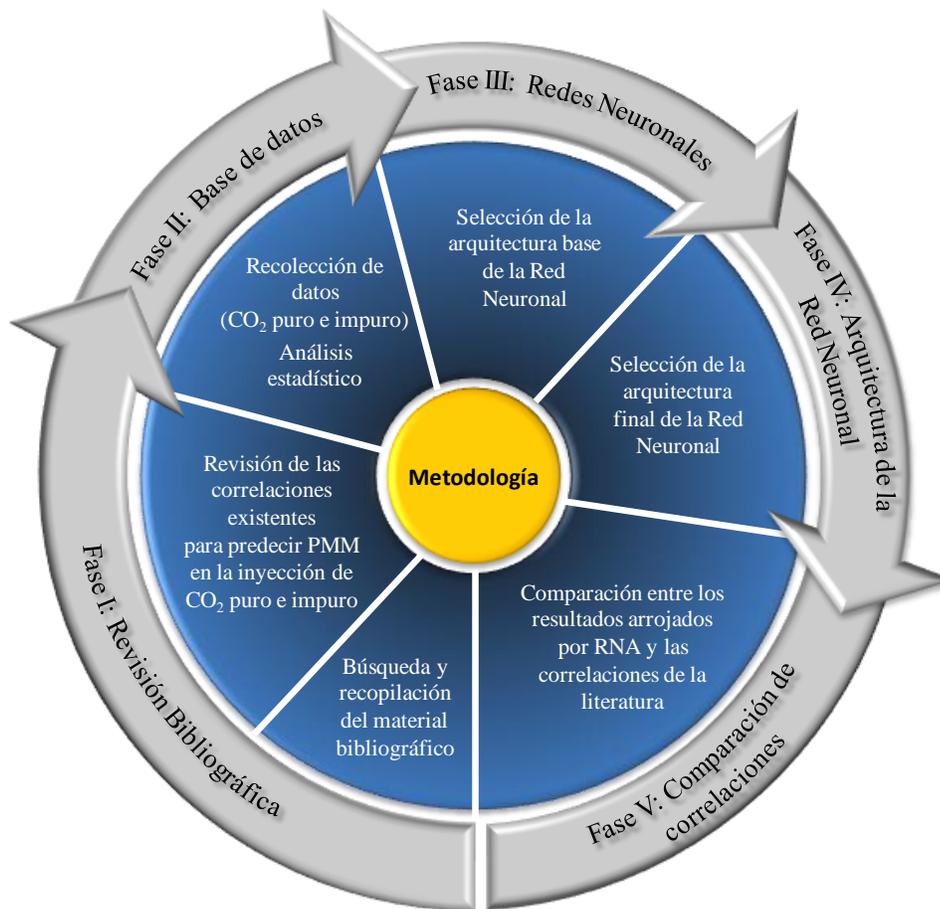


Figura 3.3. Esquema de la metodología empleada en la investigación

3.3.1. FASE I: REVISIÓN BIBLIOGRÁFICA

La revisión bibliográfica comprende la primera etapa de la investigación donde se realiza una búsqueda detallada de los aspectos teóricos necesarios que permiten desarrollar este Trabajo Especial de Grado. La revisión bibliográfica abarca los siguientes aspectos:

- Búsqueda y recopilación de la información referente a los conceptos de miscibilidad, tipos de desplazamientos miscibles, mecanismos para predecir la presión mínima de miscibilidad y los factores que afectan este proceso.

- Investigar aspectos generales sobre redes neuronales artificiales tales como sus características, clasificación, topología, algoritmos de aprendizaje y algunas aplicaciones en la ingeniería de petróleo.
- Llevar a cabo una investigación con respecto a la implementación previa de redes neuronales artificiales en procesos de desplazamientos miscibles en sistemas CO₂/crudo para predecir la presión mínima de miscibilidad.
- Adicionalmente, se realizó una búsqueda de las correlaciones existentes para calcular la PMM en la inyección de CO₂ y posteriormente el análisis de las mismas, con el fin de evaluar los parámetros utilizados en estas ecuaciones y establecer comparaciones con los resultados obtenidos.

(a) Recopilación de la Información

Esta etapa de la investigación consiste en la recopilación del material bibliográfico referente a conceptos sobre desplazamientos miscibles y redes neuronales artificiales. La información será recopilada de libros, páginas web, informes, artículos técnicos pertenecientes a la Sociedad de Ingenieros de Petróleo (SPE, *Society of Petroleum Engineers*).

(b) Revisión de las Correlaciones existentes para calcular PMM

En esta fase se realiza una búsqueda de las correlaciones existentes para calcular PMM en artículos técnicos de la SPE y trabajos de investigación publicados por diversos autores.

Para cada una de las correlaciones se genera una matriz de información donde se obtiene el autor, año, origen (Tubo Delgado o Burbuja Ascendente), tipo (Ecuación, Gráfica o Redes), tipo de gas usado (CO₂ puro o impuro) y los parámetros asociados a cada correlación. Se llevan a cabo gráficas porcentuales con cada uno de estos parámetros que se señalan en la matriz con el fin de tener una mejor observación de

los resultados y clasificación de las correlaciones. Posteriormente se procede al análisis de cada una de las gráficas.

3.3.2. FASE II: BASE DE DATOS

Esta fase comprende la recolección de datos para crear la matriz de información necesaria para el entrenamiento y prueba de la red neuronal. Igualmente se realiza un análisis estadístico de los mismos para verificar si existe alguna correlación entre las variables de estudio y poder garantizar su implementación en redes neuronales.

(a) Recolección de datos

En esta fase se recopilan datos disponibles en artículos técnicos de pruebas experimentales de tubo delgado y burbuja ascendente con CO₂ puro e impuro llevadas a cabo por diversos autores, para cada uno de los parámetros que son tomados en cuenta en la predicción de la PMM. Se crea una matriz de información para el entrenamiento de la red neuronal con valores de estudios previos de la composición del crudo y del gas, así como también de los resultados obtenidos de presión mínima de miscibilidad para cada caso.

(b) Análisis Estadístico de la información

Se realiza un análisis estadístico básico con aquellas variables que serán tomadas en cuenta para el entrenamiento de la red neuronal, con el fin de visualizar el comportamiento de la información que se tiene en la base de datos y verificar si existe algún tipo de correlación entre las variables. Se utilizan algunos parámetros estadísticos tales como las medidas de tendencia central y dispersión absoluta, además de las medidas de forma y algunas aplicaciones gráficas como histogramas y diagramas de dispersión. Cada una de estas medidas se explican con más detalle en el Apéndice A.

3.3.3. FASE III: REDES NEURONALES

Esta fase comprende la metodología usada en la selección de datos de entrenamiento y prueba para crear la red neuronal, el preprocesamiento de datos, arquitecturas de las redes neuronales a evaluar y los aspectos relacionados al entrenamiento y prueba de las mismas hasta llegar a la estructura deseada. En esta etapa se define la arquitectura base de la red. El entrenamiento y prueba de la red neuronal que se desarrolla en esta investigación es realizada bajo el esquema de la Figura 3.2.

Es importante mencionar que para llevar a cabo el entrenamiento de la red neuronal, se cuenta con una herramienta computacional conocida como MATLAB (abreviatura de *MATrix LABoratory*). Dicho software posee una herramienta que permite el diseño, implementación, visualización y simulación de redes neuronales artificiales.

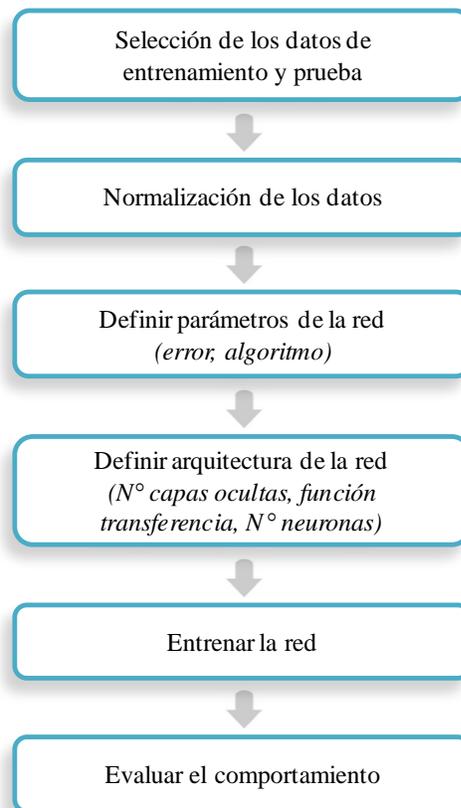


Figura 3.2. Esquema para el entrenamiento de una red neuronal

A continuación se explica en detalle el procedimiento llevado a cabo para el entrenamiento y prueba de la red neuronal, desde la fase inicial de entrenamiento hasta la selección de la estructura de la red que sirve de base para la fase donde se obtiene la arquitectura final de la misma.

(a) Selección de datos de entrenamiento y prueba

Se debe tomar en cuenta que para la fase de entrenamiento de la red se requiere que los valores de los parámetros de entrada sean diferentes a los utilizados en el momento de la prueba. Es por esto, que para entrenar las distintas arquitecturas de red que serán evaluadas se utiliza un 70 por ciento de la base de datos y el 30 por ciento restante será implementado en la prueba de la misma. Para dividir estos grupos en dichos porcentajes se generan números aleatorios, es decir, se pueden elegir los datos de entrenamiento y prueba al azar para poder disminuir el sesgo.

(b) Preprocesamiento de los datos

Luego de haber seleccionado los datos de entrenamiento y prueba, los mismos deben ser pre-procesados con el objetivo de tener una distribución uniforme en los valores de los parámetros de entrada de la red neuronal, ya que cada variable se maneja en rangos de valores diferentes. A su vez, permite un mejor rendimiento para alcanzar el aprendizaje de la red. Para esto se normalizan todos los parámetros a evaluar entre los intervalos [0,1] y [-1,1] tal como sea el caso. De esta manera, se tienen dos esquemas de normalizaciones diferentes.

La normalización de los datos que será implementada toma como nuevo límite valores en los intervalos [0,1] y [-1,1] tal como sea el caso, por medio de la ecuación 3.1 que se muestra a continuación:

$$X'_i = \left(\frac{x_i - \min(x)}{\max(x) - \min(x)} \times (\text{new_max} - \text{new_min}) + \text{new_min} \right)_p \quad 3.1$$

Donde:

new_min : Nuevo valor mínimo de la propiedad “p” después de normalizar

new_max : Nuevo valor máximo de la propiedad “p” después de normalizar

X'_i : Valor normalizado de la propiedad

$min(x)$: Es el valor mínimo de la propiedad x

$max(x)$: Es el valor máximo de la propiedad x

x_i : Valor actual de la propiedad.

Para normalizar en el intervalo $[0,1]$: $new_min = 0$, $new_max = 1$

Para normalizar en el intervalo $[-1,1]$: $new_min = -1$, $new_max = 1$

(c) Selección de la arquitectura y parámetros de la red

Para las redes neuronales es necesario conocer la arquitectura que tendrá la misma, esto implica determinar el número de capas ocultas y las neuronas que contendrán cada una de ellas, con el objetivo de obtener el mejor modelo para predecir la PMM en función de las variables de entrada de la red. Para esto se lleva a cabo un análisis de sensibilidad para cada uno de los parámetros que conforman la red tales como la función de entrenamiento y transferencia, número de capas ocultas, número de neuronas en cada capa oculta y el *Goal* o error cuadrático medio que se tiene como objetivo. Este análisis se realiza con los datos normalizados en el intervalo $[0,1]$ y $[-1,1]$.

El análisis de sensibilidad para cada uno de los parámetros que conforman la red neuronal, se lleva a cabo en base a las siguientes variables que se muestran en el diagrama de la Figura 3.3.

Cabe destacar que se entrena la red tres veces para cada arquitectura analizada con el fin de garantizar el alcance del mínimo global y no caer en un mínimo local. A continuación se explica en detalle cada uno de los parámetros mostrados.

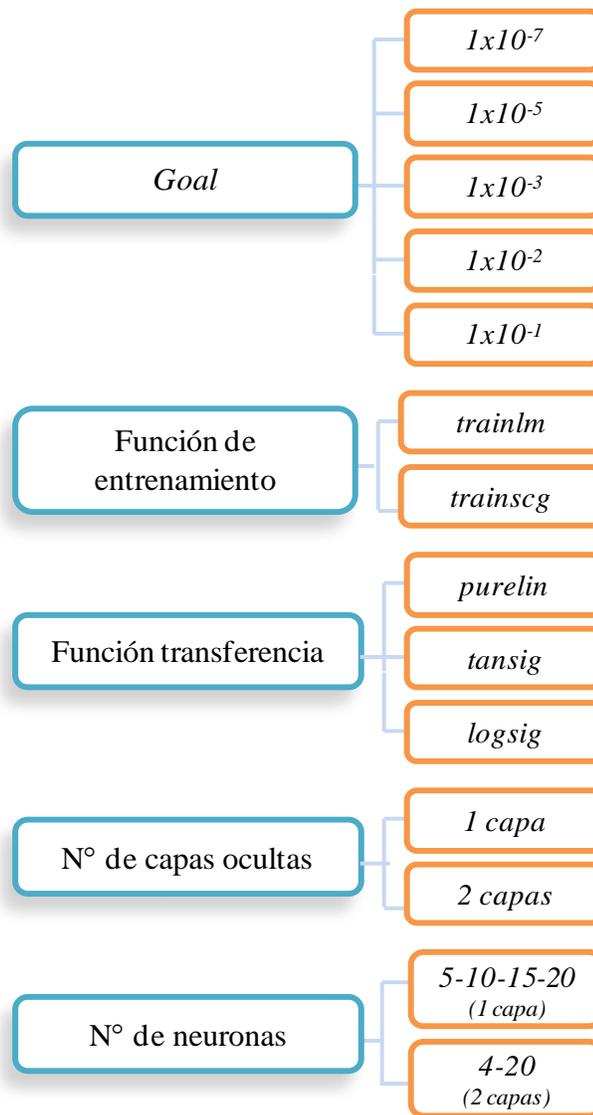


Figura 3.3. Diagrama de parámetros a evaluar en la red neuronal

- Error cuadrático medio o *Goal*

El error cuadrático medio (*ecm*) o *goal* es uno de los criterios de parada utilizados en el entrenamiento de la red neuronal y se calcula por medio de la Ecuación 3.2. Se lleva a cabo un análisis de sensibilidad para tolerancias de 1×10^{-7} , 1×10^{-5} , 1×10^{-3} , 1×10^{-2} y 1×10^{-1} con el fin de poder observar cuál de estas es la adecuada y evitar así el subajuste o sobreentrenamiento de la red neuronal. Cabe destacar que se evalúa el

comportamiento de cada tolerancia con las distintas arquitecturas de red que se construyan.

$$ecm = \sqrt{\sum_{i=1}^n \frac{(PMM_{red} - PMM_{exp})_i^2}{N}} \quad 3.2$$

Donde:

ecm : Error cuadrático medio

PMM_{red} : Presión mínima de miscibilidad obtenida por la red

PMM_{exp} : Presión mínima de miscibilidad experimental (Base de datos)

N : Número de valores analizados

- **Función de entrenamiento**

La función de entrenamiento tiene como objetivo ajustar los pesos y el *bias* de la red neuronal de acuerdo a su respectivo algoritmo de entrenamiento para obtener la mejor aproximación de la salida hacia el valor teórico. Para llevar a cabo dicho ajuste de los pesos, se utilizan las funciones de entrenamiento *trainlm* (*Levenberg-Marquardt Backpropagation*) y *trainscg* (*Scaled Conjugate Gradient Backpropagation*) por ser algoritmos de entrenamiento supervisados, al igual que forman parte de las funciones más implementadas en estos procesos. Igualmente, se evalúa el comportamiento de dichas funciones respecto a las diferentes arquitecturas de red que se construyan.

- **Función transferencia**

Las funciones transferencia utilizadas son *purelin* (lineal), *logsig* (sigmoial) y *tansig* (tangente hiperbólica) y el uso de ellas depende del rango en que se normalice la base de datos o se requiera acotar la salida de cada neurona. Para el caso de los datos normalizados en el intervalo [0,1] se utiliza únicamente como función transferencia *purelin* y *logsig*, a diferencia de los datos normalizados en el intervalo [-1,1] donde se utiliza como función transferencia *purelin* y *tansig*.

Cabe destacar que cada neurona tiene asociada una función transferencia, por lo tanto, para cada arquitectura que es diseñada la función transferencia de todas las neuronas entre las capas ocultas y la capa de salida se mantendrá igual, es decir, no se combinan dichas funciones para una arquitectura de red específica.

- **Número de neuronas y capas ocultas**

Las redes neuronales son sensibles al número de capas ocultas y neuronas que posean. A su vez, el número de neuronas depende de la cantidad de parámetros de entrada y salida, al igual que del algoritmo de entrenamiento a ser utilizado. Es por esto que para determinar el número óptimo de neuronas en la capa oculta es necesario entrenar varias redes y estimar el error de generalización de la misma.

Inicialmente, se evalúa el comportamiento de la red con una capa oculta variando la tolerancia del error cuadrático medio o *goal*, la función de entrenamiento y la función transferencia. También se lleva a cabo un análisis de sensibilidad para evaluar el comportamiento de la red aumentando progresivamente el número de neuronas en su respectiva capa oculta. Luego se verifican los resultados arrojados por la misma y posteriormente se observa si agregando una segunda capa oculta dichos errores de entrenamiento y prueba logran disminuir. En este último caso, se varía el número de neuronas en ambas capas ocultas pero en menor grado, con el fin de reducir el tiempo total de entrenamiento de la red. Finalmente, se analizan arquitecturas de red con una y dos capas ocultas. Es importante mencionar que este número de neuronas depende del número de variables de entrada a utilizar, por lo general el número máximo de ellas no excede el doble del número total de entradas.

En la Figura 3.4 se muestra para el caso *a*) un esquema de red con dos capas ocultas, a diferencia del caso *b*) donde se muestra el esquema que resulta al tener una red con una capa oculta.

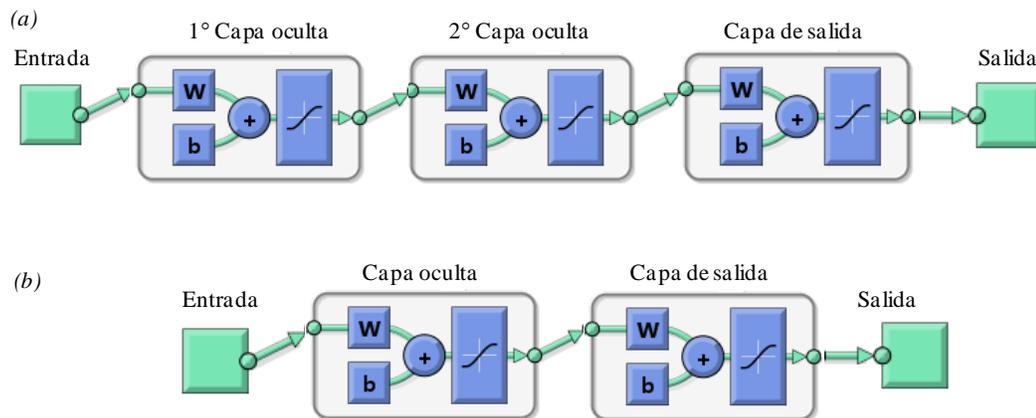


Figura 3.4. (a) RNA con dos capas ocultas. (b) RNA con una capa oculta. (MATLAB 7.8.0)

Una vez que este definida la base de datos y la arquitectura de la red neuronal a evaluar, se procede al entrenamiento de la misma y se verifican los errores de entrenamiento y prueba que se obtienen. Igualmente, se cuenta con gráficas donde se puede observar el rendimiento de la red y el coeficiente de correlación lineal tanto para el entrenamiento como para la prueba.

Finalmente, se define tanto la tolerancia del error cuadrático medio o *goal*, función de entrenamiento, función transferencia y número de capas ocultas, para pasar a una última fase donde se selecciona la arquitectura final que tendrá la misma.

3.3.4. FASE IV: ARQUITECTURA FINAL DE LA RED NEURONAL

En esta fase se define la arquitectura final que tendrá la red neuronal bajo el esquema mostrado en la Figura 3.5. Para esto se lleva a cabo un análisis de sensibilidad respecto a distintos conjuntos de datos y al número de neuronas correspondientes en cada capa oculta, dejando fija la función de entrenamiento, función transferencia, número de capas ocultas y la tolerancia del error cuadrático medio o *goal* seleccionado en la Fase III.

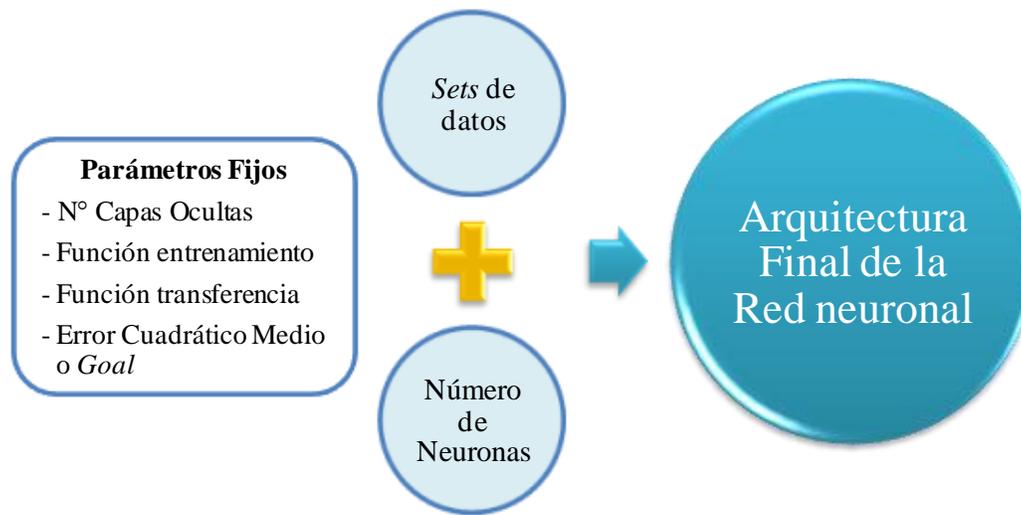


Figura 3.5. Esquema de la fase de optimización de la red neuronal

Para esta etapa se utiliza un 80 por ciento de la base de datos para el entrenamiento y el 20 por ciento restante será implementado en la prueba de la red neuronal. Para dividir la misma en dichos porcentajes, se generan números aleatorios con el fin de elegir los datos al azar y disminuir el sesgo. Cabe destacar que para esta etapa se generan distintos conjuntos o *sets* de datos de entrenamiento y prueba para verificar el comportamiento de la red al variar el orden de los mismos. El número de dichos conjuntos de datos dependerá de los errores de entrenamiento y prueba que se obtengan. Igualmente, el número de neuronas se varía en ambas capas ocultas realizando el análisis de sensibilidad con cuatro, ocho, doce, dieciséis y veinte neuronas.

Por otra parte, se realizan gráficas con el fin de verificar el comportamiento del error promedio en función del número de neuronas presentes en cada capa oculta, para cada conjunto de datos a evaluar. En la Figura 3.6 se observa un modelo de la gráfica que es utilizada en esta investigación para observar el comportamiento de los errores de la red neuronal final.

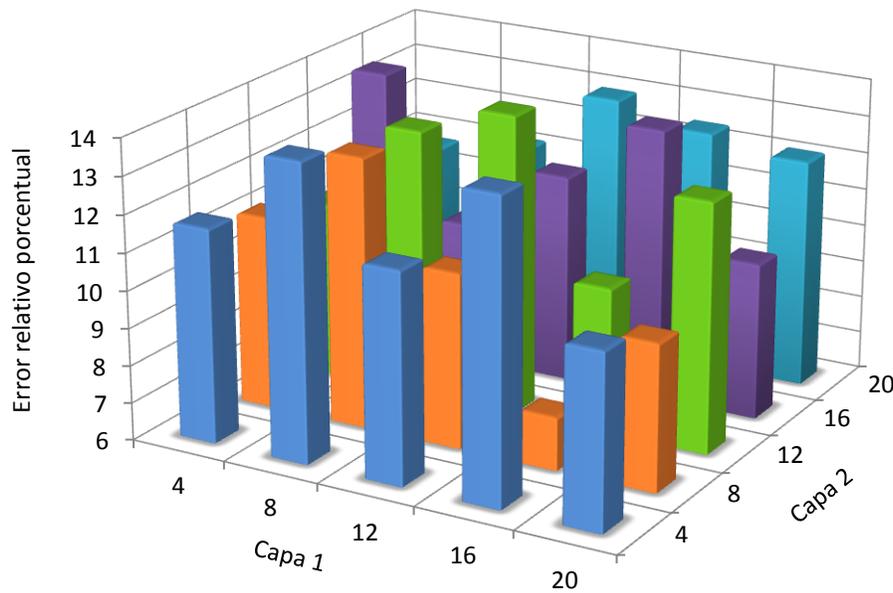


Figura 3.6. Modelo de gráfica del error relativo porcentual en función del número de neuronas para dos capas ocultas de la red neuronal final

El objetivo de esta fase es poder hallar una arquitectura de red que arroje un error promedio más bajo respecto al error que se obtiene en la Fase III. Por otra parte, se lleva a cabo la validación de la red neuronal final con cada una de las variables estudiadas para verificar la consistencia en la física de los sistemas, donde se grafican estas variables en función de la presión mínima de miscibilidad a obtener por medio de la red seleccionada.

3.3.5. FASE V: COMPARACIÓN DE LA CORRELACIÓN GENERADA POR RNA Y LAS CORRELACIONES DE LA LITERATURA

En esta fase se lleva a cabo una comparación entre los resultados arrojados por la red neuronal y las correlaciones existentes en la literatura, en función del error promedio de las mismas. Las correlaciones utilizadas para dicha comparación, depende de los parámetros y las variables en la composición del crudo y del gas que son tomadas en cuenta en el desarrollo de la red neuronal. Igualmente, se lleva a cabo una

comparación entre la red desarrollada en la presente investigación y aquellas que fueron realizadas en base a redes neuronales.

3.4. OPERACIONALIZACIÓN DE LOS OBJETIVOS

La operacionalización de los objetivos según Carlos Sabino (1992), tiene como objetivo la búsqueda de elementos concretos y empíricos, que permitan traducir y medir en la práctica los conceptos que se han definido teóricamente. De esa manera, se reduce la investigación pasando de un nivel abstracto a un nivel concreto y específico. La operacionalización de los objetivos de la presente investigación se muestra en la Tabla 3.1 y Tabla 3.2.

Tabla. 3.1. Operacionalización de los objetivos 1 y 2

Objetivo	Variable	Definición conceptual	Dimensión	Indicadores	Fuente	Instrumentos
Realizar una revisión bibliográfica de las correlaciones matemáticas existentes para predecir presión mínima de miscibilidad con dióxido de carbono puro e impuro.	Correlaciones matemáticas existentes	La correlación indica el grado en el que los valores de una variable se relacionan con los valores de otra.	En esta sección se revisan y caracterizan las correlaciones que permiten calcular la PMM. Igualmente, se revisan aquellos trabajos relacionados a la predicción de la PMM por redes neurales.	<ul style="list-style-type: none"> - Año - Autor - Origen - Tipo de correlación - Tipo de gas de inyección (CO₂ puro e impuro) - Parámetros usados en la correlación 	Informes y artículos técnicos pertenecientes a la Sociedad de Ingenieros de Petróleo (SPE, <i>Society of Petroleum Engineers</i>)	<ul style="list-style-type: none"> - Revisión Bibliográfica - Gráficas
Generar correlaciones con redes neuronales artificiales para predecir la presión mínima de miscibilidad en la inyección de CO ₂	Correlaciones con redes neuronales artificiales	Las redes neuronales artificiales son modelos computacionales que procesan información como respuesta a entradas externas. Permiten desarrollar tareas como el aprendizaje de patrones, clasificación y optimización.	En esta etapa se evalúan distintas arquitectura de redes para verificar cuál de ellas arroja el menor error en la predicción de la presión mínima de miscibilidad.	<ul style="list-style-type: none"> - Arquitectura de la red neuronal (Función entrenamiento y transferencia, número de capas ocultas y neuronas, error cuadrático medio) - Error promedio de entrenamiento y prueba 	Herramienta computacional	<ul style="list-style-type: none"> - Herramienta computacional - Gráficas - Tablas

Tabla. 3.2. Operacionalización del objetivo 3

Objetivo	Variable	Definición conceptual	Dimensión	Indicadores	Fuente	Instrumentos
Establecer una comparación entre las correlaciones matemáticas existentes y el valor obtenido por medio de la correlación generada por redes neuronales.	-Correlaciones matemáticas existentes - Valor obtenido por medio de la correlación generada por redes neuronales.	El valor predicho es el valor de presión mínima de miscibilidad generado por medio de la herramienta computacional.	En esta sección se comparan los resultados obtenidos por medio de redes neuronales y las correlaciones publicadas en la literatura.	- Error promedio - Error máximo - Error mínimo - Coeficiente de correlación	Correlaciones publicadas en la literatura. Herramienta computacional	-Correlaciones publicadas en la literatura - Tablas

CAPÍTULO IV

ANÁLISIS DE RESULTADOS

En este capítulo se llevó a cabo un análisis de las correlaciones publicadas en la literatura para predecir presión mínima de miscibilidad en la inyección de CO₂. Un total de 27 correlaciones fueron recopiladas y en un mayor detalle se muestra en el Apéndice C. Igualmente, se realizó un análisis estadístico de los datos utilizados para generar la red neuronal y se compararon los errores obtenidos en esta investigación con las correlaciones reportadas en la literatura.

4.1. CORRELACIONES PARA PREDECIR PMM EN LA INYECCIÓN DE CO₂ PURO E IMPURO

En la década de los 80 se produjo un gran interés hacia los métodos de recuperación mejorada debido al aumento en los precios del petróleo. Para la inyección de CO₂ el número de proyectos ha permanecido desde los años 80 prácticamente constante, sin embargo en los últimos años ha crecido el interés hacia el mismo (ver Figura 4.1) con el fin de disminuir la contaminación ambiental debido a la emisión de gases que causan el efecto invernadero y a las presiones de miscibilidad con CO₂ que suelen ser relativamente bajas con respecto a otros gases.

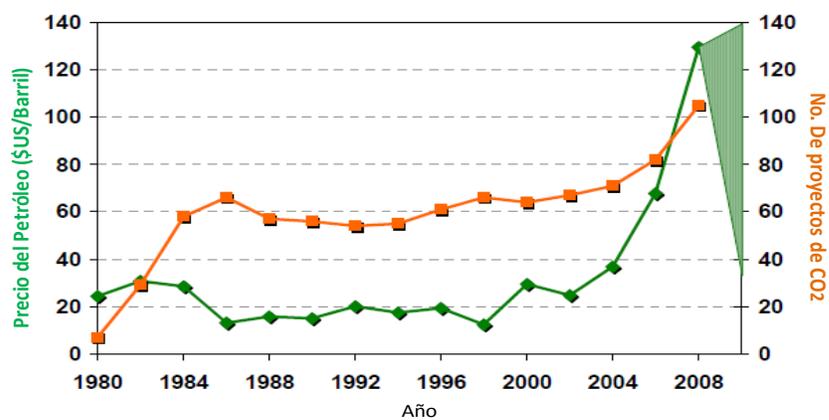


Figura 4.1. Precios del petróleo en función del número de proyectos de CO₂ (Manrique et al, 2010)

Es por esto, que se han venido desarrollando correlaciones matemáticas que permiten predecir la presión mínima de miscibilidad tanto para CO₂ puro como impuro. Las correlaciones analizadas en esta investigación comprenden las publicadas por Holm y Josendal (1974), National Petroleum Council (1976), Cronquist (1978), Dunyushkin y Namiot (1978), Petroleum Recovery Institute (1979), Lee (1979), Yellig y Metcalfé (1980), Mungan (1981), Johnson y Pollin (1981), Orr y Jensen (1984), Glaso (1985), Sebastian et al. (1985), Alston et al. (1985), Kovarik (1985), Orr y Silva (1987), Enick (1988), Eakin y Mitch (1988), Zuo et al. (1993), Dong et al. (1999), Huang et al. (2003), Yuan et al. (2004), Emera y Sarma (2005), Mousavi et al. (2006), Shokir (2007), Ghomian et al. (2008), Akbari et al. (2011) y Nezhad et al. (2011). En total, se cuenta con 27 correlaciones para calcular o predecir la PMM con CO₂ puro e impuro. Finalmente, para cada una de las correlaciones analizadas se generó una matriz de información donde se logró apreciar la clasificación de las mismas según el autor, año, origen (Tubo Delgado o Burbuja Ascendente), tipo (Ecuación, Gráfica o Redes), tipo de gas usado (CO₂ puro o impuro) y los parámetros asociados a cada una de ellas.

Con respecto al año en que fueron desarrolladas cada una de las correlaciones analizadas, se muestra en la Figura 4.2 una gráfica del porcentaje de correlaciones llevadas a cabo en cada una de las décadas. Se puede observar que en los años 70 se generaron un 22 por ciento de las correlaciones para predecir PMM. Sin embargo, un 41 por ciento fueron hechas en los años 80 cuando los precios del petróleo y el número de proyectos de recuperación mejorada aumentaron. Para los años 90 disminuyó hasta un siete por ciento el desarrollo de las mismas. Sin embargo, en los últimos años la inyección de CO₂ ha demostrado ser uno de los métodos de recuperación mejorada para petróleos livianos y medianos que ha tenido mayor auge, por lo tanto un 30 por ciento de las correlaciones existentes fueron desarrolladas en esta época. Finalmente, se puede decir que la década de los 80 ha sido una de las etapas con mayor desarrollo de correlaciones para predecir la presión mínima de miscibilidad en la inyección de CO₂.

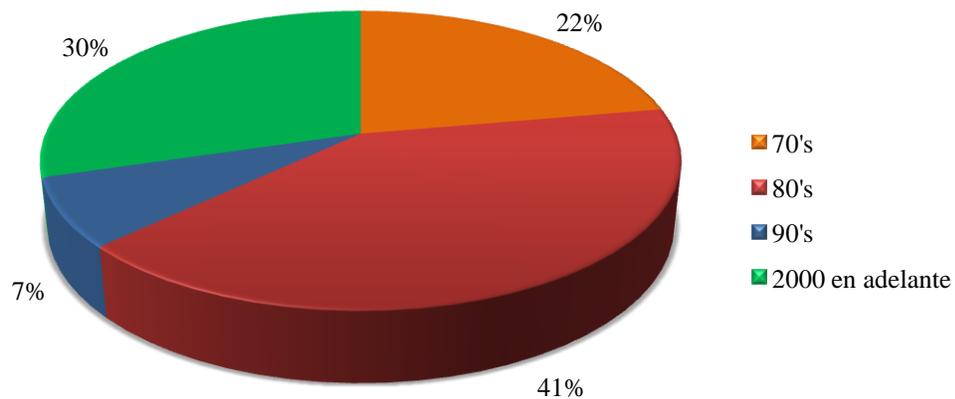


Figura 4.2. Representación gráfica del año de las correlaciones para predecir la presión mínima de miscibilidad en la inyección de CO_2

Otro análisis se puede realizar en cuanto procedimiento experimental llevado a cabo para medir la presión mínima de miscibilidad. En la Figura 4.3 se muestra una gráfica del porcentaje de correlaciones que fueron desarrolladas en base a datos obtenidos por el método de tubo delgado y burbuja ascendente, donde se puede observar que un 74 por ciento de las mismas fueron llevadas a cabo en base a datos obtenidos a través de pruebas de tubo delgado. A diferencia del método de la burbuja ascendente donde apenas un nueve por ciento de las correlaciones estudiadas se basan en dicho mecanismo. También se han desarrollado correlaciones que en su base de datos cuentan con información referida a ambos métodos experimentales, los cuales abarcan un 17 por ciento del total de casos. Cabe destacar que para este análisis se tomaron en cuenta únicamente 22 correlaciones, ya que no se dispuso de información referido al origen del resto de las correlaciones.

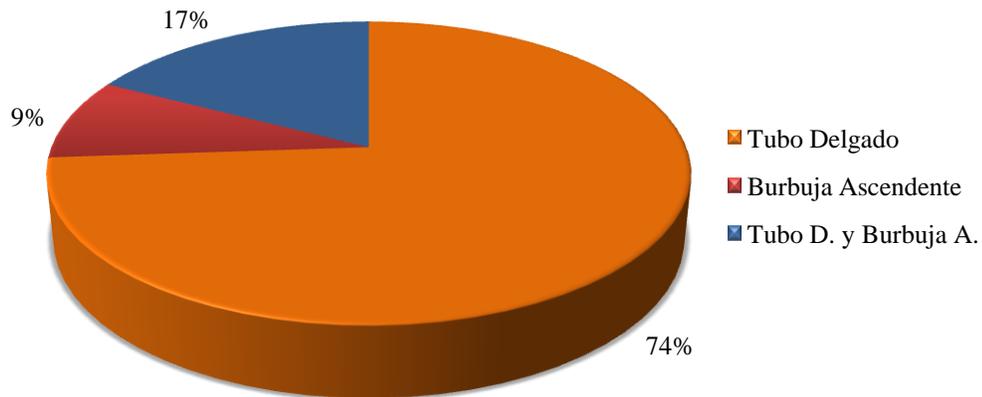


Figura 4.3. Representación grafica del origen de la correlación para predecir la presión mínima de miscibilidad en la inyección de CO₂

Con respecto al tipo de correlación desarrollada, se muestra en la Figura 4.4 la clasificación y el porcentaje correspondiente a cada uno de estas. Los tres grupos que se definen son: ecuaciones, gráficas y redes neuronales. En esta gráfica (Figura 4.4) se puede observar que la mayor parte de las correlaciones comprenden ecuaciones matemáticas derivadas de regresiones lineales y no lineales, abarcando un 67 por ciento del total. Por otra parte se tienen las correlaciones gráficas que comprenden un 18 por ciento, las cuales son menos precisas y las primeras en ser desarrolladas. Igualmente, se observa que tan solo un 15 por ciento abarca aquellas correlaciones generadas por medio de redes neuronales.

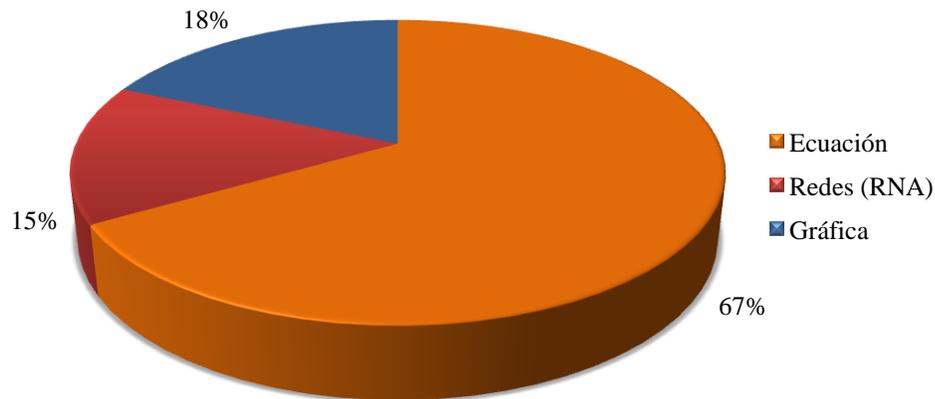


Figura 4.4. Representación gráfica del tipo de correlación para predecir la presión mínima de miscibilidad en la inyección de CO₂

Una de las primeras correlaciones gráficas fue desarrollada por Holm y Josendal en el año 1974, seguido por Yellig y Metcalfe (1980), Mungan (1981), Dunyushkin y Namiot (1978) y Enick (1988). En la Figura 4.5 se muestra que dichas correlaciones gráficas fueron hechas únicamente en la década de los 70 y 80 abarcando el 35 y 30 por ciento respectivamente. Más adelante, se fue perdiendo el interés hacia este tipo de correlaciones ya que son menos precisas en el cálculo de la presión mínima de miscibilidad. Posteriormente, hubo una evolución a la representación de correlaciones en forma de ecuación, la cual ha predominado desde los años 70 hasta los 90. En los últimos años, se ha venido desarrollando una alternativa basada en la teoría de la inteligencia artificial conocida como Redes Neuronales Artificiales (RNA) que permite construir un modelo más preciso y fiable. Es por esto, que un 50 por ciento de las correlaciones realizadas en la última década pertenecen a este grupo. Las correlaciones que implementan redes neuronales fueron desarrolladas por Huang et al. (2003), Mousavi et al. (2006), Akbari y Kasiri (2010) y Nezhad et al. (2011). En consecuencia, se ha demostrado interés en el uso de las mismas en la predicción de la presión mínima de miscibilidad ya que son herramientas más eficaces que los

métodos convencionales y se caracterizan por ser una técnica eficiente en el reconocimiento de patrones, problemas de clasificación y ajuste de funciones.

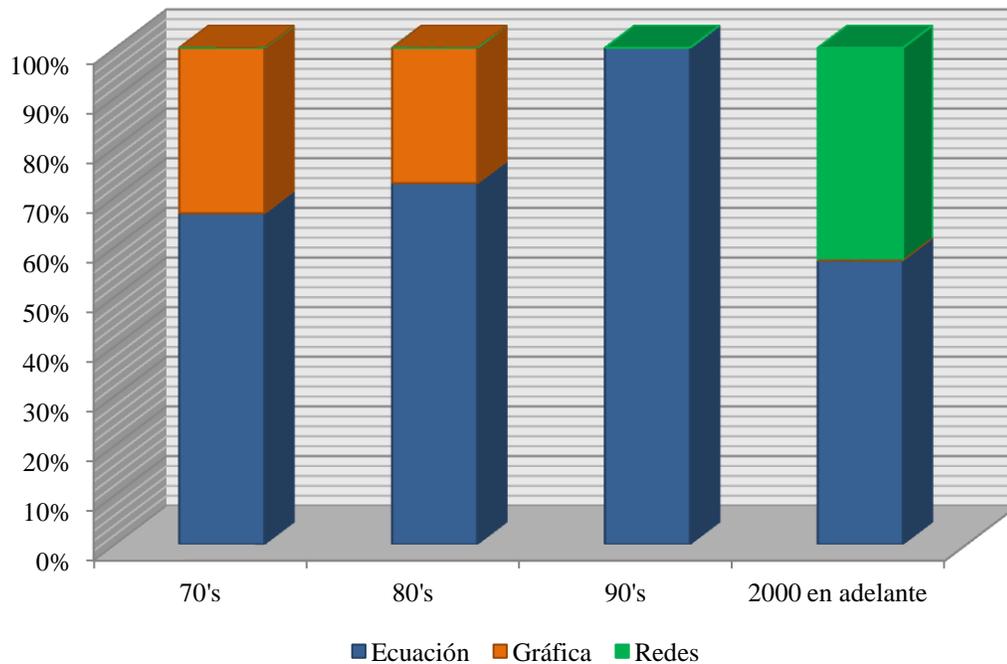


Figura 4.5. Representación gráfica del tipo de correlación evaluada en función del tiempo

En relación al tipo de gas usado para generar cada correlación, se observa en la Figura 4.6 aquellas que permiten calcular la presión mínima de miscibilidad ya sea para CO₂ puro, impuro o ambas. Para el caso del CO₂ puro, existen correlaciones desarrolladas por Holm y Josendal (1974), National Petroleum Council (1976), Petroleum Recovery Institute (1979), Cronquist (1978), Lee (1979), Yellig y Metcalfe (1980), Orr y Jensen (1984), Mungan (1981), Glaso (1985), Orr y Silva (1987), Zuo et al. (1993), Emera y Sarma (2005) y Ghomian et al. (2008), las mismas abarcan un 48 por ciento del total analizado. En cambio, Dunyushkin y Namiot (1978), Kovarik (1985), Sebastian et al. (1985) y Dong et al. (1999) desarrollaron correlaciones solo para el caso CO₂ impuro comprendiendo un 15 por ciento del total. De la misma manera, existen otras correlaciones que pueden ser usadas tanto para

CO₂ puro e impuro llevadas a cabo por Huang et al. (2003), Alston et al. (1985), Enick (1988), Eakin y Mitch (1988), Yuan et al. (2004), Johnson y Pollin (1981), Nezhad et al. (2011), Mousavi et al. (2006), Shokir (2007) y Akbari y Kasiri (2010), comprendiendo un 37 por ciento del total de las correlaciones evaluadas.

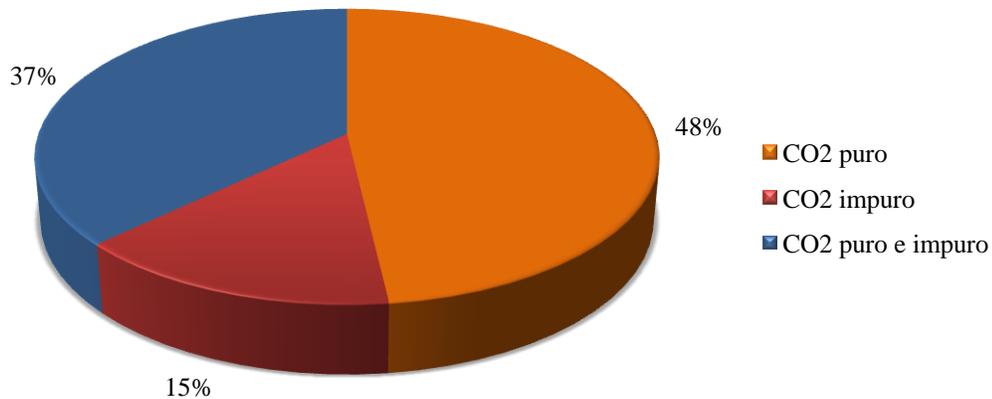


Figura 4.6. Representación gráfica del tipo de gas usado en las correlaciones para predecir la presión mínima de miscibilidad en la inyección de CO₂

Para entender el porcentaje de correlaciones llevadas a cabo según el tipo de gas usado y la década en que estas fueron desarrolladas, se muestra en la Figura 4.7 el porcentaje de las mismas desde los años 70 hasta la actualidad. Para el caso del CO₂ puro, se tiene que un 80 por ciento de las correlaciones fueron llevadas a cabo en la década de los 70. En cambio para los años 80 y 90 fue disminuyendo el desarrollo de las mismas, incluso en los últimos años se desarrollaron pocas correlaciones de este tipo. A diferencia del CO₂ puro, el CO₂ impuro está disponible desde varias fuentes incluyendo reservas naturales, plantas de proceso o también procedente de pozos que se encuentren en campos bajo un esquema de explotación por inyección de CO₂. Es por esto, que al pasar los años se fueron desarrollando correlaciones que incluyeran impurezas tales como CH₄, N₂, H₂S y componentes desde el C₂ hasta el C₆ en la corriente de gas. En consecuencia, la mayoría de estas fueron elaboradas desde los

años 80 hasta la actualidad debido a la disposición del CO₂ impuro como gas de inyección y al costo asociado a la eliminación de dichas impurezas.

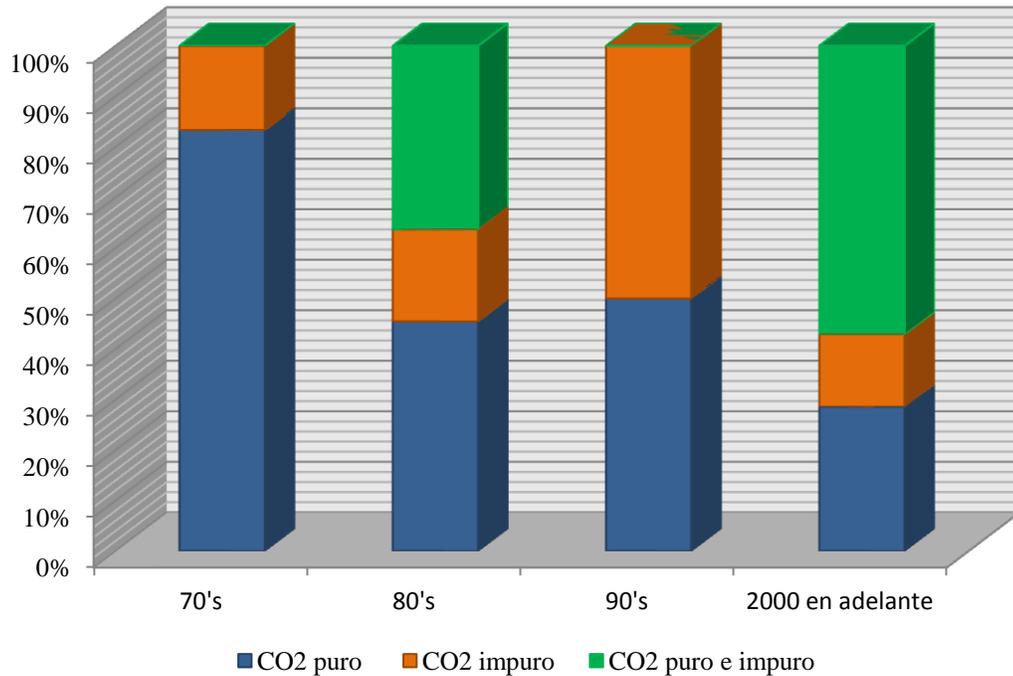


Figura 4.7. Representación gráfica del porcentaje de correlaciones según el tipo de gas en función del tiempo

Con respecto a las variables que tomaron en cuenta los autores para generar cada correlación, se tiene que tanto la temperatura del yacimiento como la composición del crudo y la pureza del gas de inyección, son parámetros importantes y por lo tanto sus efectos en la presión mínima de miscibilidad han sido investigados extensamente por varios autores. En la Figura 4.8 se muestra una gráfica del porcentaje de los parámetros usados para desarrollar dichas correlaciones en sistemas CO₂/crudo.

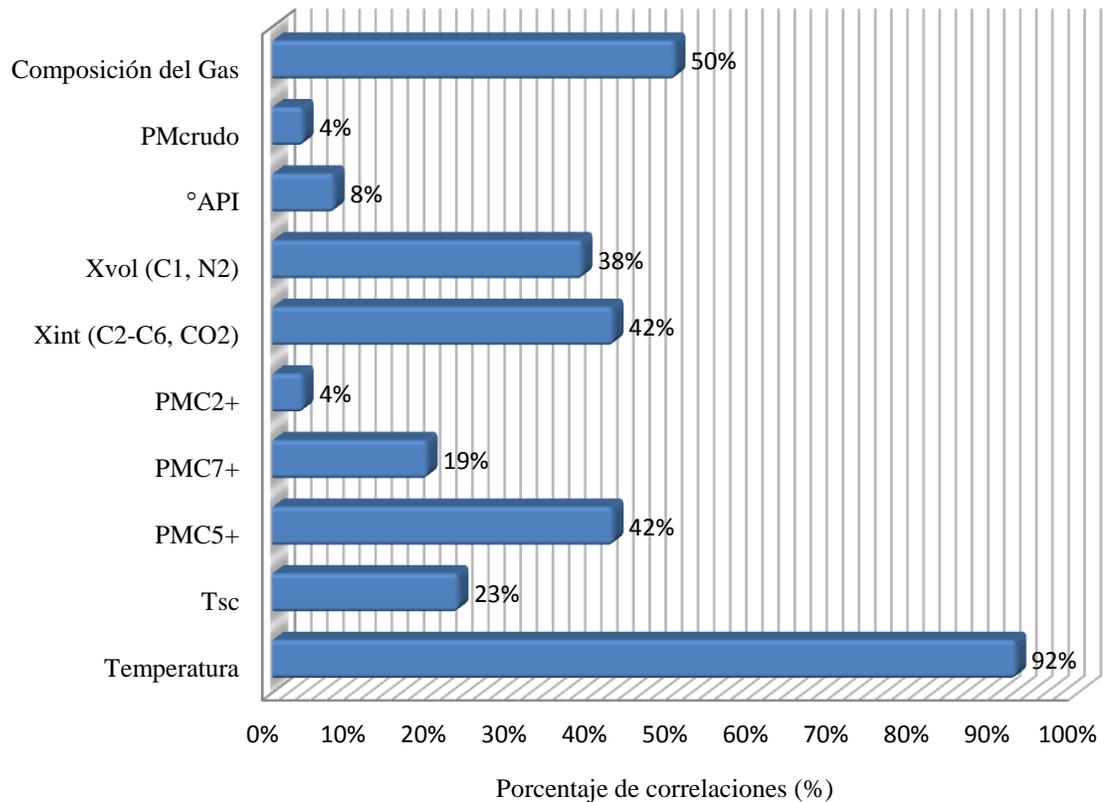


Figura 4.8. Representación gráfica de los parámetros usados en las correlaciones para predecir la presión mínima de miscibilidad en la inyección de CO₂

La temperatura del yacimiento es esencial en el desarrollo de las correlaciones y es uno de los parámetros de mayor uso y de mayor impacto en el proceso de miscibilidad, es por esto que un 92 por ciento de las correlaciones estudiadas toman en cuenta dicho parámetro y un 23 por ciento la temperatura pseudocrítica para una mezcla de gases cuando estamos en presencia de una corriente de CO₂ impuro. Por esta razón, la temperatura fue tomada en cuenta como parámetro indispensable en el desarrollo de todas las correlaciones estudiadas independientemente de la pureza del gas de inyección.

Por otra parte, el peso molecular de la fracción de C₅₊ es correlacionada en un 42 por ciento mientras que un 19 por ciento lo hace respecto al peso molecular de la fracción

de C_{7+} . Estos parámetros según Alston et al. (1985) mejoran la correlación más que la gravedad API del crudo que apenas es incluida en un ocho por ciento de las mismas. Esta última variable es únicamente tomada en cuenta en las correlaciones de Johnson y Pollin (1981) y National Petroleum Council (1976). Igualmente, se tiene que el cuatro por ciento de las correlaciones toma en cuenta el peso molecular de la fracción de C_{2+} . Dicha correlación corresponde a la elaborada por Orr y Silva (1987) donde se basa en que la extracción de hidrocarburos del crudo depende más del tamaño de sus moléculas. A su vez, existen correlaciones que toman en cuenta la composición del crudo en base a su peso molecular, pero apenas en un cuatro por ciento se aprecia esta última variable. Finalmente, se tiene que el peso molecular de la fracción de C_{5+} es uno de los parámetros más utilizados en el desarrollo de correlaciones.

Alguno autores como Zuo et al. (1993), Huang et al. (2003), Alston et al. (1985), Emera y Sarma (2005), Nezhad et al. (2011), Mousavi et al. (2006), Shokir (2007) y Askbari y Kasiri (2010), toman en cuenta la fracción de los componentes volátiles e intermedios presentes en el crudo mientras que Cronquist (1978) correlaciona la fracción de componentes más ligeros y Yuan (2004) los intermedios. Un 38 por ciento toma en cuenta la fracción de los componentes volátiles y un 42 por ciento la fracción de los componentes intermedios. Otros autores como Holm y Josendal (1974) no toman en cuenta estos parámetros ya que la cantidad de componentes ligeros e intermedios no influyeron directamente en sus estudios. Sin embargo, se consideraron importantes dichos parámetros debido a que la presión mínima de miscibilidad es afectada por la composición del crudo en el proceso de vaporización que se lleva a cabo al utilizar el CO_2 como gas de inyección.

Igualmente, la presencia de componentes distintos al CO_2 como CH_4 , H_2S , N_2 y componentes desde el C_2 al C_4 en la corriente del gas de inyección tienen un gran impacto en la presión mínima de miscibilidad, bien sea aumentando o disminuyendo la misma dependiendo del tipo de componente. Es por esto, que la composición del gas de inyección es tomada en cuenta en el 50 por ciento de las correlaciones existentes.

En la Figura 4.9 se muestra una gráfica del porcentaje de componentes usados en el desarrollo de correlaciones que toman en cuenta las impurezas presentes en el gas de inyección. Se observa que ciertos componentes como el CH₄ y N₂ son tomados en cuenta en un gran porcentaje de las correlaciones debido a que estos influyen directamente en el aumento de la presión mínima de miscibilidad, mientras que el H₂S y los componentes desde el C₂ al C₄ influyen en la disminución de la misma. Otro componente como el SO₂ es poco correlacionado, únicamente fue tomado en consideración en la correlación de Huang et al. (2003) y Mousavi et al. (2006).

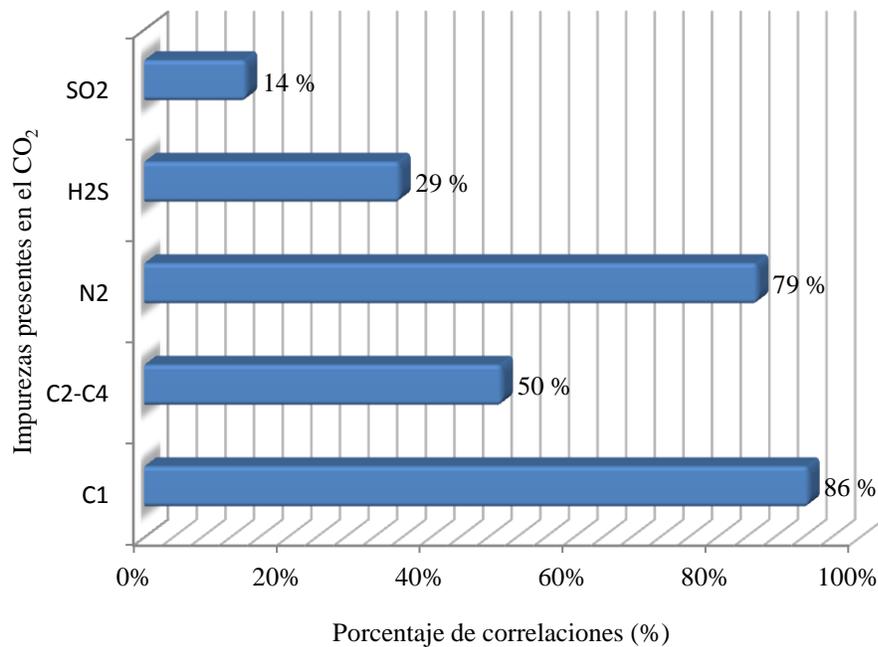


Figura 4.9. Representación gráfica de las impurezas usadas en las correlaciones para predecir la presión mínima de miscibilidad en la inyección de CO₂

4.2. ANÁLISIS ESTADÍSTICO

En esta sección se analiza el comportamiento de los parámetros de entrada que fueron utilizados para construir la red neuronal y se verificó la existencia de algún tipo de correlación entre los mismos. El análisis estadístico fue aplicado para 181 datos en total, de los cuales se obtuvo una matriz con 65 datos para el caso del CO₂ puro y una matriz con 116 datos para el caso del CO₂ impuro. Los datos utilizados para el desarrollo de la red neuronal provienen de las publicaciones de Holm y Josendal (1974), Graue y Zana (1981), Sebastian et al. (1984), Alston et al. (1985), Eakin y Mitch (1988), Harmon y Grigg (1988), Jaubert et al. (2001), Zuo et al. (1993), Wu (1995), Mousavi et al. (2000), Yuang et al. (2004), Bon et al. (2005), Shokir (2007), Wan Nurul et al. (2007) y Al_Ajmi et al. (2009).

De la información recopilada para originar la base de datos, no se reportaba en su totalidad los valores de los parámetros de entrada correspondientes a la temperatura del yacimiento, la composición del crudo, la composición del gas de inyección para el caso del CO₂ impuro y la PMM. Por lo tanto, se seleccionaron aquellos datos que poseían variables en común y se descartaron aquellos donde no se tuvieran los valores correspondientes para cada parámetro a evaluar. En consecuencia, los parámetros de entrada evaluados corresponden a la temperatura, el peso molecular de la fracción de C₅₊, la fracción de los componentes volátiles e intermedios, la concentración de CO₂ y de las impurezas presentes en el mismo tales como el N₂, CH₄, C₂-C₄ y H₂S.

Para llevar a cabo dicho análisis, se utilizaron medidas estadísticas tales como la media, mediana, máximo y mínimo, desviación estándar, varianza, covarianza, coeficiente de correlación, curtosis, asimetría y gráficas estadísticas como histogramas y diagramas de dispersión. A continuación se detallan los resultados obtenidos referentes a las medidas de tendencia central, dispersión absoluta y medidas de forma para cada uno de los parámetros analizados.

4.2.1. Análisis estadístico básico

En la Tabla 4.1 se observa el valor máximo y mínimo correspondiente a cada parámetro analizado. En el caso de la temperatura se tiene un rango que va desde 69,8 a 279 °F, el peso molecular de la fracción de C_{5+} de 136,18 a 302,5, la fracción de los componentes volátiles e intermedios de 0 a 54 y 1,2 a 52,76 por ciento respectivamente. En cuanto a las concentraciones de las impurezas presentes en el CO_2 tales como el N_2 cubre un rango de 0 a 19 por ciento, el CH_4 y los componentes que van desde el C_2 al C_4 abarcan valores de 0 a 28 por ciento y finalmente la concentración de H_2S se encuentra en una rango de 0 a 50 por ciento. Por lo tanto, los valores máximos y mínimos obtenidos, indican que existe un amplio rango de condiciones en los que se puede implementar la red neuronal desarrollada.

Los resultados obtenidos de curtosis para todas las variables expuestas en la Tabla 4.1 son positivos, varían entre 1,89 y 40,78. Para el caso de la temperatura, el peso molecular de la fracción de C_{5+} y la fracción de los componentes volátiles e intermedios, se obtuvieron valores de curtosis mucho más bajos que indican una ligera agrupación de los datos hacia la media, es decir, se tiene una distribución ligeramente leptocúrtica o apuntada. Dicho fenómeno de apuntamiento es reflejado en mayor grado con los valores obtenidos de curtosis para la concentración de las impurezas presentes en el CO_2 . El valor más alto corresponde al N_2 debido a que las concentraciones se encuentran dentro de un rango muy pequeño. Posteriormente, se tiene la fracción de C_2 a C_4 , H_2S y finalmente el CH_4 , siendo este último el que posee un valor de curtosis más bajo respecto a las otras impurezas. Tanto para el CO_2 , componentes del C_2 a C_4 , CH_4 y H_2S , se obtuvo una distribución leptocúrtica con una fuerte agrupación de los datos hacia la media, lo que trajo como resultado una distribución más apuntada que la normal. Igualmente sucede con la curtosis correspondiente a la concentración de CO_2 , donde los valores tienden a agruparse hacia la media de la misma. Estos fenómenos de apuntamiento se pueden observar gráficamente en los histogramas mostrados desde la Figura B.1 hasta la Figura B.9 del Apéndice B.

Tabla 4.1. Resultados estadísticos de los datos

	Temperatura (°F)	PMC₅₊	Xvol (N₂,CH₄)	Xint (CO₂, C₂-C₆)	CO₂	N₂	CH₄	C₂-C₄	H₂S
Media	162,02	193,11	20,35	24,26	88,66	0,47	4,78	1,69	4,30
Mediana	160,00	187,80	16,48	22,82	90,84	0,00	0,00	0,00	0,00
Mínimo	69,80	136,18	0,00	1,20	40,00	0,00	0,00	0,00	0,00
Máximo	279,00	302,50	54,00	52,76	100,00	19,00	28,00	28,00	50,00
Desviación estándar	47,02	38,10	13,01	13,33	14,05	2,13	6,34	3,84	11,31
Varianza	2211,31	1451,98	169,22	177,60	197,28	4,53	40,16	14,73	127,94
Curtosis	2,31	3,09	2,31	1,89	6,07	40,78	4,31	19,70	9,60
Coefficiente de asimetría	0,39	0,58	0,54	0,21	-1,80	5,81	1,32	3,64	2,73

De la misma manera, en la Tabla 4.1 se muestran los valores del coeficiente de asimetría para todas las variables estudiadas en un rango que va desde -1,80 a 5,81. Para el caso de la temperatura, el peso molecular de la fracción de C_{5+} y la fracción de los componentes volátiles e intermedios, se obtuvieron valores en el coeficiente de asimetría bajos (cerca de cero). Para estas variables existe una ligera agrupación de datos hacia la izquierda de la media, es decir, la distribución tiene asimetría o sesgo positivo. Sin embargo, puede considerarse que el comportamiento de dichos parámetros está muy cercano a la distribución normal ya que los valores nunca llegan a ser perfectamente simétricos, se obtuvieron resultados muy próximos a cero y el valor que se obtuvo de la media es muy cercano a la mediana. De una forma similar fue el comportamiento de la distribución de la concentración de las impurezas presentes en el CO_2 tales como el N_2 , CH_4 , C_2-C_4 y H_2S , pero en este caso el valor de la media es mucho mayor que la mediana, lo que refleja en mayor grado la concentración de datos hacia la izquierda de la media, de esta manera se obtuvo una asimetría o sesgo positivo. Para el caso del N_2 se obtuvo un coeficiente de asimetría de 5,81, siendo el valor más alto respecto al resto de las variables en estudio, esto resulta en una fuerte agrupación de los datos hacia la izquierda de la media, es decir, la distribución tiene asimetría o sesgo positivo. En el caso de la concentración de CO_2 se obtuvo un coeficiente de asimetría negativo, es decir, se tiene un sesgo negativo con una agrupación de los datos hacia la derecha de la media.

En el Apéndice B se muestran los histogramas de frecuencia porcentual para cada uno de los parámetros estudiados desde la Figura B.1 hasta la Figura B.9. Para el caso de la temperatura, se puede observar en la Figura B.1 una ligera agrupación de los datos hacia la izquierda de la misma. La mayor parte de los datos se encuentran concentrados aproximadamente entre 100 y 200 °F, lo que nos indica que la mayoría de las pruebas experimentales para predecir PMM fueron realizadas bajo esta condición. Igualmente sucede con el histograma del peso molecular de la fracción de C_{5+} mostrado en la Figura B.2, donde los datos tienden a agruparse hacia la izquierda y se encuentran más concentrados para valores entre 150 y 220, esto hace que tienda

a ser una distribución ligeramente leptocúrtica o apuntada. De la misma manera ocurre con los histogramas de la fracción de los componentes volátiles e intermedios mostrados en la Figura B.3 y Figura B.4, donde la mayor parte de los datos se encuentran en un rango de 5 a 40 y de 10 a 45 por ciento respectivamente. A diferencia de los parámetros antes analizados, los histogramas mostrados desde la Figura B.5 a la Figura B.9 del Apéndice B correspondientes a la concentración de CO_2 y a las impurezas presentes en el mismo, muestran una distribución de los datos sesgada hacia los extremos. Para el caso del histograma de la concentración de CO_2 como se muestra en la Figura B.5, la distribución tiene asimetría o sesgo negativo, es decir, la mayor parte de los datos se encuentran agrupados hacia la derecha entre 90 y 100 por ciento, siendo un comportamiento normal por ser el CO_2 el gas en estudio. Sin embargo, existen valores por debajo de este rango, ya que se toman en cuenta otras impurezas que se encuentran presentes en el CO_2 . En el caso de los histogramas correspondientes a la concentración de N_2 , CH_4 , $\text{C}_2\text{-C}_4$ y H_2S mostrados desde la Figura B.6 a la Figura B.9 respectivamente, se observa que la distribución tiene asimetría o sesgo positivo, es decir, la mayor parte de los datos se encuentran agrupados hacia la izquierda, reflejándose esta tendencia en mayor grado en el histograma de la Figura B.6 correspondiente a la concentración de N_2 donde los datos se encuentran agrupados aproximadamente entre 0 y 1 por ciento. El rango de valores donde se encuentran ubicados la mayor parte de los datos para el CH_4 , $\text{C}_2\text{-C}_4$ y H_2S es de 0 a 6, de 0 a 4 y de 0 a 3 por ciento respectivamente. De esta manera se pudo verificar que los resultados obtenidos de los histogramas que se muestran en el Apéndice B, coinciden en el comportamiento de los datos mostrados en la Tabla 4.1.

Para el caso de la desviación estándar, los valores obtenidos se pueden observar en la Tabla 4.1. Tanto para la temperatura, el peso molecular de la fracción de C_{5+} y la fracción de los componentes volátiles e intermedios, se observa que tienen mayor dispersión y desviación de los datos con respecto al valor medio de cada parámetro. A diferencia de los valores obtenidos para la concentración de CO_2 y de las impurezas

presentes en el mismo, donde la distribución de los datos con respecto a la media suele reflejarse en menor grado.

En la Tabla 4.2 y Tabla 4.3 se pueden observar los valores de covarianza y el coeficiente de correlación (R) respectivamente, que fueron obtenidos al correlacionar cada uno de los parámetros estudiados. Los valores que se obtienen en la Tabla 4.2 al correlacionar las mismas variables corresponden al valor de varianza para cada una de ellas. Cabe destacar que la covarianza no es fácilmente interpretable. En este caso, se recurrió al coeficiente de correlación para los análisis.

Los resultados obtenidos para los coeficientes de correlación entre cada uno de los parámetros mostrados en la Tabla 4.3 fueron bajos, varían de 0,01 a 0,61 en valor absoluto a excepción del coeficiente que resultó al correlacionar la concentración de CO_2 con el H_2S donde se tuvo un valor de -0,81. El H_2S fue únicamente tomado en cuenta en la base de datos de Eakin y Mitch (1988), Sebastian et al. (1984) y Alston et al. (1985) para pocos casos y la variación en la concentración de este es similar, por lo tanto aumenta la probabilidad de tener un coeficiente de correlación entre ambas variables más alto. El resto de los parámetros como la temperatura, el peso molecular de la fracción de C_{5+} , la fracción de los componentes volátiles e intermedios y las impurezas tales como el N_2 , CH_4 y componentes del C_2 a C_4 , poseen valores bajos en el coeficiente de correlación, por lo tanto se puede considerar la existencia de una relación no lineal entre cada una de las variables estudiadas.

Tabla 4.2. Valores de covarianza entre cada variable

	Temperatura (°F)	PMC₅₊	Xvol (N₂,CH₄)	Xint (CO₂, C₂-C₆)	CO₂	N₂	CH₄	C₂-C₄	H₂S
Temperatura (°F)	2211,31	-146,19	134,82	174,10	144,15	-10,78	-34,08	16,60	-115,91
PMC₅₊	-146,19	1451,98	-81,38	-242,70	-65,98	13,78	-4,14	8,74	47,63
Xvol (N₂,CH₄)	134,82	-81,38	169,22	33,33	43,40	-0,20	-20,02	7,12	-30,31
Xint (CO₂, C₂-C₆)	174,10	-242,70	33,33	177,60	19,60	-3,83	3,25	1,73	-20,76
CO₂	144,15	-65,98	43,40	19,60	197,28	-1,36	-54,20	-12,98	-128,75
N₂	-10,78	13,78	-0,20	-3,83	-1,36	4,53	-1,41	0,27	-2,03
CH₄	-34,08	-4,14	-20,02	3,25	-54,20	-1,41	40,16	5,30	10,14
C₂-C₄	16,60	8,74	7,12	1,73	-12,98	0,27	5,30	14,73	-7,31
H₂S	-115,91	47,76	-30,31	-20,76	-128,75	-2,03	10,14	-7,31	127,94

Tabla 4.3. Valores del coeficiente de correlación entre cada variable

	Temperatura (°F)	PMC₅₊	Xvol (N₂,CH₄)	Xint (CO₂, C₂-C₆)	CO₂	N₂	CH₄	C₂-C₄	H₂S
Temperatura (°F)	1	-0,08	0,22	0,28	0,22	-0,11	-0,11	0,09	-0,22
PMC₅₊	-0,08	1	-0,16	-0,48	-0,12	0,17	-0,02	0,06	0,11
Xvol (N₂,CH₄)	0,22	-0,16	1	0,19	0,24	-0,01	-0,24	0,14	-0,21
Xint (CO₂, C₂-C₆)	0,28	-0,48	0,19	1	0,10	-0,14	0,04	0,03	-0,14
CO₂	0,22	-0,12	0,24	0,10	1	-0,05	-0,61	-0,24	-0,81
N₂	-0,11	0,17	-0,01	-0,14	-0,05	1	-0,10	0,03	-0,08
CH₄	-0,11	-0,02	-0,24	0,04	-0,61	-0,10	1	0,22	0,14
C₂-C₄	0,09	0,06	0,14	0,03	-0,24	0,03	0,22	1	-0,17
H₂S	-0,22	0,11	-0,21	-0,14	-0,81	-0,08	0,14	-0,17	1

En el Apéndice B se cuenta con diagramas de dispersión entre cada una de las variables desde la Figura B.10 a la Figura B.45 que permiten la visualización de la distribución de los datos. En estos diagramas de dispersión se refleja que no existe ningún tipo de correlación entre las variables estudiadas y además se observa la no linealidad entre las mismas. De esta manera se verifica que los resultados obtenidos entre los valores de la Tabla 4.1 y las gráficas generadas para cada caso coinciden con el comportamiento de los datos.

Finalmente, tanto la temperatura, el peso molecular de la fracción de C_{5+} , la fracción de los componentes volátiles e intermedios, la concentración de CO_2 y de las impurezas presentes en el mismo, son parámetros que resultaron tener un comportamiento adecuado para ser implementados en el entrenamiento de la red neuronal.

4.3. REDES NEURONALES

En esta sección se analizó el comportamiento de las distintas arquitecturas de redes neuronales evaluadas y los aspectos relacionados al entrenamiento y prueba de las mismas hasta llegar a la estructura de red deseada, es decir, la que arroje el menor error en la predicción de la presión mínima de miscibilidad.

4.3.1. Selección de datos de entrenamiento y prueba

Para esta primera etapa, se tuvo una matriz de datos con 181 vectores de información para cada valor de PMM obtenida de la literatura. Cabe destacar, que las variables de entrada utilizadas para el entrenamiento y prueba de la red fueron la temperatura del yacimiento, la fracción de los componentes volátiles e intermedios presentes en el crudo, el peso molecular de la fracción de C_{5+} , la concentración de CO_2 y de las impurezas presentes en el mismo tales como el N_2 , CH_4 , C_2-C_4 y H_2S , además de contar con la PMM para cada caso. En total se cuenta con nueve variables de entrada para entrenar y probar la red.

Para evaluar el comportamiento de las distintas arquitecturas de la red se utilizó un 70 por ciento de la base de datos para la fase de entrenamiento, lo que abarca 127 valores del total y para la prueba de la misma, se utilizó el 30 por ciento de la base de datos restante, comprendiendo 54 valores del total. Para esto se generaron números aleatorios que permitieron seleccionar los datos de entrenamiento y prueba al azar, de tal forma que disminuya el sesgo.

En esta primera fase donde se evaluaron los posibles escenarios para la construcción de la red neuronal, las diferentes arquitecturas evaluadas fueron hechas únicamente para un conjunto (*set*) de la base de datos. Esto quiere decir que con el mismo conjunto de datos de entrenamiento y prueba se corrieron todos los escenarios posibles variando el error cuadrático medio, función entrenamiento y transferencia, número de capas ocultas y neuronas de la red, con el objetivo de minimizar el tiempo. De lo contrario se requieren grandes cantidades de corridas de la red si se llegara a

utilizar distintos *sets* de datos de entrenamiento y prueba en esta fase, ya que por cada *set* de datos se tendrían que evaluar todos los parámetros que forman la arquitectura de la red.

4.3.2. Preprocesamiento de los datos

El preprocesamiento de los datos se realizó con el fin de tener las variables de entrada y la salida de la red en un mismo rango de magnitud, ya que las variables utilizadas para la construcción de la misma se encuentran en escalas totalmente diferentes. Por lo tanto, se quiso contar con una distribución uniforme de los datos para procesos que impliquen reconocimiento de patrones y facilitar así el aprendizaje de la red. Si los datos de entrada no son normalizados dentro de un rango aceptable, la red neuronal no realiza predicciones precisas y resulta ser menos eficiente. De la misma manera, la normalización de los datos permite que la red sea entrenada rápidamente.

Se evaluaron dos escenarios para el preprocesamiento de datos, la cual incluye normalización en los intervalos $[0,1]$ y $[-1,1]$. En el caso de la normalización de los datos en el intervalo $[0,1]$ se obtuvieron mejores resultados en los errores de entrenamiento y prueba, es decir, se lograron errores más bajos respecto a la normalización de los datos en el intervalo $[-1,1]$. Por lo tanto, los resultados que se obtienen en el rendimiento de la red neuronal dependen del rango en que se normalicen los datos.

4.3.3. Entrenamiento de la red neuronal

Para las redes neuronales es necesario conocer la arquitectura que tendrá la misma, esto implica determinar el número de capas ocultas y las neuronas que tendrán cada una de ellas, con el objetivo de conseguir la red neuronal más sencilla que mejor se aproxime al valor de PMM deseado. Para esto se hizo un análisis de sensibilidad con cada uno de los parámetros que conforma la red tales como la función de

entrenamiento y transferencia, número de capas ocultas, número de neuronas en cada capa oculta y el *Goal* o error cuadrático medio que se tiene como objetivo.

Luego de haber iniciado los pesos y el *bias* con valores aleatorios, la red fue entrenada para cada una de las arquitecturas analizadas. Cabe destacar que para cada arquitectura de red evaluada, la misma fue corrida tres veces.

También existen ciertos criterios de parada para el entrenamiento de la red en el caso de que la misma no converja rápidamente a algún resultado o se quiera evitar el sobreajuste. El entrenamiento de la red es paralizado cuando:

- El error cuadrático medio o *goal* cae por debajo de 1×10^{-3}
- La magnitud del gradiente cae por debajo de 1×10^{-6}
- Se alcanza el número máximo de épocas (iteraciones) para el entrenamiento (500 épocas).

A continuación se explica detalladamente los resultados obtenidos para cada parámetro en las distintas arquitecturas de red evaluadas.

(a) Error cuadrático medio o *Goal*

El error cuadrático medio o *goal* es uno de los criterios de parada en el entrenamiento de la red neuronal. Se hizo análisis de sensibilidad para tolerancias de 1×10^{-7} , 1×10^{-5} , 1×10^{-3} , 1×10^{-2} y 1×10^{-1} .

Uno de los problemas que ocurre durante el entrenamiento de la red neuronal es el sobreajuste. Esto es observado cuando el error promedio que se obtiene al entrenar la misma es muy pequeño, pero cuando la red es probada el error resultante es muy alto. Esto trae como consecuencia que la red memorice los datos mostrados en el entrenamiento y no tenga la capacidad de aprender para generalizar nuevas situaciones.

En el caso de los errores promedio obtenidos para una tolerancia de 1×10^{-7} y 1×10^{-5} con el algoritmo de *Levenberg-Marquardt* (*trainlm*), se observó que los errores de

entrenamiento tenían valores muy bajos, a diferencia de los errores de prueba que resultaban ser muy altos. Igualmente, para este caso se observó que la curva de rendimiento de la red en función de las épocas oscilaba, este comportamiento fue como consecuencia del sobreajuste de la misma. Para el algoritmo *Scaled Conjugate Gradient (trainscg)* la red no logró converger a algún resultado, por lo tanto se detenía el entrenamiento cuando era alcanzado el número máximo de épocas. En consecuencia, para ambos casos la red era sobreentrenada.

Para una tolerancia de 1×10^{-3} , se lograron tener resultados mucho más aceptables para todas las arquitecturas evaluadas. Por último, a partir de una tolerancia de 1×10^{-2} los errores de entrenamiento y prueba comenzaron a aumentar, debido a que no se entrenaba bien la red, lo que trae como consecuencia que no se alcance el mínimo global. Igualmente sucede para errores cuadráticos medios de 1×10^{-1} , pero en este caso los errores arrojados por la prueba de la red resultaron ser demasiado altos, trayendo como consecuencia un subajuste de la misma. Finalmente, los errores promedios más bajos, corresponden a una tolerancia de 1×10^{-3} y por lo tanto la misma fue tomada en cuenta para la selección de la arquitectura final de la red neuronal.

En la Figura 4.10 se muestra el error relativo porcentual de los datos de prueba en función del error cuadrático medio y el número de neuronas para una red con una capa oculta, basada en la función de entrenamiento *trainlm* y la función transferencia *logsig*. En esta gráfica se puede apreciar que los errores de prueba para tolerancias entre 1×10^{-7} y 1×10^{-3} disminuyen progresivamente, en cambio al caer el valor del error cuadrático medio por encima de 1×10^{-2} dichos errores van aumentando.

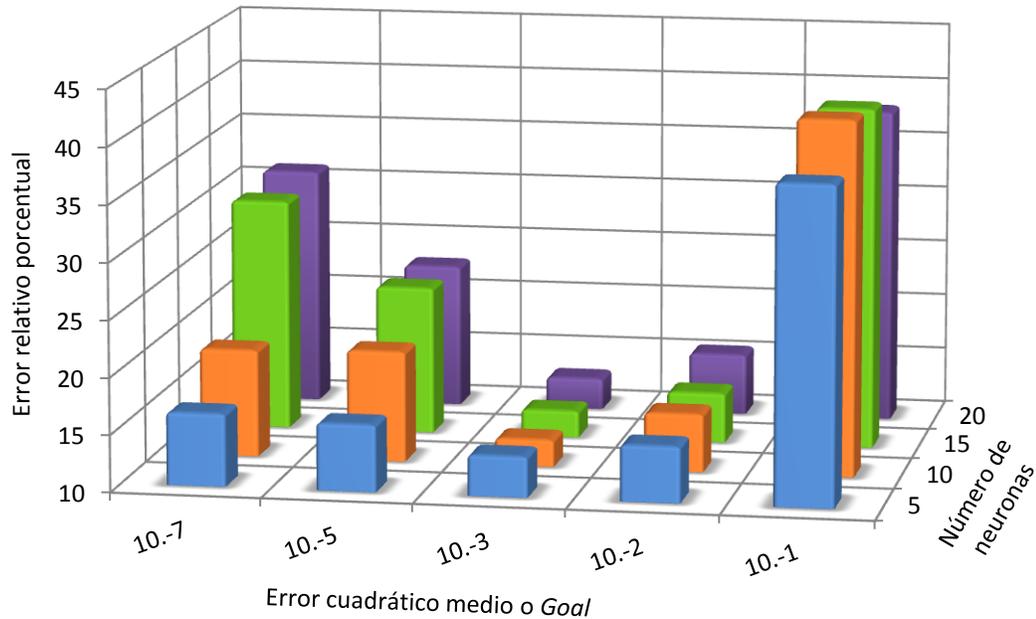


Figura 4.10. Gráfica del error relativo porcentual de prueba en función del error cuadrático medio y el número de neuronas para una capa oculta

(b) Algoritmo de entrenamiento (Función de entrenamiento)

El entrenamiento tiene como objetivo ajustar los pesos y el *bias* de la red neuronal de acuerdo a ciertos algoritmos o métodos numéricos. Para llevar a cabo dicho ajuste de los pesos, se utilizaron las funciones de entrenamiento *trainlm* (*Levenberg-Marquardt Backpropagation*) y *trainscg* (*Scaled Conjugate Gradient Backpropagation*).

La velocidad del algoritmo depende de factores como la complejidad del problema, número de datos de entrenamiento, número de pesos, el *bias* de la red y el error cuadrático medio o *goal*. En el caso del algoritmo empleado para la función *trainscg* se requirió mayor número de iteraciones o épocas para converger a algún resultado que la función *trainlm* donde el error cuadrático medio disminuye mucho más rápido respecto al tiempo, lo que nos indica que el método de *Levenberg-Marquardt Backpropagation* parece ser uno de los algoritmos más rápidos en el entrenamiento

de redes neuronales de tamaño moderado. En consecuencia, se tomó como algoritmo de entrenamiento para la fase de selección de la red neuronal final la función *trainlm*.

En la Figura 4.11 se muestran las curvas del error durante la fase de entrenamiento en función del número de épocas para una arquitectura de red específica. El caso *a)* corresponde a la red cuando es entrenada bajo el algoritmo *Scaled Conjugate Gradient Backpropagation (trainscg)* y el caso *b)* cuando es entrenada bajo el algoritmo de *Levenberg-Marquardt Backpropagation (trainlm)*, donde se corrobora que la función *trainlm* suele ser mucho más eficiente y rápida en el entrenamiento de la red que la función *trainscg* donde se requiere mayor número de épocas para lograr la convergencia de la misma. Cabe destacar que para ambos casos se tomó en cuenta la función transferencia *logsig*, una tolerancia en el error cuadrático medio de 1×10^{-3} y una capa oculta formada por 20 neuronas.

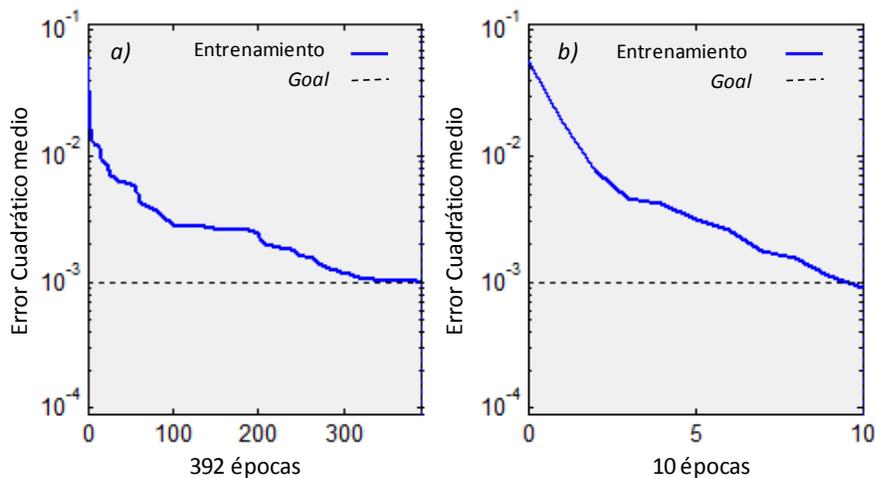


Figura 4.11. Caso *a)* Rendimiento de la red para la función de entrenamiento *trainscg*. Caso *b)* Rendimiento de la red para la función de entrenamiento *trainlm*

(c) Función transferencia

La función transferencia tiene como objetivo generar la salida de cada neurona que conforma la red a partir de las entradas de la misma. Para esto fueron utilizadas las

funciones transferencia *logsig* (sigmoide), *tansig* (tangente hiperbólica) y *purelin* (lineal) por ser las más implementadas en las redes neuronales. En el caso de los datos normalizados en el intervalo $[0,1]$ se utilizaron únicamente como funciones transferencia *purelin* y *logsig*. A diferencia de los datos normalizados en el intervalo $[-1,1]$ donde se utilizó como función *purelin* y *tansig*. Es importante señalar que la función transferencia para todas las neuronas ubicadas entre las capas ocultas y la capa de salida se mantuvo igual, es decir, no fueron combinadas dichas funciones para una arquitectura de red específica.

Los errores de entrenamiento y prueba obtenidos por medio de las redes entrenadas con la función de transferencia *purelin*, son similares para todas las arquitecturas evaluadas como consecuencia de un ajuste lineal. Los mismos se mantuvieron aproximadamente entre 12,9 por ciento para el entrenamiento y 13,4 por ciento para la prueba.

Para la función de transferencia *tansig* se lograron obtener arquitecturas de red con errores aceptables de entrenamiento y prueba. Sin embargo, cuando esta función fue utilizada con el algoritmo de entrenamiento correspondiente a la función *trainscg* (*Scaled Conjugated Gradient*), no se aseguraba la convergencia de la red y como consecuencia se paralizaba el entrenamiento cuando llegaba al número máximo de épocas. Cuando la función de transferencia *tansig* fue implementada con la función de entrenamiento *trainlm* (*Levenberg-Marquart*), se lograron obtener errores de entrenamiento y prueba un poco más altos respecto a la función anteriormente utilizada. En este caso se logró converger al resultado de manera más rápida pero con errores mucho más altos, ya que para algunas arquitecturas no se lograba entrenar la red correctamente.

En el caso de la función transferencia *logsig* los errores de entrenamiento y prueba resultaron ser aceptables y similares para ambos algoritmos. Sin embargo, el comportamiento de dicha función cuando fue implementada con el algoritmo de entrenamiento *trainscg* no aseguraba la convergencia de la red y nuevamente como

en el caso anterior, se paralizaba el entrenamiento cuando llegaba al número máximo de épocas.

Finalmente, se tomó para la fase de selección de la red neuronal final la función transferencia *logsig* con los datos normalizados en el intervalo $[0,1]$ ya que se aseguró la convergencia de la red al ser utilizado con el algoritmo de entrenamiento de *Levenberg-Marquardt*.

En la Figura 4.12 se muestra el error relativo porcentual de prueba en función del número de neuronas para un modelo de red con una capa oculta y la función transferencia implementada, donde se puede observar que para la función de transferencia *purelin* los errores son similares independientemente del número de neuronas utilizadas. Igualmente, se corrobora el comportamiento de la función transferencia *tansig* y *logsig*, obteniendo para esta última función errores de prueba mucho más bajos.

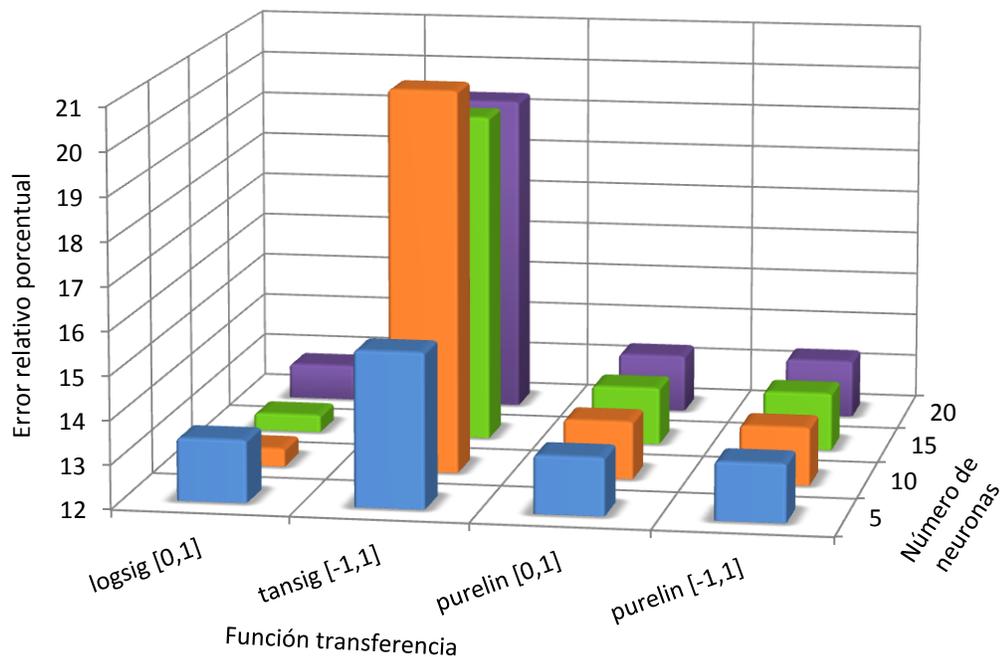


Figura 4.12. Gráfica del error relativo porcentual de prueba en función del número de neuronas y la función transferencia

(d) Número de capas ocultas

El número de capas ocultas depende de la complejidad del problema a resolver. Inicialmente, se evaluó el comportamiento de la red con una capa oculta variando el número de neuronas, el error cuadrático medio o *goal*, la función de entrenamiento y la función transferencia. Se observaron los errores promedios arrojados por el entrenamiento y la prueba de la red, y posteriormente se verificó si agregando una segunda capa oculta los mismos podían disminuir. Por lo tanto, fueron analizadas distintas arquitecturas de red con una y dos capas ocultas.

En el caso de la función de transferencia *purelin* al ser implementada con la función de entrenamiento *trainlm* y *trainscg*, se obtuvieron los mismos valores en los errores de entrenamiento y prueba con respecto a una y dos capas ocultas, es decir, que en este caso el número de capas ocultas no influyó directamente en la disminución del error. Esto ocurre como consecuencia de un ajuste lineal.

Igualmente, las funciones de transferencia *logsig* y *tansig* fueron analizadas para una y dos capas ocultas. Al utilizar una capa oculta se lograron encontrar errores aceptables para ciertas arquitecturas, sin embargo, al agregar una capa adicional estos errores de entrenamiento y prueba disminuyeron. En consecuencia, se utilizaron dos capas ocultas para la fase de selección de la red final.

(e) Número de neuronas

Las redes neuronales son sensibles al número de neuronas que poseen en sus capas ocultas. Es por esto, que fue evaluado el comportamiento de la misma aumentando progresivamente el número de neuronas para cada capa. En el caso de la red construida con una capa oculta se obtuvieron los errores de entrenamiento y prueba correspondientes con cinco, diez, quince y veinte neuronas. A diferencia de la red que contenía dos capas ocultas, donde el análisis fue llevado a cabo con cuatro y veinte neuronas. La variación de las mismas fue realizada tanto para la función de entrenamiento *trainscg* y *trainlm* como para las funciones transferencia *logsig*, *tansig*

y *purelin*, además de tomar en cuenta las distintas tolerancias del error cuadrático medio o *goal*.

En la Figura 4.13 se muestra el error relativo porcentual de prueba en función del número de neuronas para una red con dos capas ocultas, basada en la función de entrenamiento *trainlm* y la función transferencia *logsig*, donde se puede observar que existe poca variación en los errores de prueba, independientemente del número de neuronas que sean implementadas en cada capa oculta. Es por esta razón que en esta fase no se definió exactamente el número de neuronas que contendría cada una de estas capas, ya que no se logró apreciar con claridad la variación del error promedio de prueba de la red.

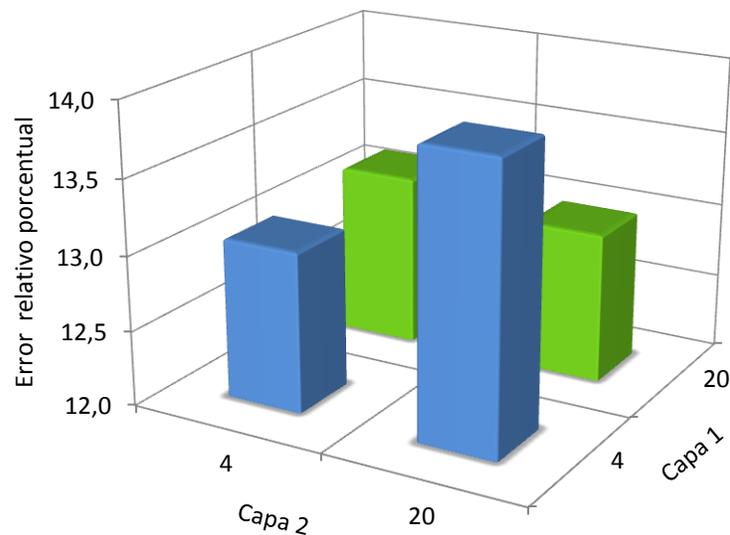


Figura 4.13. Gráfica del error relativo porcentual de prueba en función del número de neuronas para dos capas ocultas

Finalmente, en la Tabla 4.4 se observan los parámetros que fueron definidos para ser implementados en la siguiente fase donde fue seleccionada la arquitectura final de la red como resultado de los análisis descritos anteriormente. Dichos parámetros comprenden el algoritmo de entrenamiento, la función transferencia, número de capas ocultas y la tolerancia del error cuadrático medio o *goal*.

Tabla 4.4. Parámetros seleccionados para la fase de optimización de la red

Parámetro evaluado	Parámetro seleccionado
Algoritmo de entrenamiento	<i>Levenberg-Marquardt (trainlm)</i>
Función transferencia	<i>logsig</i>
Número de capas ocultas	2 capas
Tolerancia del Error cuadrático medio o <i>goal</i>	1×10^{-3}

4.4. SELECCIÓN DE LA ARQUITECTURA FINAL DE LA RED NEURONAL

En esta sección se define en forma definitiva la arquitectura de la red neuronal. Para esto, se llevó a cabo un análisis de sensibilidad respecto a distintos *sets* o conjuntos de datos y al número de neuronas correspondientes en cada capa oculta, dejando fija la función de entrenamiento, función transferencia, número de capas ocultas y la tolerancia del error cuadrático medio.

Para evaluar el comportamiento de las distintas arquitecturas de la red se utilizó un 80 por ciento de la base de datos para la fase de entrenamiento, lo que abarca 145 valores del total y para la prueba de la misma, se utilizó el 20 por ciento de la base de datos restante, comprendiendo 36 valores. Para dividir la misma en dichos porcentajes, se generaron números aleatorios con el fin de elegir los datos al azar y disminuir el sesgo.

En esta fase se trabajó con distintos conjuntos de datos de entrenamiento y prueba donde se verificó el comportamiento de la red al variar los mismos. En total se contó con 15 conjuntos de datos para el entrenamiento y evaluación de la red. Es importante mencionar que estos conjuntos no difieren de los valores de la base de datos original, sino en el orden de los datos de entrenamiento y prueba que se seleccionaron.

De los 15 conjuntos de datos seleccionados, en la Tabla 4.5 se reportan los errores relativos promedios, al igual que el coeficiente de correlación y el número de

neuronas correspondiente para cinco conjuntos de datos. Estos últimos, fueron seleccionados de acuerdo al error promedio de prueba arrojado por la red, es decir, se seleccionaron aquellos donde los errores en la predicción de la presión mínima de miscibilidad resultaron ser más bajos.

Tabla 4.5. Redes neuronales optimizadas

Set de datos	Error relativo promedio (%)		Coeficiente de correlación (R)		Número de Neuronas	
	Entrenamiento	Prueba	Entrenamiento	Prueba	Capa 1	Capa 2
<i>a</i>	4,23	7,49	0,99	0,96	12	8
<i>a</i>	3,29	7,64	0,99	0,94	16	4
<i>b</i>	3,64	6,98	0,99	0,97	16	8
<i>c</i>	4,13	6,68	0,99	0,97	8	4
<i>d</i>	3,99	6,96	0,99	0,95	20	16
<i>e</i>	4,09	6,83	0,99	0,95	20	12

4.4.1. Selección de la red neuronal

La estructura de la red neuronal más exitosa es aquella donde se tiene el error de predicción más bajo para un determinado conjunto de datos, es decir, cuando la diferencia entre el valor predicho y el valor real es lo más pequeña posible. Igualmente, cuando la arquitectura de la red neuronal resulta ser sencilla y existe poca diferencia entre el coeficiente de correlación de entrenamiento y prueba.

En el caso del *set* de datos *a*, se obtuvieron dos redes con errores de entrenamiento y prueba bajos, al igual que una arquitectura sencilla. Sin embargo, el coeficiente de correlación de prueba de la red que obtuvo un error de 7,64 por ciento es más bajo

respecto al coeficiente de las otras redes obtenidas. Por lo tanto, el ajuste de los datos es menor. Igualmente, se tiene que los errores de entrenamiento y prueba para ambas redes resultantes del conjunto de datos a son bajos, sin embargo al compararlos con las distintas redes obtenidas se aprecia que estos valores están por encima de los errores que corresponden a las otras redes. Es por esto que las correlaciones resultantes del *set* de datos a quedan descartadas.

Posteriormente, al verificar el coeficiente de correlación de prueba para el *set* de datos d y e , se observa que el ajuste de los mismos es relativamente bajo. A su vez, poseen la arquitectura más compleja con respecto a las otras redes analizadas en la Tabla 4.5 y lo que se busca es una red sencilla con el número de neuronas más bajo posible. Para el caso de la red correspondiente al *set* de datos d , se tienen 20 y 16 neuronas en sus respectivas capas ocultas y en cuanto a la red resultante del *set* de datos e se tienen 20 y 12 neuronas en sus respectivas capas. Es por esto, que las correlaciones obtenidas de las redes neuronales entrenadas con el *set* de datos d y e son descartadas, incluso cuando los errores de entrenamiento y prueba se encuentran entre los más bajos.

Por otra parte, se tiene que las redes resultantes del *set* de datos b y c , son unas de las que poseen los errores de prueba más bajos. Sin embargo, fue necesaria la selección de la mejor red neuronal y es por esto que se recurrió al análisis de su arquitectura para elegir la que posea la estructura más sencilla. Para el caso de la red resultante del *set* de datos b , se tienen 16 y 8 neuronas en sus respectivas capas. Sin embargo, la red que resulta del *set* de datos c , posee la menor cantidad de neuronas en sus capas ocultas, con ocho neuronas en la primera capa y cuatro neuronas en la segunda. Es por esto que la correlación resultante del *set* de datos b queda descartada.

Finalmente, fue seleccionada la correlación desarrollada en base al *set* de datos c , debido a que posee el error de predicción más bajo con un 6,68 por ciento, la diferencia en los coeficientes de correlación de entrenamiento y prueba es relativamente baja, al igual que sus valores indican un buen ajuste de los datos

utilizados. A su vez, es la red neuronal que posee la arquitectura más sencilla en cuanto al número de neuronas utilizadas, con ocho neuronas en la primera capa oculta y cuatro neuronas en la segunda capa.

En la Figura 4.14 se muestra el error relativo porcentual de los datos de evaluación en función del número de neuronas para el conjunto de datos c , donde se puede corroborar que el error de prueba más bajo corresponde a la red neuronal con ocho neuronas en la primera capa oculta y cuatro neuronas en la segunda capa.

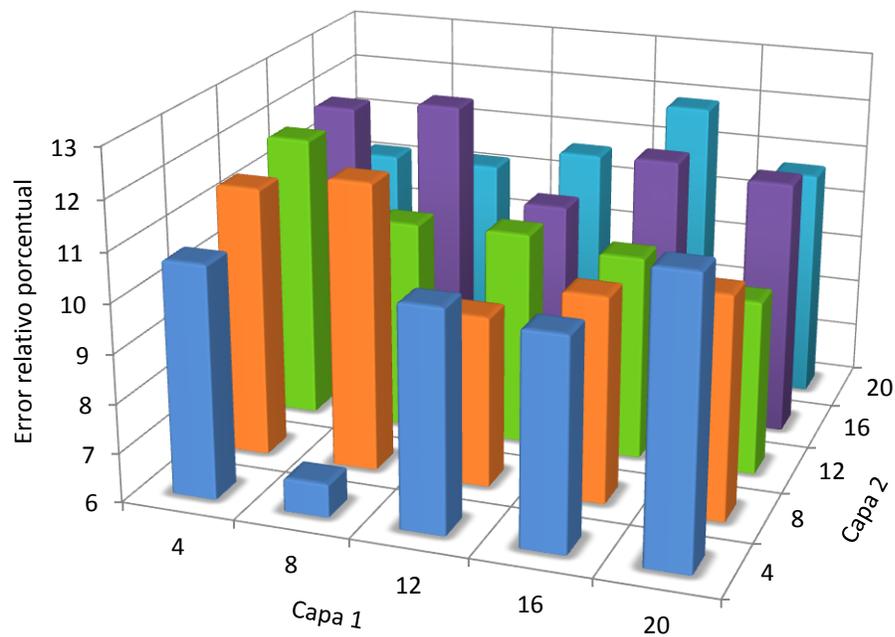


Figura 4.14. Gráfica del error relativo porcentual de prueba en función del número de neuronas para dos capas ocultas de la red neuronal optimizada

Por otra parte, en la Figura 4.15 y Figura 4.16 se muestra la correlación entre los datos experimentales y los obtenidos con la red neuronal, tanto para los datos de entrenamiento como los de evaluación. El valor del coeficiente de correlación en las gráficas correspondientes demuestra un alto ajuste de los datos implementados en el entrenamiento y prueba de la misma.

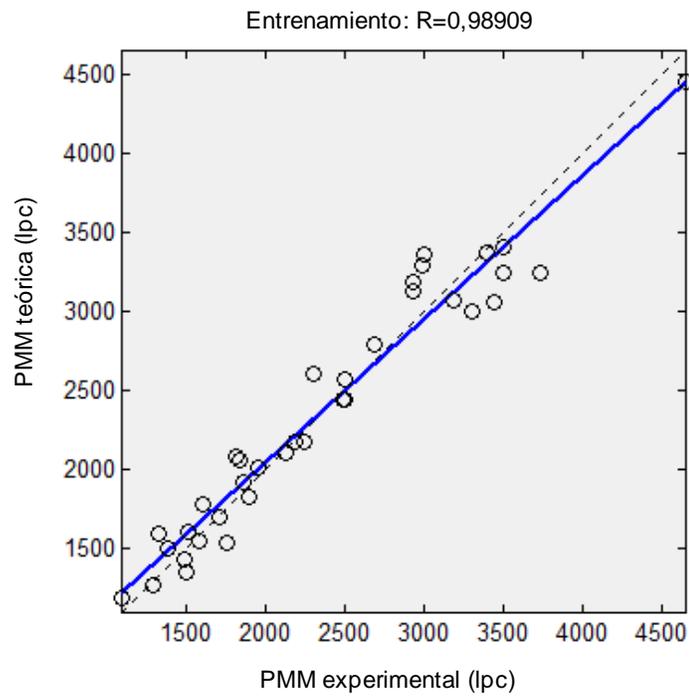


Figura 4.15. PMM estimada en función de la PMM experimental para la prueba de la red.

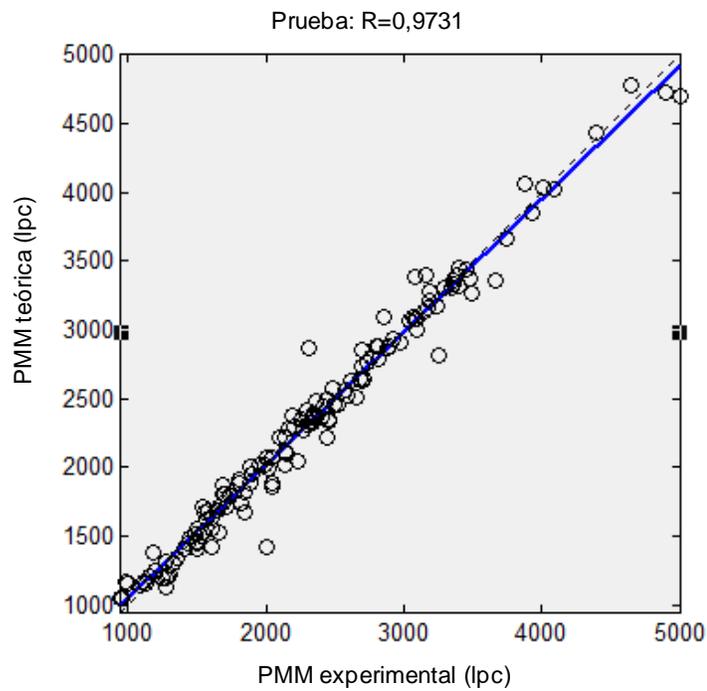


Figura 4.16. PMM estimada en función de la PMM experimental para el entrenamiento de la red

Otra de las gráficas generadas por el modelo se muestra en la Figura 4.17, donde se tiene el error cuadrático medio o *goal* en función del número de épocas de la red neuronal. Por medio de esta gráfica, se demuestra el comportamiento de la misma durante la fase de entrenamiento hasta que la red logra converger a algún resultado. Se puede observar, que en este caso la red culmina el entrenamiento al llegar a 18 épocas, es decir, cuando logró alcanzar el error cuadrático medio o *goal* con una tolerancia de 1×10^{-3} para dicha cantidad de ciclos. De esta manera, se puede corroborar que la función *trainlm* (*Levenberg-Marquardt Backpropagation*) es uno de los algoritmos más rápidos en el entrenamiento de redes neuronales artificiales tipo regresión.

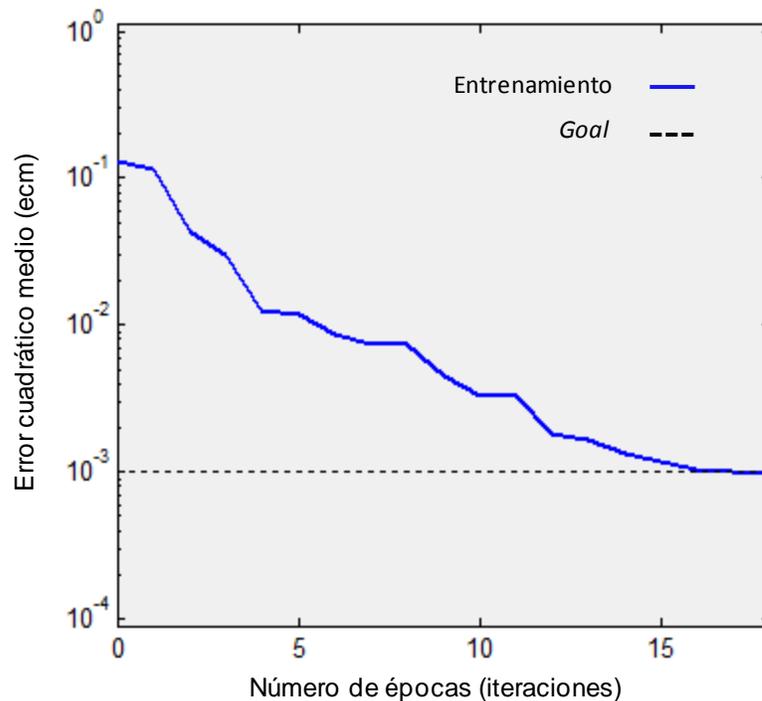


Figura 4.17. Gráfica del error cuadrático medio en función del número de épocas de la red neuronal

Finalmente, en la Tabla 4.6 se muestra un resumen de los parámetros y la arquitectura de la red neuronal desarrollada en esta investigación. Igualmente, se muestra el rango de aplicabilidad de la misma en base a las variables seleccionadas para el entrenamiento de la red.

Tabla 4.6. Rango de aplicación, parámetros de entrenamiento y arquitectura de la red neuronal desarrollada

	Temperatura (°F)	PMC₅₊	Xvol (N₂,CH₄)	Xint (CO₂, C₂-C₆)	CO₂	N₂	CH₄	C₂-C₄	H₂S
Mínimo	69,80	136,18	0,00	1,20	40,00	0,00	0,00	0,00	0,00
Máximo	279,00	302,50	54,00	52,76	100,00	19,00	28,00	28,00	50,00
Algoritmo de entrenamiento					<i>Levenberg-Marquardt (trainlm)</i>				
Función transferencia					<i>logsig (sigmoide)</i>				
Tolerancia del error cuadrático medio					1x10 ⁻³				
Número de neuronas 1° capa oculta					8				
Número de neuronas 2° capa oculta					4				

A su vez, para tener una mejor representación de la arquitectura del modelo desarrollado, se muestra en la Figura 4.18 la arquitectura de la red neuronal final para predecir la presión mínima de miscibilidad en la inyección de CO₂ puro e impuro, donde se observan las variables de entrada utilizadas para entrenar la red, al igual que la arquitectura de la misma con el número de capas ocultas y neuronas correspondientes.

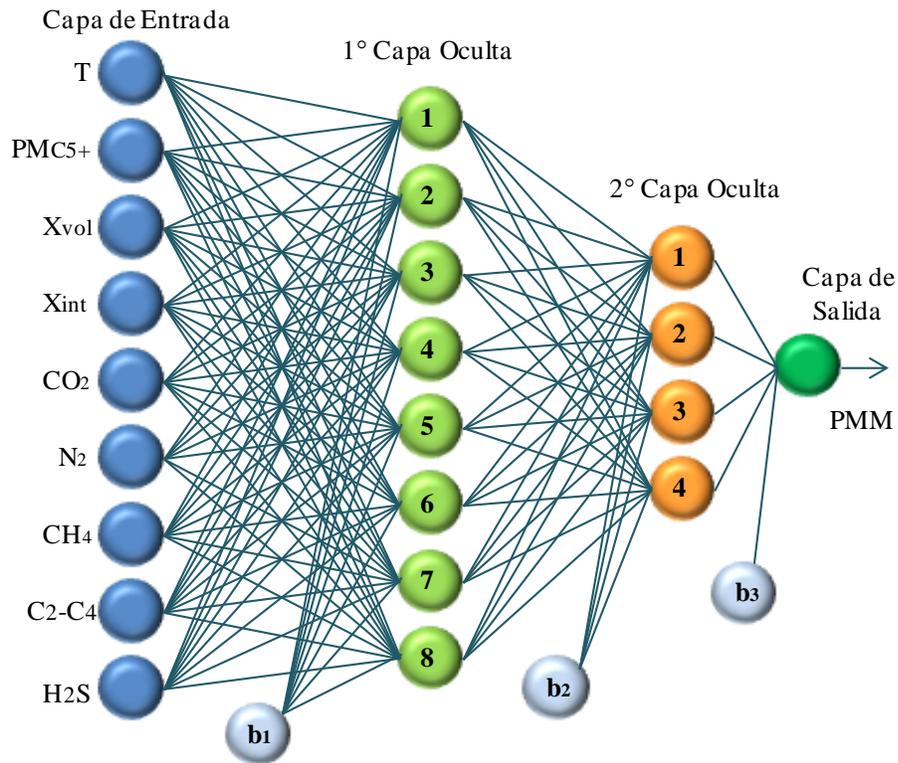


Figura 4.18. Arquitectura final de la Red Neuronal para predecir la PMM en la inyección de CO₂

Igualmente, la red neuronal de la Figura 4.18 puede ser representada matemáticamente por medio de la ecuación matricial:

$$PMM_p = \text{logsig}(LW_2 * \text{logsig}(LW_1 * \text{logsig}(IW * p + b_1) + b_2) + b_3) \quad 4.1$$

Donde:

p : Vector de entrada (9x1)

IW : Matriz de pesos entre la capa de entrada y la primera capa oculta (8x9)

LW_1 : Matriz de pesos entre la primera capa oculta y la segunda capa oculta (4x8)

LW_2 : Matriz de pesos entre la segunda capa oculta y la capa de salida (1x4)

b_1 : Vector de tendencias o *bias* de las neuronas en la primera capa oculta (8x1)

b_2 : Vector de tendencias o *bias* de las neuronas en la segunda capa oculta (4x1)

b_3 : Tendencia o *bias* de la neurona en la capa de salida

PMM_p : Valor estimado por la red neuronal

Los vectores de tendencia o *bias*, al igual que los pesos correspondientes de la correlación desarrollada en esta investigación, se muestran a continuación desde la Tabla 4.7 a la Tabla 4.12.

Tabla 4.7. Vector de tendencias o *bias* de las neuronas en la primera capa oculta (b_1)

Neuronas de la primera capa oculta	b_1
1	10,041925
2	5,629649
3	-3,717359
4	4,204047
5	-0,322576
6	0,346214
7	-0,531967
8	7,939969

Tabla. 4.8. Matriz de pesos entre la capa de entrada y la primera capa oculta (*IW*)

Neuronas ocultas	Neuronas de entrada								
	1	2	3	4	5	6	7	8	9
<i>IW</i>	<i>T</i>	<i>PM_{C5+}</i>	<i>X_{vol}</i>	<i>X_{int}</i>	<i>CO₂</i>	<i>N₂</i>	<i>CH₄</i>	<i>C₂-C₄</i>	<i>H₂S</i>
1	-3,151663	2,340150	-2,413846	-1,330103	1,453491	-2,982238	0,418139	-2,660173	0,347380
2	-0,075603	-3,830991	1,186965	-6,152602	-3,579369	-0,646663	1,389724	4,726675	0,565622
3	7,836813	-5,408437	-5,207229	1,409493	2,664934	-9,072103	0,879333	2,962439	1,029494
4	-2,033105	-5,831264	0,544315	-4,149068	-2,628977	-4,984066	-0,619863	2,586069	2,277243
5	-6,563488	4,013093	2,773580	-0,258297	0,739621	2,478587	0,550829	-0,159658	0,833391
6	0,224607	-5,474297	0,733483	4,533254	-5,162978	-1,028483	4,978808	-2,153426	-1,444217
7	3,972163	6,544274	5,723162	-9,481119	1,654273	-1,305394	-5,751788	-1,602377	1,976835
8	2,596621	-7,375412	-4,214783	4,151638	-2,219228	-2,452431	-2,221673	6,923406	-1,603694

Tabla 4.9. Vector de tendencias o *bias* de las neuronas en la segunda capa oculta (b_2)

Neuronas de la segunda capa oculta	b_2
1	6,344748
2	0,336473
3	-0,617135
4	-8,965176

Tabla 4.10. Matriz de pesos entre la primera capa oculta y la segunda capa oculta (LW_I)

Neuronas de la segunda capa oculta LW_I	Neuronas de la primera capa oculta							
	1	2	3	4	5	6	7	8
1	-0,514311	-6,246890	0,112318	0,349417	3,514496	1,437986	-0,409218	-2,407805
2	-3,367314	-1,262253	3,025563	3,110286	2,761666	-5,117867	1,891641	1,917762
3	0,640052	-3,780076	1,460000	-1,345100	-1,160247	0,566745	1,815082	-0,497227
4	-1,696286	-3,465904	6,226385	4,193977	4,448605	-1,646341	1,279778	7,022495

Tabla 4.11. Vector de tendencias o *bias* de la neurona en la capa de salida (b_3)

Neurona de salida	b_3
1	2,079050

Tabla 4.12. Matriz de pesos entre la segunda capa oculta y la capa de salida (LW_2)

Neurona de salida LW_2	Neuronas de la segunda capa oculta			
	1	2	3	4
1	-3,083196	0,837796	6,583819	-5,728622

4.4.2. Validación de la red neuronal

Para esta etapa del trabajo se verifica que la red cumple con el comportamiento físico apropiado que deben tener ciertas variables frente la presión mínima de miscibilidad y que han sido ampliamente reportadas en la literatura. Tales parámetros incluyen la temperatura del yacimiento, fracción del peso molecular de C_{5+} , fracción de los componentes volátiles e intermedios, al igual que las impurezas presentes en la corriente de gas (N_2 , CH_4 , C_2 - C_4 , H_2S), con el fin de verificar que estas últimas cumplan con el comportamiento físico que describen algunos autores en la literatura.

Cabe destacar que para verificar el comportamiento de cada una de las variables anteriormente mencionadas, fue seleccionada de la base de datos al azar un vector con los valores correspondientes a cada parámetro tal como se muestra en Tabla 4.13. Esta última es un ejemplo de la selección de datos que se llevó a cabo para validar el comportamiento de la temperatura con la presión mínima de miscibilidad obtenida de la red. En el caso de la temperatura se eligieron números aleatorios que se encuentren dentro del rango máximo y mínimo de la red neuronal, es decir, entre 69,8 y 279 °F. Para el resto de las variables, se observa que se mantienen fijas con el valor correspondiente al vector de datos seleccionado.

Tabla 4.13. Modelo de selección de datos para la validación de la red neuronal final

Temperatura	PM_{C5+}	Xvol	Xint	CO₂	N₂	CH₄	C₂-C₄	H₂S
120,00	187,27	34,24	22,82	90,00	0,00	0,00	10,00	0,00
140,00	187,27	34,24	22,82	90,00	0,00	0,00	10,00	0,00
160,00	187,27	34,24	22,82	90,00	0,00	0,00	10,00	0,00
180,00	187,27	34,24	22,82	90,00	0,00	0,00	10,00	0,00

Finalmente, este procedimiento fue llevado a cabo para cada uno de los parámetros utilizados en el desarrollo de la red, donde se variaba aleatoriamente entre el máximo y el mínimo los valores de la variable a analizar y dejando fijo los valores correspondientes al resto de los parámetros.

Es notable que la temperatura del yacimiento tiene un gran impacto sobre la presión mínima de miscibilidad del CO₂ y este último aumenta a medida que la temperatura incrementa. Dicho comportamiento se puede corroborar con la gráfica de la Figura 4.19. Igualmente, tal comportamiento es validado con lo reportado en publicaciones de diversos autores, entre ellos Holm y Josendal (1974), Cronquist (1978), Lee (1979), Petroleum Recovery Institute (1979), Yellig y Metcalfe (1980), Mungan (1981), Johnson y Pollin (1981), Orr y Jensen (1984), Alston et al. (1985), Glaso (1985), Enick (1988), Huang et al. (2003), Yuan et al. (2004), Emera y Sarma (2005), Mousavi et al. (2006) y Shokir (2007).

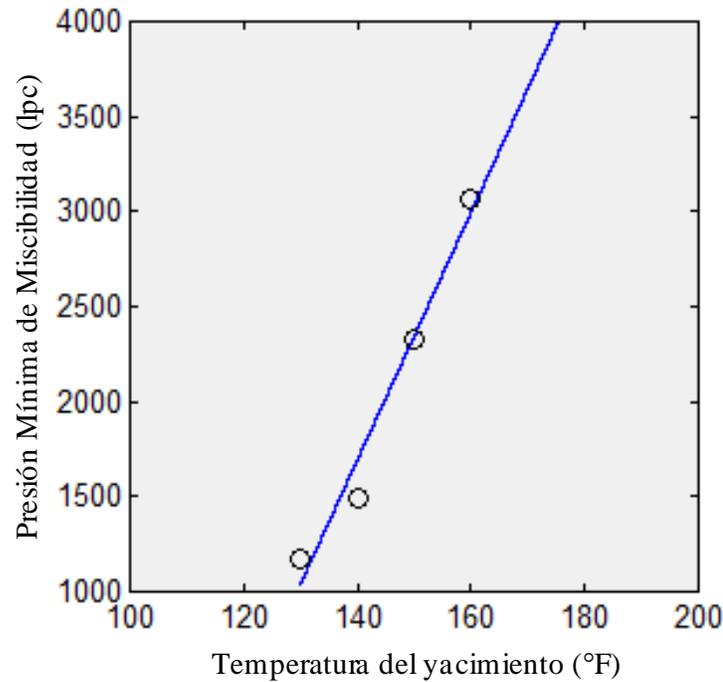


Figura 4.19. Gráfica de la Presión Mínima de Miscibilidad en función de la temperatura del yacimiento

Por otra parte, la composición del crudo también tiene un efecto importante sobre la presión mínima de miscibilidad. Esta última incrementa a medida que aumenta la fracción de los componentes volátiles presentes en el crudo. De otra manera se comporta la fracción de los componentes intermedios presentes en el mismo, donde la presión mínima de miscibilidad disminuye a medida que aumenta el porcentaje molar de estos.

Stalkup (1983) en su libro "*Miscible Displacement*" indica un aumento de la presión mínima de miscibilidad a medida que la gravedad API es más baja o incrementan las fracciones más pesadas del crudo. Sin embargo, el comportamiento de las variables obtenidos en la presente investigación es corroborado con el comportamiento establecido por Holm y Josendal (1974) que según estudios experimentales llegaron a la conclusión que la presión mínima de miscibilidad aumenta cuando incrementan las fracciones de componentes volátiles como el metano, mientras que decrece con las

fracciones de los componentes intermedios que van del C₂ hasta el C₄. Igualmente, Rathmell et al. (1971) llega a la conclusión que la existencia de volátiles como el CH₄ en el crudo aumentan la presión mínima de miscibilidad mientras que la presencia de intermedios pueden disminuirla. Entre otras publicaciones de la literatura desarrolladas por Emera y Sarma (2005), Zuo et al. (1993), Glaso (1985) y Alston et al. (1985), cumplen con tales comportamientos.

En la Figura 4.20 y Figura 4.21 se observa una gráfica de la presión mínima de miscibilidad en función de la fracción de los componentes volátiles y la fracción de los componentes intermedios presentes en el crudo, donde se puede corroborar el comportamiento anteriormente mencionado.

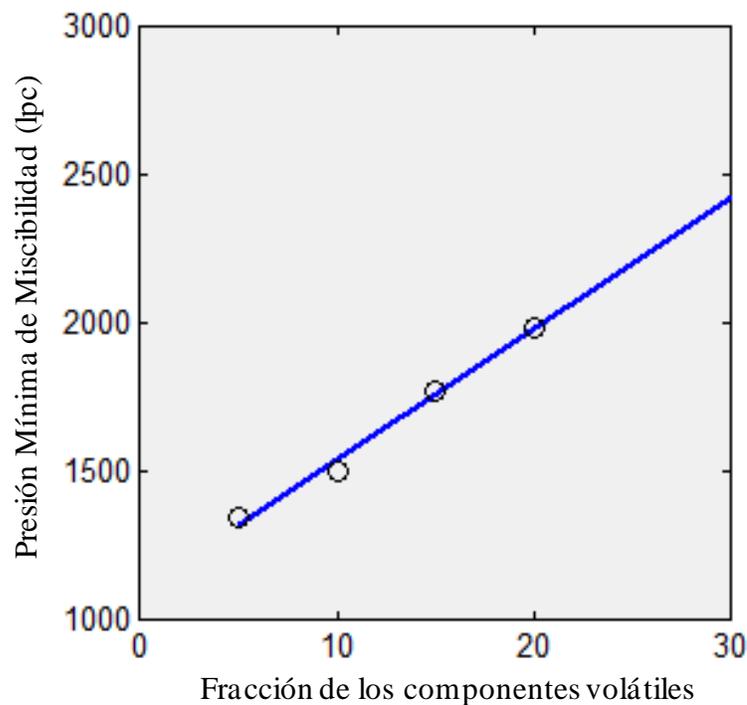


Figura 4.20. Gráfica de la PMM en función de la fracción de los componentes volátiles

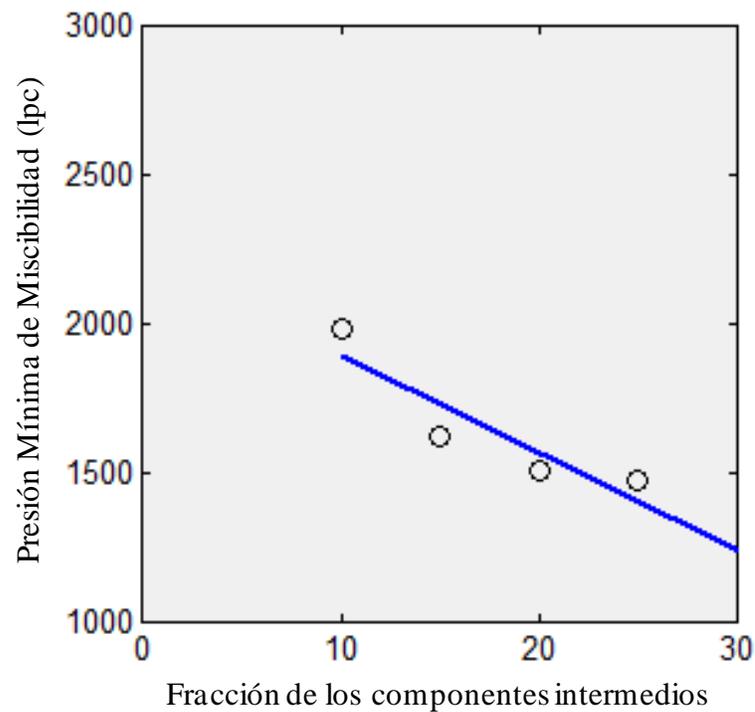


Figura 4.21. Gráfica de la PMM en función de la fracción de los componentes intermedios

A su vez, el peso molecular de la fracción de C_{5+} resultó tener una gran influencia sobre la presión mínima de miscibilidad, es decir, esta última aumenta a medida que dicha fracción incrementa, tal como se refleja en los estudios desarrollados por Holm y Josendal (1974). Igualmente, Huang et al. (2003), Emera y Sarma (2005), Alston et al. (1985), Mungan (1981) y Cronquist (1978) reflejan este comportamiento en sus publicaciones.

En la Figura 4.22 se observa una gráfica de la presión mínima de miscibilidad en función del peso molecular de la fracción de C_{5+} , donde se corrobora el comportamiento anteriormente mencionado y que mientras más pesada sea la fracción de C_{5+} la PMM aumenta.

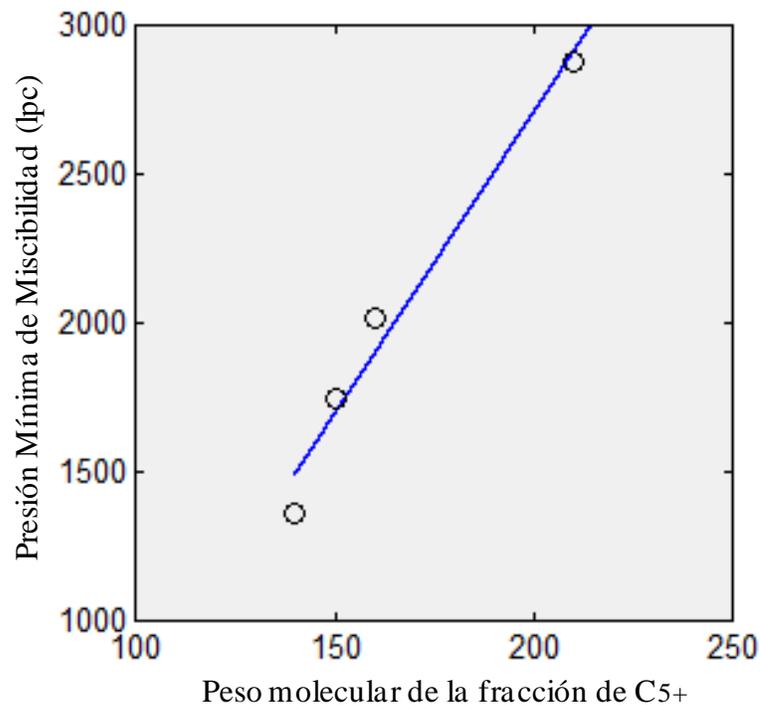


Figura 4.22. Gráfica de la PMM en función del peso molecular de la fracción de C₅₊

Por otra parte, fue analizado el efecto de las impurezas de la corriente de gas en la presión mínima de miscibilidad de la correlación generada en dicho estudio. Shokir (2007) llega a la conclusión que componentes como el CH₄ y el N₂ tienen un impacto negativo sobre la PMM aumentando la misma, a diferencia del H₂S y componentes que van del C₂ al C₄ que la disminuyen.

En la Figura 4.23 se observan las gráficas de la presión mínima de miscibilidad en función de la concentración de contaminantes presentes en el gas de inyección, donde se puede corroborar el comportamiento de las variables para la red desarrollada. Para el caso de las impurezas como el H₂S y componentes que van del C₂ al C₄ se tiene que al incrementar la concentración de tales parámetros la presión mínima de miscibilidad disminuye, a diferencia del CH₄ y N₂ donde esta última incrementa a medida que la concentración de tales componentes aumenta.

Tal comportamiento es corroborado por diversos autores tales como Mousavi et al. (2006), Enick (1988), Johnson y Pollin (1981), Shokir (2007), Dong et al. (1999), Alston et al. (1985), Kovarik (1985) y Sebastian et al. (1985).

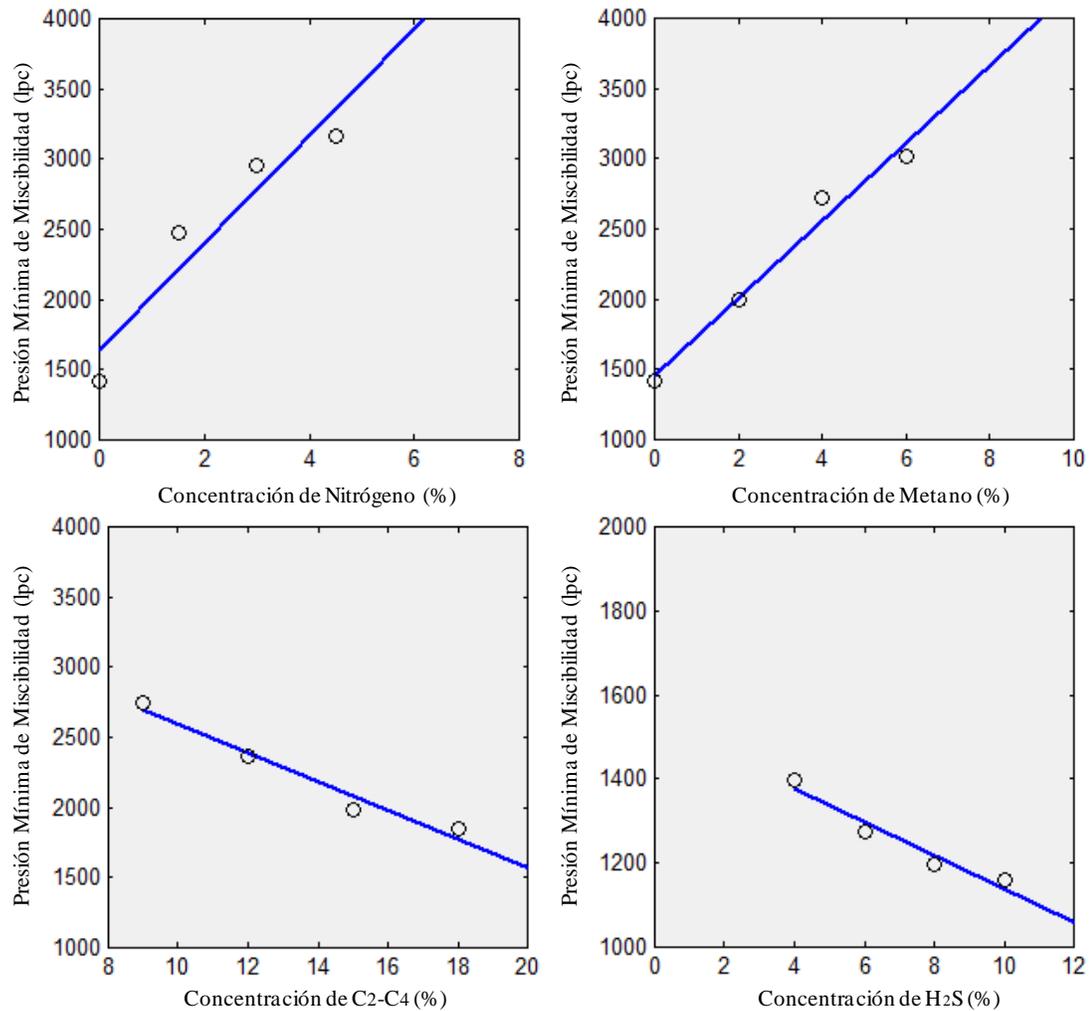


Figura 4.23. Gráfica de la PMM en función de la concentración de contaminantes presentes en el gas de inyección

Finalmente, la red neuronal desarrollada en esta investigación cumple con el comportamiento físico descrito en la literatura.

4.5. COMPARACION DE LA CORRELACIÓN GENERADA POR RNA Y LAS CORRELACIONES DE LA LITERATURA

Se han desarrollado investigaciones previas acerca de la implementación de redes neuronales artificiales en la predicción de la presión mínima de miscibilidad para la inyección de CO₂ puro e impuro. En la Tabla 4.14 se observan los resultados obtenidos en las investigaciones llevadas a cabo por Nezhad et al. (2011), Akbari y Kasiri (2010), Mousavi et al. (2006), Huang et al. (2003) y la obtenida en esta investigación, donde se reporta el número de capas ocultas y neuronas, número de datos de entrenamiento y prueba que implementaron, al igual que el error relativo promedio y el coeficiente de correlación, esto con el fin de establecer una comparación entre los estudios previos donde desarrollaron correlaciones por redes neuronales y la correlación generada en la presente investigación.

Con respecto a la cantidad de datos que obtuvieron para la fase de entrenamiento y prueba en la construcción de la red neuronal, se tiene que Mousavi et al. (2006) utilizaron la menor cantidad de ellos abarcando 55 datos en total, seguido de Akbari y Kasiri (2010) que contaron con 128 datos y por último Nezhad et al. (2011) con 179 datos. Sin embargo, la correlación llevada a cabo en la presente investigación cuenta con una base de datos más amplia respecto a las redes reportadas en investigaciones previas, con 181 datos en total. Cabe destacar que para la red desarrollada por Huang et al. (2003), no se cuenta con la cantidad y el porcentaje de datos que utilizaron. Finalmente, se tiene que la correlación llevada a cabo en dicha investigación, fue desarrollada con una mayor cantidad de datos para tener así una mayor generalización de la red neuronal en la fase de aprendizaje y una mejor predicción de la presión mínima de miscibilidad.

Tabla 4.14. Comparación de la correlación obtenida por la red neuronal desarrollada en esta investigación y las correlaciones por redes neuronales de la literatura

Correlación	Número de datos			Error relativo promedio (%)		Coeficiente de correlación (R)		Arquitectura		Pesos
	<i>E</i>	<i>P</i>	<i>Total</i>	<i>E</i>	<i>P</i>	<i>E</i>	<i>P</i>	<i>Capa 1</i>	<i>Capa 2</i>	
Nezhad et al. (2011)	154	25	179	2,43	6,61	0,99	0,96	100 neuronas		-
Akbari y Kasiri (2010)	102	26	128	2,37	3,25	0,99	0,99	30	-	-
Mousavi et al. (2006)	44	11	55	-	3,98	-	0,98	7	5	-
Huang et al. (2003)	-	-	-	-	12,08	-	0,94	-	-	-
RNA*	145	36	181	4,13	6,68	0,99	0,97	8	4	Desde la Tabla 4.7 a la Tabla 4.12
<i>E: Entrenamiento P: Prueba * Red neuronal desarrollada en esta investigación</i>										

Otro parámetro importante a comparar, es la arquitectura de la red neuronal. En el caso de Nezhad et al. (2011) desarrollaron un tipo de red neuronal de base radial para la predicción de la presión mínima de miscibilidad, por lo tanto hace difícil su comparación debido a que este tipo de red tiene una arquitectura más compleja, es decir, requiere un mayor número de neuronas que la redes estándar de propagación hacia atrás o *backpropagation*. En las otras redes reportadas, tal como el caso de Mousavi et al. (2006) y la red de Akbari y Kasiri (2010), obtuvieron arquitecturas relativamente sencillas. Sin embargo, una de las limitantes más fuertes es que no reportan en sus publicaciones los pesos necesarios para la construcción de dichas redes y por lo tanto se ve limitada su implementación.

Por otra parte, se evaluó el error relativo promedio de cada correlación. Uno de los valores más altos corresponde al error obtenido en la red llevada a cabo por Huang et al. (2003) con un 12,08 por ciento en la salida de la misma. Igualmente, no se tiene para este estudio la base de datos implementada por dichos autores, por lo tanto no se conoce el rango de aplicabilidad de la misma. Posteriormente, la red desarrollada por Nezhad et al. (2011) obtuvo un error de prueba mucho más bajo con un 6,61 por ciento. Sin embargo, para ambas redes no se conocen los pesos ni los parámetros necesarios para la construcción de estos modelos y por lo tanto su aplicabilidad se ve fuertemente limitada. Es importante señalar que Nezhad et al. (2011) utilizan 25 datos para evaluar la red mientras que para este estudio se trabajan con 36 datos. A pesar de esto la diferencia en los errores de ambas redes es muy similar.

Otras correlaciones como la llevada a cabo por Akbari y Kasiri (2010), cuenta con uno de los errores de prueba más bajos con un 3,25 por ciento. Sin embargo, estos autores desarrollaron una red neuronal universal para predecir la presión mínima de miscibilidad en la inyección de CO₂ y gases hidrocarburos. Pero una de las limitantes es que no se conoce con certeza que tan aplicable es dicha red a la inyección de CO₂, ya que se desconoce la cantidad de casos en su base de datos que utilizan el mismo como gas de inyección y por lo tanto no se asegura la predicción de la PMM con exactitud. Posteriormente, se tiene la red de Mousavi et al. (2006) con un error de

3,98 por ciento, pero en este caso la base de datos utilizada en su investigación es reducida, por lo tanto su aplicabilidad y capacidad de predecir valores de la presión mínima de miscibilidad con precisión es mucho más baja. Ambas investigaciones, lograron obtener resultados aceptables, pero su limitación está en que no se cuenta con los parámetros necesarios para la construcción de las redes.

Finalmente, los modelos previamente desarrollados por redes neuronales que predicen la presión mínima de miscibilidad en la inyección de CO₂, se ven fuertemente limitados en cuanto a su aplicabilidad por la falta de información que se tiene para la construcción de los mismos. A su vez, la red desarrollada en la presente investigación cuenta con una arquitectura simple y con una base de datos amplia para mayor generalización de la correlación.

Además de los modelos desarrollados por redes neuronales, existen otros modelos llevados a cabo por métodos estadísticos que presentan la predicción de la presión mínima de miscibilidad usando como gas de inyección CO₂ puro e impuro. Es por esto que en la Tabla 4.15 se muestra el error mínimo, máximo y promedio, además del coeficiente de correlación y la desviación estándar para el modelo desarrollado en esta investigación y las correlaciones reportadas en la literatura.

Cabe destacar, que las correlaciones que fueron seleccionadas para realizar tal comparación entre las correlaciones estadísticas y la desarrollada en la presente investigación, depende de los parámetros que tomaron en cuenta cada uno de los autores. Por lo tanto, se seleccionaron aquellas que incluyeran parámetros como la temperatura de yacimiento, el peso molecular de la fracción de C₅₊, la fracción de los componentes volátiles e intermedios, al igual que las impurezas presentes en el CO₂ tales como el N₂, CH₄ y H₂S. Para el caso de las correlaciones que incluían la temperatura pseudocrítica de la corriente de gas, se descartaron debido a que se desconoce de la base de datos la fracción de C₂, C₃ y C₄.

Tales correlaciones que cumplen con las características necesarias corresponden a la desarrollada por Shokir (2007) para el caso del CO₂ impuro, Petroleum Recovery

Institute (1979), Cronquist (1978), Emera y Sarma (2005), Lee (1979) y Alston et al. (1985) para el caso del CO₂ puro. Es importante mencionar que para la evaluación de las correlaciones anteriormente nombradas, se utilizaron los valores de cada parámetro correspondientes a la base de datos desarrollada en esta investigación.

Con respecto a la correlación llevada a cabo por Shokir (2007), cuando fue utilizada con la base de datos de esta investigación para el cálculo de la presión mínima de miscibilidad con CO₂ impuro, se obtuvo un error de 20,18 por ciento y un coeficiente de correlación de 0,69, siendo el error más alto y el coeficiente más bajo respecto a las otras correlaciones reportadas.

Para el caso del CO₂ puro, en base a la correlación desarrollada por Petroleum Recovery Institute (1979) y Lee (1979), se tuvo un error de predicción 19,49 y 19,30 por ciento respectivamente, siendo los errores más altos respecto a las correlaciones reportadas para CO₂ puro. Dichos errores van ligados a la cantidad de parámetros que implementaron en su correlación. En este caso, tomaron únicamente como parámetro a evaluar la temperatura del yacimiento. Por lo tanto, esto trae como consecuencia una menor precisión de estas correlaciones por no tomar en cuenta la influencia de la composición del crudo.

Por otra parte, al evaluar la correlación de Alston et al. (1985) se obtuvo un error de 16,16 por ciento, seguido de Cronquist (1978) con 13,70 por ciento y por último Emera y Sarma (2005) con 11,94 por ciento. A diferencia de Petroleum Recovery Institute (1979) y Lee (1979), estos últimos autores tomaron en cuenta tanto la temperatura del yacimiento como la composición del crudo. Es por esto que los errores reflejados en dichas correlaciones son menores y los coeficientes de correlación resultantes demuestran un mayor ajuste de la base de datos implementada. Sin embargo, la correlación desarrollada en esta investigación es mucho más precisa que las correlaciones reportadas en la literatura, con un error de 6,68 por ciento y un coeficiente de correlación de 0,97.

Tabla 4.15. Comparación de la correlación obtenida por la red neuronal desarrollada en esta investigación y las correlaciones de la literatura

	Correlación	Error mínimo (%)	Error máximo (%)	Error promedio (%)	Desviación estándar (%)	Coefficiente de correlación
CO ₂ impuro	Shokir (2007)	0,02	87,45	20,18	18,33	0,69
CO ₂ puro	Petroleum Recovery Institute (1979)	0,05	109,94	19,49	20,26	0,71
	Cronquist (1978)	0,57	58,21	13,70	11,18	0,90
	Lee (1979)	0,02	107,51	19,30	19,80	0,71
	Emera y Sarma (2005)	0,04	48,99	11,94	9,54	0,91
	Alston et al. (1985)	0,05	64,52	16,16	12,68	0,86
CO ₂ puro e impuro	RNA*	0,28	20,32	6,68	4,95	0,97

* Red neuronal desarrollada en esta investigación

Finalmente, comparando los resultados obtenidos en esta investigación y las correlaciones reportadas en la literatura, se tiene que estos métodos inteligentes de regresión como las redes neuronales artificiales pueden ser usados para la predicción de fenómenos complejos en la industria del petróleo con mayor precisión que los métodos convencionales estadísticos.

CONCLUSIONES

1. La red neuronal desarrollada en esta investigación cumple con el comportamiento físico que descrito en la literatura. El aumento de la temperatura del yacimiento, la fracción de componentes volátiles presentes en el crudo, el peso molecular de la fracción de C_{5+} al igual que la concentración de componentes tales como el N_2 y CH_4 en el gas, influyen en el incremento de la presión mínima de miscibilidad. En cambio, esta última disminuye al aumentar la fracción de componentes intermedios presentes en el crudo, la concentración de H_2S y componentes desde el C_2 hasta el C_4 presentes en el gas de inyección.
2. Mediante la correlación generada en esta investigación, se puede predecir la presión mínima de miscibilidad en la inyección de CO_2 con un error de 6,68 por ciento, siendo mucho más bajo que los errores obtenidos al implementar las correlaciones de la literatura. Igualmente, se obtuvo un coeficiente de correlación de 0,97.
3. La red neuronal desarrollada para la predicción de la presión mínima de miscibilidad en la inyección de CO_2 , posee una arquitectura sencilla con dos capas ocultas, ocho neuronas en su primera capa y cuatro neuronas en la segunda.
4. Para la correlación desarrollada existe un amplio rango de condiciones en las que se puede implementar la red neuronal.
5. El algoritmo implementado fue el de *Levenberg-Marquardt*, junto con la función transferencia *tansig* (sigmoide) y una tolerancia del error cuadrático medio de 1×10^{-3} para el entrenamiento de la red, siendo este último el más adecuado para evitar el sobreentrenamiento de la misma.

6. Los parámetros tomados en cuenta para llevar a cabo la correlación por medio de redes neuronales fueron la temperatura del yacimiento, el peso molecular de la fracción de C_{5+} , la fracción de los componentes volátiles e intermedios, al igual que las impurezas presentes en el CO_2 tales como el N_2 , CH_4 , C_2-C_4 y H_2S .
7. Los métodos inteligentes de regresión como las redes neuronales artificiales pueden ser usados en la predicción de fenómenos complejos en la industria del petróleo con mayor precisión que los métodos convencionales estadísticos.
8. La implementación de modelos desarrollados por redes neuronales publicados en la literatura, se ven fuertemente limitados por la falta de información que se tiene para la construcción de los mismos.
9. En la década de los 70 fueron desarrolladas las primeras correlaciones gráficas. Posteriormente, desde los años 70 hasta los 90 hubo una evolución de las mismas donde ha predominado su representación en forma de ecuación, siendo estas últimas las que abarcan la mayor parte de las correlaciones publicadas en la literatura.
10. La mayor parte de las correlaciones publicadas en la literatura han sido desarrolladas en la década de los 80 y en base a datos obtenidos por medio de pruebas de tubo delgado.
11. En la actualidad, se han venido desarrollando correlaciones en base a redes neuronales por ser modelos eficientes en la predicción de la presión mínima de miscibilidad.
12. La inyección de CO_2 ha demostrado ser un método efectivo en la recuperación mejorada de crudos livianos y medianos, por lo tanto se busca utilizar este método con el fin de disminuir la contaminación ambiental y la emisión de gases que causan el efecto invernadero.

RECOMENDACIONES

1. Complementar la base de datos con pruebas llevadas a cabo por tubo delgado o burbuja ascendente para mayor generalización de la red neuronal, además de incluir nuevas propiedades para evaluar su efecto sobre la presión mínima de miscibilidad obtenida por medio de esta herramienta.
2. Generar correlaciones por medio de redes neuronales con datos que tomen en cuenta, para la composición del crudo, cada una de las fracciones de los componentes presentes.
3. Uso de computación emergente tales como maquinas lineales, algoritmos genéticos, autómatas celulares y cualquier otra técnica de cómputo no tradicional que imite mecanismos naturales.

REFERENCIAS BIBLIOGRÁFICAS

- [1] Akbari, M.R. & Kasiri, N. (2011).: “*A Determination of Minimum Miscibility Pressure in Gas Injection Process by Mixing Rules*”. Presented at 14th Intl. Oil, Gas & Petrochemical Congress.
- [2] Alston, R.B., Kokolis, G.P. & James, C.F. (1985, Abril): “*CO₂ Minimum Miscibility Pressures: A Correlation for Impure CO₂ Streams and Live Oil Systems*”, SPE 11959, 268–274.
- [3] Arias, F. (1999): “*El Proyecto de Investigación, Guía Para su Elaboración*”. 3era ed. Caracas, Editorial Episteme – Oriol Ediciones.
- [4] Baljit S. Sehbi, Scott M. Frailey & Akanni S. Lawal (2001, Mayo): “*Analysis of Factors Affecting Microscopic Displacement Efficiency in CO₂ Floods*”. SPE 70022. SPE Permian Basin Oil and Gas Recovery Conference, Midland, Texas.
- [5] *Características principales de las Redes neuronales (s.f.)*. Consultado el 10 de Julio de 2011 desde:
<http://proton.ucting.udg.mx/posgrado/curso/idc/neuronales2/RNArtificial.htm>
- [6] Curtis H. Whitson & Michael R. Brule (2000).: “*Phase Behaviour*”. Monografía. Volumen 20. SPE. Henry L. Doherty Series. Richardson, Texas.
- [7] Danesh, Ali. (1998, Mayo).: “*PVT and Phase Behaviors Petroleum Reservoir Fluids*”. Elsevier Science & Technology Books. 253-273.
- [8] Demuth, Howard B., Hagan, Martin T. & Beale, Mark H. (1996): “*Neural Network Design*”. United States of America.
- [9] Dong M., Huang S., Srivastava R. (1999, Junio).: “*Effect of Solution Gas in Oil on CO₂ Minimum Miscibility Pressure*”. Paper 99-47. The Petroleum Society. Presented at 1999 CSPG and Petroleum Society Joint Convention, in Calgary, Alberta, Canada.

- [10] Eakin, B.E. & Mitch, F.J. (1988): “*Measurement and Correlation of Miscibility Pressures of Reservoir Oils*”. SPE Paper 18065 presented at 63rd Annual Technical Conference and Exhibition, Houston, TX, pp. 75–81.
- [11] Elsharkawy, A., Poettman, F. & Christiansen, R.L. (1992, Abril). “*Measuring Minimum Miscibility Pressure: Slim-Tube or Rising-Bubble Method*”. (SPE 24114). Presentado en el Octavo Simposio de Recuperación Mejorada de Petróleo. Tulsa. 22-24.
- [12] Emera, M.K. & Sarma, H.K. (2004): “*Use of Genetic Algorithm to estimate CO₂-Oil Minimum Miscibility Pressure—a Key Parameter in Design of CO₂ Miscible Flood*”, J. Pet. Sci. Eng. 46, 37– 52.
- [13] Enick, R.M., Holder, G.D., Morsi, B.I (1988).: “*A Thermodynamic Correlation for the Minimum Miscibility Pressure in CO₂ Flooding of Petroleum Reservoirs*”. SPE Reserv. Eng. J. 2, 81–92.
- [14] Flórez L. Raquel y Fernández F. José M. (2008): “**Las Redes Neuronales Artificiales: Fundamentos Teóricos y Aplicaciones Prácticas**”. Consultado el 18 de Julio de 2011 desde: <http://books.google.co.ve>
- [15] Glaso O. (1985): “*Generalized Minimum Miscibility Pressure Correlation*”. SPE 12893.
- [16] Hernández S. Robert, Fernández C. Carlos y Baptista L. Pilar (1997): “*Metodología de la Investigación*”. Mc Graw Hill, México.
- [17] *Historia de las Redes Neuronales*. (s.f.). Consultado el 1 de Julio de 2011 desde: http://www.ibiblio.org/pub/linux/docs/LuCaS/Presentaciones/200304curso-glisa/redes_neuronales/curso-glisa-redes_neuronales-html/x24.html.
- [18] Holm, L.W. and Josendal, V.A. (1974): “*Mechanisms of Oil Displacement by Carbon Dioxide*”, J Pet Technol, 1427-1436.

- [19] Holm, L.W. and Josendal, V.A (1980, Abril): “*Effect of Oil Composition on Miscible- Type Displacement by CO₂*”. SPE 8814. Presentado en el Simposio de Recuperación Mejorada de Petróleo en Tulsa, Oklahoma, 87-98.
- [20] Holm., L.W. (1982, Diciembre): “*CO₂ Flooding: Its Time has come*”. SPE 11592. Journal of Petroleum Technology. 2739-2745.
- [21] Holm, L.W. (1986, Agosto): “*Miscibility and Miscible Displacement*”. Paper SPE 15794. 7-818.
- [22] Huang, Y.F., Huang, G.H., Dong, M.Z. & Feng, G.M. (2003): “*Development of an Artificial Neural Network model for Predicting Minimum Miscibility Pressure in CO₂ Flooding*”. Journal of Petroleum Science and Engineering, 37, 83-95.
- [23] Johnson, J.P. & Pollin, J.S. (1981): “*Measurement and Correlation of CO₂ Miscibility Pressures*”. SPE Paper 9790 presented at the SPE/DOE Second Joint Symposium on Enhanced Oil Recovery, Tulsa, USA, pp. 269–281.
- [24] Kovarik, F.S. (1985, Noviembre): “*A Minimum Miscibility Pressure Study Using Impure CO₂ and West Texas Oil Systems: Data Base, Correlations, and Compositional Simulation*”. SPE 14689. Production Technology Symposium held in Lubbock, Texas.
- [25] Manrique, E., Thomas, C., Ravikiran, R., Izadi, M., Lantz, M., Romero, J., Alvarado, V. (2010, Abril): “*EOR: Current Status and Opportunities*”. SPE 130113. Presented at the 2010 SPE Improved Oil Recovery Symposium held in Tulsa, Oklahoma, USA.
- [26] Marín, Jesús (2002, Abril): “**Metodología para estimar Presión Mínima de Miscibilidad mediante una ecuación de estado**”. Trabajo Especial de Grado. UNIMET. Consultado el 9 de Mayo de 2011 desde:
<http://repositorios.unimet.edu.ve/docs/31/TP155M37G6.pdf>

- [27] Mousavi S.A., Vafaie Sefti M., Ameri A. & Shojai Kaveh N. (2008): “**Minimum Miscibility Pressure Prediction Based on a Hybrid Neural Genetic Algorithm**”, Chemical Engineering Research and Design, 86, 173-185.
- [28] Mungan, N. (1981, Enero-Marzo): “**Carbon Dioxide Flooding - Fundamentals**”. J. Cdn. Pet. Tech. Calgary, Alberta. 87 – 92.
- [29] Nezhad A.B., Mousavi S.M. & Aghahoseini S. (2011): “**Development of an Artificial Neural Network model to predict CO₂ Minimum Miscibility Pressure**”. NAFTA 62 (3-4) 105-108.
- [30] Orr Jr., F.M. & Silva, M.K. (1987): “**Effect of Oil Composition on Minimum Miscibility Pressure—Part 2: Correlation**”. SPE Reserv. Eng. J. 11, 479–491.
- [31] Sebastian, H.M., Wenger, R.S. & Renner, T.A. (1985, Abril): “**Correlation of Minimum Miscibility Pressure for Impure CO₂ Streams**”, Paper SPE 12648 Presented at the 1984 SPE/DOE Enhanced Oil Recovery Symposium, Tulsa, JPT , 37 (2), 268– 274.
- [32] Shokir, Eissa M. El-M. (2007): “**CO₂ Oil Minimum Miscibility Pressure Model for Impure and Pure CO₂ Streams**”, Journal of Petroleum Science and Engineering.
- [33] Stalkup Jr., Fred J. (1983): “**Miscible Displacement**”. Dallas: SPE Monograph Series.
- [34] Suleman, Ali A. (2008, Julio): “**Experimental Investigation of CO₂ – Miscible Oil Recovery at Different Conditions**”. Thesis Msc. King Saud University.
- [35] **Tendencias de los Sistemas Inteligentes Artificiales (s.f.)**. Consultado el 8 de Julio de 2011 desde: <http://inteligart.blogspot.com>.
- [36] Yellig, W.F. & Metcalfe, R.S. (1980): “**Determination and Prediction of CO₂ Minimum Miscibility Pressures**”. J. Pet. Technol. 1, 160–168.

- [37] Yousef Ghomian, Gary A. Pope & Kamy Sepehrnoori (2008, Septiembre): ***“Development of a Response Surface Based Model for Minimum Miscibility Pressure (MMP) Correlation of CO₂ Flooding”***. SPE 116719. Presented at the Annual Technical Conference and Exhibition held in Denver, Colorado, USA.
- [38] Yuan, H., Johns, R.T., Egwuenu, A.M. & Dindoruk, B. (2004): ***“Improved MMP Correlations for CO₂ Floods using Analytical Gas Flooding Theory”***. SPE Paper 89359 presented at the SPE/DOE Fourteenth Symposium on Improved Oil Recovery, Tulsa, USA, pp. 1- 16.
- [39] Wu, R.S. & Batycky, J.P. (2006): ***“Evaluation of Miscibility from Slim Tube Test”***, Journal of Canadian Petroleum Technology. JCPT 90-06-06. Esso Resources Canada Ltd. Calgary, Alberta.
- [40] Zuo, Y.X., Chu, J.Z., Ke, S.L. & Guo, T.M. (1993): ***“A study of the Minimum Miscibility Pressure for Miscible Flooding Systems”***, J. Pet. Sci. Eng. 8, 315– 328.

BIBLIOGRAFÍA

Adyani, W.N., Razak, W. & Kechut, N.I. (2007, Octubre-Noviembre): “***Advanced Technology for Rapid Minimum Miscibility Pressure Determination (Part 1)***”. SPE 110265. Presented at the SPE Asia Pacific Oil and Gas Conference. Jakarta, Indonesia.

Akbari, M.R. & Kasiri, N. (2011): “***A Determination of Minimum Miscibility Pressure in Gas Injection Process by Mixing Rules***”. Presented at 14th Intl. Oil, Gas & Petrochemical Congress.

Al-Ajmi, M., Alomair, O. & Elsharkawy, A. (2009, Diciembre): “***Planning Miscibility Test and gas Injection Projects for Four Major Kuwaiti Reservoirs***”. SPE 127537. Presented at the Kuwait International Petroleum Conference. Kuwait.

Alston, R.B., Kokolis, G.P. & James, C.F. (1985, Abril): “***CO₂ Minimum Miscibility Pressures: A Correlation for Impure CO₂ Streams and Live Oil Systems***”, SPE 11959, 268–274.

Arias, F. (1999): “***El Proyecto de Investigación, Guía Para su Elaboración***”. 3era ed. Caracas, Editorial Episteme – Oriol Ediciones.

Baljit S. Sehbi, Scott M. Frailey & Akanni S. Lawal (2001, Mayo): “***Analysis of Factors Affecting Microscopic Displacement Efficiency in CO₂ Floods***”. SPE 70022. SPE Permian Basin Oil and Gas Recovery Conference, Midland, Texas.

Bon J. & Sarma H.K.. (2005): “***An Investigation of Minimum Miscibility Pressure for CO₂ – Rich Injection Gases with Pentanes-Plus Fraction***”, SPE 97536.

Características principales de las Redes neuronales (s.f.). Consultado el 10 de Julio de 2011 desde:

<http://proton.ucting.udg.mx/posgrado/curso/idc/neuronales2/RNArtificial.htm>

- Curtis H. Whitson & Michael R. Brule (2000).: “*Phase Behaviour*”. Monografía. Volumen 20. SPE. Henry L. Doherty Series. Richardson, Texas.
- Danesh, Ali. (1998, Mayo).: “*PVT and Phase Behaviors Petroleum Reservoir Fluids*”. Elsevier Science & Technology Books. 253-273.
- Demuth, Howard B., Hagan, Martin T. & Beale, Mark H. (1996): “*Neural Network Design*”. United States of America.
- Demuth, H. & Beale, M. (2002).: “*Neural Network Toolbox User’s Guide*”. The Mathworks Inc. Versión 4.
- Dong M., Huang S., Srivastava R. (1999, Junio).: “*Effect of Solution Gas in Oil on CO₂ Minimum Miscibility Pressure*”. Paper 99-47. The Petroleum Society. Presented at 1999 CSPG and Petroleum Society Joint Convention, in Calgary, Alberta, Canada.
- Eakin, B.E. & Mitch, F.J. (1988): “*Measurement and Correlation of Miscibility Pressures of Reservoir Oils*”. SPE Paper 18065 presented at 63rd Annual Technical Conference and Exhibition, Houston, TX, pp. 75–81.
- Elsharkawy, A., Poettman, F. & Christiansen, R.L. (1992, Abril). “*Measuring Minimum Miscibility Pressure: Slim-Tube or Rising-Bubble Method*”. (SPE 24114). Presentado en el Octavo Simposio de Recuperación Mejorada de Petróleo. Tulsa. 22-24.
- Emera, M.K. & Sarma, H.K. (2004): “*Use of Genetic Algorithm to estimate CO₂–Oil Minimum Miscibility Pressure—a Key Parameter in Design of CO₂ Miscible Flood*”, J. Pet. Sci. Eng. 46, 37– 52.
- Enick, R.M., Holder, G.D., Morsi, B.I (1988).: “*A Thermodynamic Correlation for the Minimum Miscibility Pressure in CO₂ Flooding of Petroleum Reservoirs*”. SPE Reserv. Eng. J. 2, 81–92.

Flórez L. Raquel y Fernández F. José M. (2008): “**Las Redes Neuronales Artificiales: Fundamentos Teóricos y Aplicaciones Prácticas**”. Consultado el 18 de Julio de 2011 desde: <http://books.google.co.ve>.

Frimodig, J.P., Reese, N.A. & Williams, C.A. (1983, Agosto): “*Carbon Dioxide Flooding Evaluation of High Pour- Point, Paraffinic Red Wash Reservoir Oil*”, Soc. Pet. Eng. J., 587–594.

Glaso O. (1985): “*Generalized Minimum Miscibility Pressure Correlation*”. SPE 12893.

Graue, D.J., Zana, E.T. (1981, Julio): “*Study of a Possible CO₂ Flood in Rangeley Field*”, SPE 7060. J. Pet. Technol., 1312–1318.

Harmon, R.A. & Grigg, R.B. (1988): “*Vapor-Density Measurement for Estimating Minimum Miscibility pressure*”, SPE Reserv Eng J., 1215-1220.

Hernández, Benigno (2008): “*Implementación de Redes Neuronales para la predicción del comportamiento de producción en pozos con tratamiento de geles para el control de agua excesiva*”. Trabajo Especial de Grado. Universidad Central de Venezuela, Caracas.

Hernández S. Robert, Fernández C. Carlos y Baptista L. Pilar (1997): “*Metodología de la Investigación*”. Mc Graw Hill, México.

Historia de las Redes Neuronales. (s.f.). Consultado el 1 de Julio de 2011 desde: http://www.ibiblio.org/pub/linux/docs/LuCaS/Presentaciones/200304curso-glisa/redes_neuronales/curso-glisa-redes_neuronales-html/x24.html.

Holm, L.W. and Josendal, V.A. (1974): “*Mechanisms of Oil Displacement by Carbon Dioxide*”, J Pet Technol, 1427-1436.

Holm, L.W. and Josendal, V.A (1980, Abril): “*Effect of Oil Composition on Miscible- Type Displacement by CO₂*”. SPE 8814. Presentado en el Simposio de Recuperación Mejorada de Petróleo en Tulsa, Oklahoma, 87-98.

Holm., L.W. (1982, Diciembre): “*CO₂ Flooding: Its Time has come*”. SPE 11592. Journal of Petroleum Technology.2739-2745.

Holm, L.W. (1986, Agosto): “*Miscibility and Miscible Displacement*”. Paper SPE 15794. 817-818.

Huang, Y.F., Huang, G.H., Dong, M.Z. & Feng, G.M. (2003): “*Development of an Artificial Neural Network model for Predicting Minimum Miscibility Pressure in CO₂ Flooding*”. Journal of Petroleum Science and Engineering, 37, 83-95.

Jaubert, J.N., Avaulle, L. & Souvay, J.F. (2002).: “*A Crude Oil Data Bank containing more than 5000 PVT and Gas Injection Data*”. Journal of Petroleum Science and Engineering. 65-107.

Johnson, J.P. & Pollin, J.S. (1981): “*Measurement and Correlation of CO₂ Miscibility Pressures*”. SPE Paper 9790 presented at the SPE/DOE Second Joint Symposium on Enhanced Oil Recovery, Tulsa, USA, pp. 269–281.

Kovarik, F.S. (1985, Noviembre): “*A Minimum Miscibility Pressure Study Using Impure CO₂ and West Texas Oil Systems: Data Base, Correlations, and Compositional Simulation*”. SPE 14689. Production Technology Symposium held in Lubbock, Texas.

Manrique, E., Thomas, C., Ravikiran, R., Izadi, M., Lantz, M., Romero, J., Alvarado, V. (2010, Abril).: “*EOR: Current Status and Opportunities*”. SPE 130113. Presented at the 2010 SPE Improved Oil Recovery Symposium held in Tulsa, Oklahoma, USA.

Marín, Jesús (2002, Abril): “**Metodología para estimar Presión Mínima de Miscibilidad mediante una ecuación de estado**”. Trabajo Especial de Grado. UNIMET. Consultado el 9 de Mayo de 2011 desde:

<http://repositorios.unimet.edu.ve/docs/31/TP155M37G6.pdf>

Moujahid, A., Inza I. y Larra, P. “**Redes Neuronales**”. Departamento de Ciencias de la Computación e Inteligencia Artificial. Universidad del País Vasco. Consultado el 19 de Julio de 2011 desde:

<http://www.sc.ehu.es/ccwbayes/docencia/mmcc/docs/t14s-neuronales.pdf>

Mousavi S.A., Vafaie Sefti M., Ameri A. & Shojai Kaveh N. (2008): “**Minimum Miscibility Pressure Prediction Based on a Hybrid Neural Genetic Algorithm**”, Chemical Engineering Research and Design, 86, 173-185.

Mungan, N. (1981, Enero-Marzo): “**Carbon Dioxide Flooding - Fundamentals**”. J. Cdn. Pet. Tech. Calgary, Alberta. 87 – 92.

Nezhad A.B., Mousavi S.M. & Aghahoseini S. (2011): “**Development of an Artificial Neural Network model to predict CO₂ Minimum Miscibility Pressure**”. NAFTA 62 (3-4) 105-108.

Orr Jr., F.M. & Silva, M.K. (1987): “**Effect of Oil Composition on Minimum Miscibility Pressure—Part 2: Correlation**”. SPE Reserv. Eng. J. 11, 479–491.

Rathmell, J.J, Stalkup, F.I. & Hassinger R.C. (1971): “**A Laboratory Investigation of Miscible Displacement by CO₂**”. SPE 3483, presented at the 46th Annual Fall Meeting of the Society of Petroleum Engineers of AIME, New Orleans, LA, pp. 1–16.

Rocha P.S., Alves D.R. & Costa G.M. (s.f.): “**Pure and Impure CO₂ Minimum Miscibility Pressure: Comparing Sixteen Correlations**”.

Sebastian, H.M., Wenger, R.S. & Renner, T.A. (1985, Abril): “**Correlation of Minimum Miscibility Pressure for Impure CO₂ Streams**”, Paper SPE 12648

Presented at the 1984 SPE/DOE Enhanced Oil Recovery Symposium, Tulsa, JPT , 37 (2), 268– 274.

Shokir, Eissa M. El-M. (2007): “*CO₂ Oil Minimum Miscibility Pressure Model for Impure and Pure CO₂ Streams*”, Journal of Petroleum Science and Engineering.

Stalkup Jr., & Fred J. (1983): “*Miscible Displacement*”. Dallas: SPE Monograph Series.

Suleman, Ali A. (2008, Julio): “*Experimental Investigation of CO₂ – Miscible Oil Recovery at Different Conditions*”. Thesis Msc. King Saud University.

Tendencias de los Sistemas Inteligentes Artificiales (s.f.). Consultado el 8 de Julio de 2011 desde: <http://inteligart.blogspot.com>

Villanueva E., María. (s.f.): “*Las Redes Neuronales Artificiales y su importancia como herramienta en la toma de decisiones*”. Tesis UNMSM. Consultado el 15 de Julio de 2011 desde:
http://sisbib.unmsm.edu.pe/bibvirtualdata/tesis/basic/Villanueva_EM/enPDF/Cap5.PDF

Yellig, W.F. & Metcalfe, R.S. (1980): “*Determination and Prediction of CO₂ Minimum Miscibility Pressures*”. J. Pet. Technol. 1, 160–168.

Yousef Ghomian, Gary A. Pope & Kamy Sepehrnoori (2008, Septiembre): “*Development of a Response Surface Based Model for Minimum Miscibility Pressure (MMP) Correlation of CO₂ Flooding*”. SPE 116719. Presented at the Annual Technical Conference and Exhibition held in Denver, Colorado, USA.

Yuan, H., Johns, R.T., Egwuenu, A.M. & Dindoruk, B. (2004): “*Improved MMP Correlations for CO₂ Floods using Analytical Gas Flooding Theory*”. SPE Paper 89359 presented at the SPE/DOE Fourteenth Symposium on Improved Oil Recovery, Tulsa, USA, pp. 1- 16.

Adyani, W.N., Razak, W. & Kechut, N.I. (2007).: ***“Advanced Technology for Rapid Minimum Miscibility Pressure Determination (Part 1)”***. SPE 110265. Presented at the 2007 SPE Asia Pacific Oil & Gas Conference and Exhibition held in Jakarta, Indonesia.

Wu, R. (1995): ***“Prediction of CO₂ Miscibility Pressures”***. Presented at the Sixth Petroleum Conference of the South Saskatchewan Section. Petroleum Society of Cim. October 16-18.

Wu, R.S. & Batycky, J.P. (2006).: ***“Evaluation of Miscibility from Slim Tube Test”***, Journal of Canadian Petroleum Technology. JCPT 90-06-06. Esso Resources Canada Ltd. Calgary, Alberta.

Zuo, Y.X., Chu, J.Z., Ke, S.L. & Guo, T.M. (1993): ***“A study of the Minimum Miscibility Pressure for Miscible Flooding Systems”***, J. Pet. Sci. Eng. 8, 315– 328.