

**DETERMINACION DE LA TEMPERATURA DE FORMACION DE HIDRATOS
DEL GAS NATURAL UTILIZANDO REDES NEURONALES ARTIFICIALES**

**CARLOS ANDRES AYALA MARIN
CHRISTIANN CAMILO GARCIA YELA**

**UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FISICOQUÍMICAS
ESCUELA DE INGENIERÍA DE PETRÓLEOS
ESPECIALIZACIÓN EN INGENIERÍA DE GAS
BUCARAMANGA**

2011

**DETERMINACION DE LA TEMPERATURA DE FORMACION DE HIDRATOS
DEL GAS NATURAL UTILIZANDO REDES NEURONALES ARTIFICIALES**

**CARLOS ANDRES AYALA MARIN
CHRISTIAN CAMILO GARCIA YELA**

**Monografía presentada para optar el título de
Especialista en Ingeniería del Gas**

**Director:
Ing. JULIO CESAR PEREZ ANGULO**

**UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FISICOQUÍMICAS
ESCUELA DE INGENIERÍA DE PETRÓLEOS
ESPECIALIZACIÓN EN INGENIERÍA DE GAS
BUCARAMANGA**

2011

DEDICATORIA

A mis Padres Gonzalo Ayala Oliveros y María Consuelo Marín Chica, quienes antes de su partida siempre me apoyaron y brindaron su amor y comprensión para lograr este paso tan importante en mi vida. Solo le pido a Dios que los tenga en paz y gloria, los amaré por siempre.

A mi hermano Juan Gonzalo y demás familiares que contribuyeron de alguna manera a la consecución de este logro.

A María Fernanda Díaz, que en los momentos finales de la especialización me brindó su apoyo y amor.

Carlos Andrés Ayala Marín.

DEDICATORIA

A mis padres, quienes siempre me ofrecieron su apoyo y respaldo incondicional y a pesar de la distancia siempre estuvieron en los momentos más difíciles para darme una voz de aliento y brindarme su amor y comprensión.

A mi hermano Edward, con quien he vivido y compartido momentos buenos y difíciles en diferentes etapas de mi vida.

A mi familia, por el cariño brindado y por confiar siempre en mí

A Eliana González Sánchez, por el amor que me ha brindado y por estar siempre a mi lado.

Christiann Camilo García Yela.

AGRADECIMIENTOS

*Agradecimiento Especial al ingeniero **Julío Cesar Pérez Angulo** profesor de la escuela de ingeniería de petróleos de la Universidad Industrial de Santander por su confianza y cooperación en el transcurso del proyecto.*

*Al ingeniero **Fernando Enrique Calvete** profesor de la escuela de ingeniería de petróleos de la Universidad Industrial de Santander por el tiempo prestado y por la confianza brindada durante el desarrollo de nuestro proyecto.*

A los docentes del programa de especialización en ingeniería del gas de la Universidad Industrial de Santander, por sus contribuciones en nuestra formación como especialistas.

CONTENIDO

	pág.
INTRODUCCION	17
1. HIDRATOS DE GAS	21
1.1 HISTORIA DE LOS HIDRATOS DE GAS	21
1.2 DESCRIPCIÓN DE LOS HIDRATOS DE GAS NATURAL	22
1.3 ESTRUCTURA DE LOS HIDRATOS DE GAS NATURAL	24
1.3.1 Hidratos Estructura I	25
1.3.2 Hidratos Estructura II	27
1.3.3 Hidratos Estructura H	28
1.4 FORMACIÓN DE HIDRATOS	29
1.5 INHIBICIÓN DE HIDRATOS	37
2. REDES NEURONALES ARTIFICIALES	39
2.1 ANALOGÍA ENTRE UNA RED NEURONAL BIOLÓGICA Y UNA RED NEURONAL ARTIFICIAL	39
2.2 TOPOLOGÍA DE UNA RED NEURONAL	41
2.3 FUNCIONES DE TRANSFERENCIA	44
2.4 MODELO PERCEPTRÓN	47
2.4.1 Perceptrón simple	47
2.4.2 Regla de aprendizaje	48
2.4.3 Perceptrón multicapa	48
2.4.4 Propagación Inversa (Backpropagation)	50
3. MODELOS EMPIRICOS PARA LA PREDICCIÓN DE CONDICIONES DE FORMACION DE HIDRATOS DEL GAS NATURAL	52
3.1 MODELOS EMPÍRICOS COMPOSICIONALES	52
3.1.1 Modelos dependientes de la gravedad específica	53

3.1.2 Modelos independientes de la gravedad especifica	54
3.2 MODELOS EMPÍRICOS NO COMPOSICIONALES	56
4. ANALISIS DE ERROR	57
4.1 ANÁLISIS DE ERROR ESTADÍSTICO	57
4.2 PORCENTAJE DE ERROR PROMEDIO RELATIVO	57
4.3 PORCENTAJE DE ERROR PROMEDIO ABSOLUTO	58
4.4. MÍNIMO Y MÁXIMO PORCENTAJE ABSOLUTO DE ERROR RELATIVO	58
4.5 DESVIACIÓN ESTÁNDAR	58
5. PROYECTO NEUROCOMPUTACIONAL	59
5.1 IDENTIFICAR SI EL PROBLEMA ES ADECUADO PARA INTENTAR RESOLVERLO UTILIZANDO REDES NEURONALES	59
5.2. DISEÑO Y CONSTRUCCIÓN DE UN PROTOTIPO QUE OFREZCA SOLUCIONES AL PROBLEMA	60
5.3 ENTRENAMIENTO DE LA RED Y VALIDACIÓN	60
5.4 PROBAR Y OPTIMIZAR EL PROTOTIPO	61
5.5 FASE DE MANTENIMIENTO	61
5.6 RECOLECCIÓN DE LA INFORMACIÓN.	61
6. METODOLOGÍA PARA LA DETERMINACIÓN DE LA TEMPERATURA DE FORMACIÓN DE HIDRATOS DEL GAS NATURAL	62
6.1 ETAPA 1	62
6.2 ETAPA 2	63
6.3 ETAPA 3	66
6.4 ETAPA 4	69
6.5 ESQUEMA DEL PROCESO	70
7. ANALISIS DE RESULTADOS	71
7.1 CONSTANTES AJUSTADAS DE LOS MODELOS SLOAN Y MOTIEE	71

7.2 DEFINICION DE LA TOPOLOGIA DE LA RED NEURONAL	77
7.2.1 Primera Alternativa.	77
7.3 PREDICCIÓN DE LA TEMPERATURA DE FORMACIÓN DE HIDRATOS	84
7.4 EVALUACIÓN DEL MODELO DE SLOAN (KOBAYASHI ET AL 1987)	89
7.5 EVALUACIÓN DEL MODELO DE MOTIEE (1991)	89
7.6 EVALUACIÓN DEL MODELO DE HAMMERSCHMIDT (1934)	90
7.7 EVALUACIÓN MEMBRAN Y STATISTICA (REDES NEURONALES)	90
7.8 COEFICIENTES DE CORRELACIÓN CUADRÁTICO (R ²) OBTENIDOS CON LOS MODELOS EMPÍRICOS.	91
7.9 COEFICIENTES DE CORRELACIÓN CUADRÁTICO (R ²) OBTENIDOS CON MEMBRAN Y CON STATISTICA.	93
8. CONCLUSIONES	96
BIBLIOGRAFIA	98
ANEXOS	99

LISTA DE FIGURAS

	Pág.
Figura 1. Hidrato de Gas Natural	22
Figura 2. Estructura Hidrato de Gas	25
Figura 3. Hidrato Estructura I	26
Figura 4. Hidrato Estructura I	26
Figura 5. Hidrato Estructura II	27
Figura 6. Hidrato Estructura II	28
Figura 7. Hidrato Estructura H	28
Figura 8. Solubilidad de los Hidrocarburos en el agua	31
Figura 9. Condiciones para la formación de hidratos de gases livianos	32
Figura 10. Curvas de Presión y Temperatura para la predicción de formación de Hidratos	33
Figura 11. Expansión permisible sin formación de Hidratos	34
Figura 12. Expansión permisible sin formación de Hidratos	35
Figura 13. Constantes de Equilibrio Vapor Solido para el Metano	36
Figura 14. Constantes de Equilibrio Vapor Solido para el Etano	37
Figura 15. De la neurona biológica a la neurona artificial	39
Figura 16. Proceso de una red neuronal	41
Figura 17. Neurona con varias entradas.	42
Figura 18. Red de tres capas	44
Figura 19. Función de transferencia de Hardlim	45
Figura 20. Función de transferencia de Purelin	46
Figura 21. Función de transferencia sigmoideal	46
Figura 22. Perceptrón simple	47
Figura 23. Perceptrón multicapa para dar solución a la función XOR	49
Figura 24. Esquema general de una RNA multicapa	51
Figura 25. Software GetData Graph Digitizer	63
Figura 26. Datos Tomados Gráfica Katz	64

Figura 27. Datos para entrenamiento	65
Figura 28. Datos para verificación	65
Figura 29. Topología Obtenida de la Red Neuronal en Membrain	67
Figura 30. Diagrama de flujo de la metodología	69
Figura 31. Esquema del Proceso de Obtención de la Temperatura de formación de Hidratos	70
Figura 32. Datos de Entrada y Salida a la Red Neuronal	70
Figura 33. Variables Independientes Modelo Sloan	72
Figura 34. Variables Independientes Modelo Sloan	72
Figura 35. Resultados Regresión Multivariable Modelo Sloan	73
Figura 36. Resumen Regresión Multivariable Modelo Sloan	73
Figura 37. Variables Independientes Modelo Motiee	74
Figura 38. Variables Independientes Modelo Motiee	75
Figura 39. Resultados Regresión Multivariable Modelo Motiee	75
Figura 40. Resumen Regresión Multivariable Modelo Motiee	76
Figura 41. Topología de la Red Neuronal	77
Figura 42. Error Neto vs Lecciones	78
Figura 43. R2 Datos Verificación	79
Figura 44. Topología de la Red Neuronal	79
Figura 45. Error Neto vs Lecciones	80
Figura 46. R2 Datos Verificación	81
Figura 47. Topología de la Red Neuronal	81
Figura 48. Error Neto vs Lecciones	82
Figura 49. R2 Datos Verificación	83
Figura 50. Temperatura de formación de hidratos predicha por modelo Sloan	91
Figura 51. Temperatura de formación de hidratos predicha por modelo Motiee	92
Figura 52. Temperatura de formación de hidratos predicha por modelo Hammerschmidt	92
Figura 53. Temperatura de formación de hidratos predicha por Membrain	93
Figura 54. Temperatura de formación de hidratos predicha por Statistica	94

Figura 55. Red Neuronal	100
Figura 56. Selección de Datos	101
Figura 57. Selección de información	101
Figura 58. Predicciones en Statistica	102
Figura 59. R2 Modelo Sloan	103
Figura 60. R2 Modelo Sloan	103
Figura 61. R2 Modelo Hammerschmidt	104
Figura 62. R2 Membrain	104
Figura 63. R2 Statistica	105

LISTA DE TABLAS

	pág.
Tabla 1. Composición del gas (GPSA).	36
Tabla 2. Constantes Correlación Sloan	74
Tabla 3. Constantes Correlación Motiee	76
Tabla 4. R2 Diferentes alternativas	83
Tabla 5. Temperatura de formación de hidratos para un gas con 0,55 de gravedad específica	84
Tabla 6. Porcentaje de Error	84
Tabla 7. Porcentajes de Error y Desviación estándar	84
Tabla 8. Temperatura de formación de hidratos para un gas con 0,6 de gravedad específica	85
Tabla 9. Porcentaje de Error	85
Tabla 10. Porcentajes de Error y Desviación estándar	85
Tabla 11. Temperatura de formación de hidratos para un gas con 0,68 de gravedad específica	86
Tabla 12. Porcentaje de Error	86
Tabla 13. Porcentajes de Error y Desviación estándar	86
Tabla 14. Temperatura de formación de hidratos para un gas con 0,8 de gravedad específica	87
Tabla 15. Porcentaje de Error	87
Tabla 16. Porcentajes de Error y Desviación estándar	87
Tabla 17. Temperatura de formación de hidratos para un gas con 0,9 de gravedad específica	88
Tabla 18. Porcentaje de Error	88
Tabla 19. Porcentajes de Error y Desviación estándar	88
Tabla 20. R2 Modelos Empíricos, Membrain y Statistica	94

LISTA DE ANEXOS

	Pág.
Anexo A. Red Neuronal en Statistica	100
Anexo B. Calculo R2 Modelos Empíricos y Redes Neuronales en Excel.	103

RESUMEN

TITULO: DETERMINACION DE LA TEMPERATURA DE FORMACION DE HIDRATOS DEL GAS NATURAL UTILIZANDO REDES NEURONALES ARTIFICIALES.*

AUTORES:

**CARLOS ANDRES AYALA MARIN
CHRISTIANN CAMILO GARCIA YELA****

PALABRAS CLAVE:

Hidratos de gas natural, Presión, Temperatura, Gravedad Específica, Redes Neuronales Artificiales.

DESCRIPCION.

Los hidratos de gas son sólidos en forma de cristales con apariencia de hielo pero poseen una estructura diferente. Se forman en sistemas de gas o de líquidos recuperados del gas natural, normalmente cuando hay presencia de agua líquida, sin embargo, no necesariamente tiene que darse esta condición.

Dependiendo de la composición del gas natural, la presión y temperatura para la formación de hidratos varía y siendo conscientes que existe un número amplio de condiciones en los procesos de producción y transporte de gas natural que los puedan generar, métodos alternativos para la predicción de las condiciones de formación de hidratos se requieren, los cuales logren realizar interpolaciones entre medidas realizadas de manera acertada.

Es aquí donde radica la importancia de las redes neuronales, ya que son una aplicación matemática que actúa como un interpolador perfecto, que permite la identificación de patrones establecidos a partir de datos existentes, en este caso datos de Presión, Temperatura y Gravedad Específica. De acuerdo con lo anterior el desarrollo de un modelo aplicado a Redes Neuronales para predecir la temperatura de formación de hidratos, es viable y funcional, ya que ayuda a la caracterización de la información que se requiere en los cálculos de la ingeniería del gas y ayuda a mitigar los problemas operativos que generan tales como: bloqueo de tuberías, bloqueo de equipos e instrumentos, falsas lectura de presión y errores de medición.

Actualmente la industria petrolera se gasta millones de dólares para combatir la formación de hidratos. Por lo tanto, la precisión de la estimación de las condiciones de formación de los hidratos de gas natural es muy importante para optimizar el costo de los sistemas de tuberías y unidades de procesamiento.

* Monografía

** Facultad de Ingenierías Físicoquímicas, Escuela de Ingeniería de Petróleos. Director: Ing. Julio Cesar Perez

ABSTRACT

TITULO: DETERMINING THE TEMPERATURE OF HYDRATE FORMATION OF NATURAL GAS USED ARTIFICIAL NEURAL NETWORKS.*

AUTHORS:

**CARLOS ANDRES AYALA MARIN
CHRISTIANN CAMILO GARCIA YELA ****

KEY WORDS:

Hydrate of natural gas, Pressure, Temperature, Specific Gravity, Artificial Neural Networks.

DESCRIPTION

Gas hydrates are solid as ice-like crystals but have a different structure. Systems are formed in gas or liquid natural gas recovered, usually when liquid water is present, however, need not be given this condition.

Depending upon the composition of natural gas, pressure and temperature for hydrate formation varies and being aware that there is a large number of conditions in the processes of production and transportation of natural gas that can generate alternative methods for the prediction of hydrate formation conditions are required, which achieve that interpolations between measurements made in a proper way.

Herein lies the importance of neural networks because they are a mathematical application which acts as a perfect interpolator, which allows the identification of patterns established from existing data, in this case pressure data, temperature and specific gravity. According to the above, the development of a neural network model applied to predict the hydrate formation temperature is viable and functional, as it helps to characterize the information required in the calculations of gas engineering and support to alleviate operational problems that generate such as blocking of pipes, blocking equipment and instruments, false pressure reading and measurement errors.

Currently the oil industry spends millions of dollars to combat the formation of hydrates. Therefore, the accuracy of the estimate of the formation conditions of natural gas hydrates is very important to optimize the cost of piping systems and processing units.

* Monograph

** Faculty of Engineering Physicochemical, School of Petroleum Engineering. Director: Engineer Julio Cesar Perez

INTRODUCCION

Los hidratos de gas son sólidos en forma de cristales con apariencia de hielo pero poseen una estructura diferente. Se forman en sistemas de gas o de líquidos recuperados del gas natural, normalmente cuando hay presencia de agua líquida, sin embargo, no necesariamente tiene que darse esta condición.

Dependiendo de la composición del gas natural, la presión y temperatura para la formación de hidratos varía y siendo conscientes que existe un número amplio de condiciones en los procesos de producción y transporte de gas natural que los puedan generar, métodos alternativos para la predicción de las condiciones de formación de hidratos se requieren, los cuales logren realizar interpolaciones entre medidas realizadas de manera acertada.

Es aquí donde radica la importancia de las redes neuronales, ya que son una aplicación matemática que actúa como un interpolador perfecto, que permite la identificación de patrones establecidos a partir de datos existentes, en este caso datos de Presión, Temperatura y Gravedad Específica. De acuerdo con lo anterior el desarrollo de un modelo aplicado a Redes Neuronales para predecir la temperatura de formación de hidratos, es viable y funcional, ya que ayuda a la caracterización de la información que se requiere en los cálculos de la ingeniería del gas y ayuda a mitigar los problemas operativos que generan tales como: bloqueo de tuberías, bloqueo de equipos e instrumentos, falsas lectura de presión y errores de medición.

Actualmente la industria petrolera se gasta millones de dólares para combatir la formación de hidratos. Por lo tanto, la precisión de la estimación de las

condiciones de formación de los hidratos de gas natural es muy importante para optimizar el costo de los sistemas de tuberías y unidades de procesamiento.

1. HIDRATOS DE GAS

“El interés industrial petrolero y gasífero sobre los hidratos de gas natural se origino en los inicios del siglo XX, con el descubrimiento de la formación de hidratos en tuberías de transporte de hidrocarburos”¹. Actualmente la industria petrolera se gasta millones de dólares para combatir la formación de hidratos. Debido a lo anterior disponer de modelos empíricos y programas computaciones que predigan con exactitud las condiciones de formación de hidratos es muy importante para la ingeniería del gas.

1.1 HISTORIA DE LOS HIDRATOS DE GAS

Los hidratos fueron descubiertos en 1810 por el señor Humphrey Davy. Durante los primeros 100 años después del descubrimiento el interés sobre los hidratos era solo académico., estudiando las especies que pudieran formas hidratos e identificando la presión y temperatura a la que la formación se producía.

Cuando se forman los hidratos éstos tienden a bloquear tuberías, equipos e instrumentos, restringiendo el flujo. En tomas de presión de medidores producen falsas lecturas de presión y errores de medición. Una vez que se forman los hidratos su remoción es bastante difícil. Debido a lo anterior se iniciaron estudios para resolver dichos problemas; “Hammerschmidt aportó los principios fundamentales para predecir el taponamiento en tuberías por efecto de los hidratos y también creó los métodos básicos de control de hidratos”²

¹ GIL, Juan Camilo y ROJAS, Fernán Isdwar. Métodos utilizados en la recuperación de gas natural en formación de hidratos de lechos marinos. Trabajo de grado Ingeniero de Petróleos. Bucaramanga: Universidad Industrial de Santander. 2008. p.25.

² Ibid., p.25.

Posteriormente también se destacan los científicos O. Katz, R. Kobayashi, E.D. Sloan, V. A: Kamath, quienes profundizaron las bases teóricas y obtuvieron nuevas técnicas para mitigar el problema de los hidratos.

1.2 DESCRIPCIÓN DE LOS HIDRATOS DE GAS NATURAL

“El hidrato es un sólido complejo cristalino estable, con apariencia de hielo pero posee una estructura diferente. Se forma en sistemas de gas o de líquidos recuperados del gas natural, normalmente cuando hay presencia de agua líquida, sin embargo, no necesariamente tiene que darse esta condición. Dependiendo de la composición del gas, la presión y temperatura para la formación de hidratos varía”³.

Lo importante de estos sólidos para la industria del gas es que pueden encontrarse a presiones y temperatura que generan en los procesos de producción y transporte del gas natural. A continuación se presenta una foto de un hidrato:



Figura 1. Hidrato de Gas Natural

Fuente: Internet

³ <http://es.scribd.com/doc/59477491/Capitulo-2-2-4-Hidratos>. p.1

“La composición del hidrato es aproximadamente un 10 % de hidrocarburos y un 90 % de agua. Su gravedad específica es de 0.98, flotan en el agua pero se hunden en los hidrocarburos líquidos”⁴.

Los hidratos más importantes para la industria del hidrocarburo están compuestos por agua y por las siguientes moléculas: Metano (I), Etano (I), Propano (II), Iso-Butano (II), normal-Butano (II), Dióxido de Carbono (I), Nitrógeno (II) y Sulfuro de Hidrogeno (I).

Para lograr la formación y estabilidad adecuada del hidrato, son necesarias ciertas condiciones, entre ellas están:

- “La combinación adecuada de presión y temperatura. La formación de hidratos se favorece a bajas temperaturas, aproximadamente entre 35 y 53 °F y a altas presiones, las cuales pueden ir desde 363 hasta 1595 psi. A medida que la presión aumenta, la temperatura de formación también aumenta”⁵.
- “La presencia de agua libre, bien sea en estado líquido o vapor y de hidrocarburos livianos u otros gases capaces de formar los hidratos”⁶.

Los valores de temperatura y presión dependen de la composición del gas. Cabe resaltar que los hidratos pueden formarse incluso a temperaturas mayores al punto de congelación del agua (32 °F).Adicionalmente existen otras causas que favorecen la formación de hidratos:

A. Turbulencia:

⁴ MARCIAS, J. Martínez. Deshidratación del gas natural. 1995.

⁵ VIRNA N., MARIA M., ALEXIS B., YAMILET S., JENNY M. Evaluación de modelos empíricos para la predicción de hidratos de gas natural. Caracas, Venezuela: Universidad Simón Bolívar. 2009. p.2

⁶ Ibid., p.2.

- Alta Velocidad: La formación de hidratos es favorecida en zonas donde la velocidad del fluido es elevada. Esto genera que las válvulas estranguladoras sean susceptibles para la formación de hidratos. Primero, un descenso significativo de la temperatura cuando el gas es estrangulado a través de una válvula por el efecto Joule – Thompson (J.T). Segundo, la velocidad es elevada en la zona estrecha de la válvula.
 - Agitación: La mezcla de corrientes y componentes dentro de los equipos de proceso, tales como separadores, intercambiadores de calor, línea de flujo, etc., promueven la formación de hidratos.
- B. Lugares de Nucleación: En términos generales, un lugar de Nucleación es un punto donde la transición de fases es favorable, por lo tanto la formación de un sólido de una de las fases del líquido. Estos lugares propicios para la formación de núcleos de hidratos incluyen imperfecciones en las tuberías, puntos soldados, accesorios de tubería (codo, te, válvula, etc.).
- C. Agua libre: La presencia de agua libre no es necesaria para la formación de hidratos, pero ciertamente favorece a su formación. En adición, la interface agua-gas resulta ser un buen lugar de Nucleación para la formación de hidratos.

1.3 ESTRUCTURA DE LOS HIDRATOS DE GAS NATURAL

“La unidad básica de un hidrato es un cristal hueco de moléculas de agua que contiene una sola molécula de gas flotando en su interior”⁷ (figura 2). Existen tres tipos de estructuras de hidratos de gas, entre ellas están: Estructura I, Estructura II

⁷ VIRNA N., MARIA M., ALEXIS B., YAMILET S., JENNY M. Evaluación de modelos empíricos para la predicción de hidratos de gas natural. Caracas, Venezuela: Universidad Simón Bolívar. 2009.p.2.

y Estructura H, las cuales se diferencian en el tipo y número de cavidades que contienen por unidad de celda. En la industria del gas, las estructuras I y II son las de mayor importancia, ya que ambas hospedan pequeñas moléculas de gas natural y la estructura H es la menos común.




Figura 2. Estructura Hidrato de Gas

Fuente: Internet

1.3.1 Hidratos Estructura I

Es la estructura más simple en la formación de hidratos. Esta hecho de dos tipos de jaulas o enmallado cristalino como se observa a continuación:

A. Dodecaedro (poliedro de 12 caras, donde cada cara es un pentágono regular).

A continuación se presentan la estructura:




Figura 3. Hidrato Estructura I

Fuente: Internet

B. Tetradecaedro (poliedro de 14 caras, 12 caras en forma de pentágono y dos en forma hexagonal). A continuación se presenta la estructura:




Figura 4. Hidrato Estructura I

Fuente: Internet

El Dodecaedro es más pequeño que el Tetradecaedro, es por esto que se hace referencia al primero como “enmallado pequeño”, mientras que al Tetradecaedro como “enmallado largo”. Algunos de los formadores de hidratos con estructura I más comunes son el Metano, Etano, Dióxido de Carbono, Sulfuro de Hidrogeno. Por otro lado el Etano solo puede ocupar el enmallado largo.

1.3.2 Hidratos Estructura II

Ésta estructura es más complicada que la anterior. Los hidratos de estructura II también cuentan con dos enmallados:

- A. Dodecaedro (poliedro de 12 caras, donde cada cara es un pentágono regular).
A continuación se presentan su estructura:




Figura 5. Hidrato Estructura II

Fuente: Internet

- B. Hexadecaedro (polígono de 16 caras, 12 caras en forma de pentágono y 4 en forma de hexágono). La estructura se puede observar en la siguiente figura.




Figura 6. Hidrato Estructura II

Fuente: Internet

1.3.3 Hidratos Estructura H

Para formarlos se necesita una molécula pequeña, como el metano, y además un formador de hidratos tipo H. Cabe resaltar que la mayoría de estos componentes no se encuentran en el gas natural. A continuación se presenta la estructura H:




Figura 7. Hidrato Estructura H

Fuente: Internet

1.4 FORMACIÓN DE HIDRATOS

“Una característica inusual de los hidratos es que su formación no es estrictamente dependiente de la temperatura. Se forman a alta presión cuando la temperatura del gas que fluye está muy por encima del punto de congelación del agua. Algunos lugares donde los hidratos se producen son, oleoductos, líneas de flujo, tubing y casing en los pozos”⁸. Debido a que los hidratos restringen el flujo normal de gas, una caída de presión en el hidrato hará que el gas se expanda. Esta expansión enfría el gas a través de la auto refrigeración, lo que contribuye a un mayor crecimiento de los hidratos hasta llegar al punto donde el flujo que totalmente bloqueado.

“Se sabe que el agua es en realidad un grupo disperso formado por moléculas con espacios entre ellos. Cuando los espacios se llenan con otras moléculas, como los gases hidrocarburos: metano (C1), etano (C2), propano (C3) y butano (n-C4 y C4-i) y / o impurezas: nitrógeno (N2), dióxido de carbono (CO2) y sulfuro de hidrógeno (H2S), los cristales se forman y la mezcla se convierte en sólido. Las moléculas de gas pueden ocupar los espacios en las condiciones adecuadas de temperatura y presión sobre la base de la solubilidad del gas en el agua. Todos los gases se disuelven en cierta medida en el agua a temperaturas normales y bajo condiciones de presión atmosférica”⁹

La cantidad de gas que se disuelve en el agua y que ocupa los espacios entre las moléculas del agua depende de la temperatura y presión. Cuando la presión es alta, el gas se comprime y llena los espacios hasta que se saturan. Esta saturación debida a la alta presión puede ocurrir a temperaturas muy por encima del punto de congelación del agua como se menciona anteriormente, lo que

⁸ Canadian Association of Petroleum Producers (CAAP). Prevention and Safe Handling of Hydrates. Calgary, Alberta.1994. p.4.

⁹ Ibid., p.5.

explica por qué se producen los hidratos en las corrientes de gas "caliente". Una vez que el agua está saturada de gas, los cambios químicos de los enlaces y el crecimiento de cristales comienza, dando lugar a la eventual formación de una masa sólida de agua y gas que se llama "hidratos".

“Cada componente del gas natural tiene una solubilidad en agua diferente. Como resultado de ello los hidratos se forman a diferentes presiones y temperaturas para los diferentes compuestos”¹⁰. Gases más pesados, como el pentano, son demasiado grandes para ocupar los espacios en la molécula de agua, mientras que gases más ligeros, como el metano y el etano, lo hacen con mayor facilidad.

En el capítulo 20 de la GPSA (2004) se encuentra una gráfica con las solubilidades de algunos hidrocarburos en el agua. La figura está basada en una data experimental. Yaws, *et al* proporcionó una correlación general la cual puede ser usada para obtener la solubilidad de más de 200 hidrocarburos en el agua. A continuación se presenta la figura:

¹⁰ Canadian Association of Petroleum Producers (CAAP). Prevention and Safe Handling of Hydrates. Calgary, Alberta.1994. p.5.




Figura 8. Solubilidad de los Hidrocarburos en el agua

Fuente: GPSA

Una de las principales dificultades en el diseño de procesos consiste en averiguar a qué condiciones de temperatura y presión empezarán a formarse los hidratos en el proceso. Existen métodos manuales a través de gráficas, correlaciones y paquetes computacionales. Los métodos manuales debido a su inexactitud, solo se utilizan para una estimación rápida de las condiciones para la formación de hidratos, mientras que los paquetes computacionales aceleran y garantizan resultados confiables en la determinación de las condiciones. A continuación se

presentan métodos manuales sencillos presentados en la GPSA para calcular las condiciones de formación de hidratos para gases dulces:

Basada en data experimental la figura 9 presenta la presión y temperatura de equilibrio de los hidratos para las curvas de metano, etano, propano y una mezcla de 70 % etano y 30 % propano.




Figura 9. Condiciones para la formación de hidratos de gases livianos

Fuente: GPSA

Basado en datos experimentales, se presenta a continuación la figura 10 donde se involucra la temperatura, presión y gravedad específica del gas para la estimación

de las condiciones para la formación de hidratos. Ésta gráfica debe ser usada para realizar una primera aproximación.

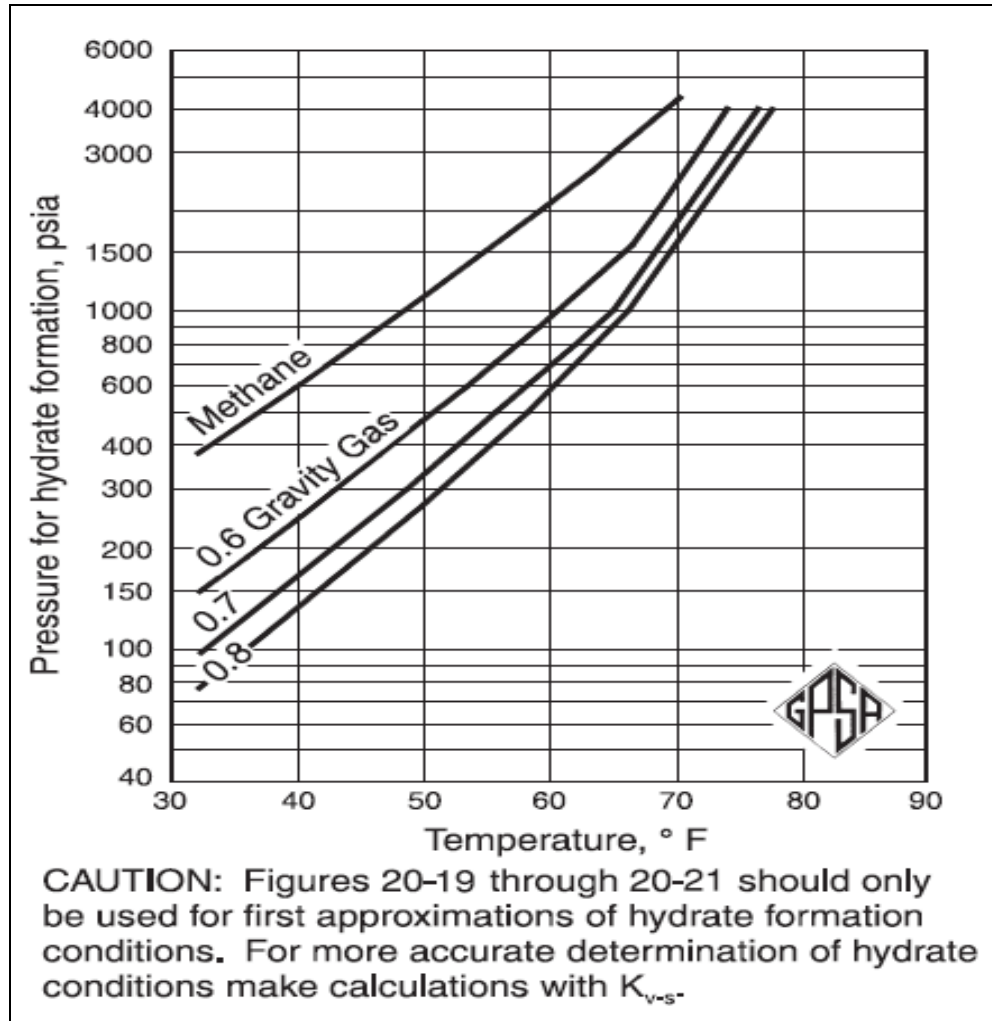


Figura 10. Curvas de Presión y Temperatura para la predicción de formación de Hidratos

Fuente: GPSSA

Manteniendo una presión constante se puede calcular la temperatura a la cual se formarán los hidratos a una determinada gravedad específica del gas. Por debajo de esta temperatura es más que seguro la presencia de hidratos en la corriente. Con el procedimiento descrito anteriormente se está suponiendo que los hidratos se formaron debido a un descenso en la temperatura sin una caída súbita de

presión, como ocurriría en un tren de tubería. “Cabe resaltar que a presiones altas y temperatura bajas, la formación de hidratos es más favorable”.

Si la formación de hidratos se debe a una expansión repentina, por ejemplo una válvula Joule Thompson (J-T), se pueden utilizar las figuras 11 y 12 para una primera aproximación de las condiciones de formación de hidratos.




Figura 11. Expansión permisible sin formación de Hidratos

Fuente: GPSA

Las figuras 11 y 12 permiten determinar hasta qué presión se puede expandir un gas con gravedad específica de 0,6 y 0,7 respectivamente, dada una temperatura sin llegar a la zona de formación de hidratos.




Figura 12. Expansión permisible sin formación de Hidratos

Fuente: GPSA

Las condiciones en la que se pueden formar los hidratos se ven fuertemente afectadas por la composición del gas. De acuerdo a lo anterior, la siguiente tabla

muestra la composición del gas que se utilizó en la GPSA para elaborar las figuras 10, 11 y 12. Adicionalmente los gases fueron saturados con agua.

Fracción Molar			
C ₁	0,9267	0,8605	0,735
C ₂	0,0529	0,606	0,134
C ₃	0,0138	0,0339	0,069
iC ₄	0,0018	0,0084	0,008
nC ₄	0,0034	0,0136	0,024
nC ₅	0,0014	0,023	0,03
Sp. Gr	0,603	0,692	0,796

Tabla 1. Composición del gas.

Fuente: GPSA

Método del factor K: En el método de Katz se ejecutan cálculos tipo "Flash" (ejemplo "punto de rocío"), usando constantes de equilibrio vapor sólido K_{V-s} , las cuales se muestran a continuación para el metano y etano; para los demás componentes se encuentran en la GPSA.




Figura 13. Constantes de Equilibrio Vapor Sólido para el Metano

Fuente: GPSA




Figura 14. Constantes de Equilibrio Vapor Solido para el Etano

Fuente: GPSA

1.5 INHIBICIÓN DE HIDRATOS

“Las estrategias para inhibir los hidratos generalmente consisten en modificar unas o varias de las condiciones necesarias para su formación a fin de desestabilizar el hidrato, entre ellas se encuentran”¹¹ :

- Control de temperatura: Consiste en mantener la temperatura del fluido de producción por encima de la temperatura de formación del hidrato; ello se logra con el calentamiento o recubrimiento de tuberías en los proceso de operación o transporte del gas natural.

¹¹ PICKERING P. F., EDMONDS, B., MOORWOOD, R.A.S., SZCZEPANSKI., WATSON, M. J. (2001). Evaluating new chemicals and alternatives for mitigating hydrates in oil & gas production. Escocia. Citado por VIRNA et al 2001. Evaluación de modelos empíricos para la predicción de hidratos de gas natural. Caracas, Venezuela: Universidad Simón Bolívar. 2009. p.3.

- Control de Presión: Para evitar la formación de hidratos se debe mantener la presión de operación del sistema suficientemente baja; sin embargo no es adecuado en condiciones normales de operación ya que las presiones que se requieren en los sistemas para el transporte de los fluidos de producción son generalmente elevadas.
- Remoción de agua: La deshidratación del gas natural es otro método para evitar la formación de los hidratos.
- Adición de inhibidores químicos: Es un método adoptado por la industria del gas y petróleo para prevenir o controlar la formación de los hidratos. El inhibidor modifica el diagrama de fases del hidrato y altera las condiciones de formación hacia valores más altos de presión y más bajos de temperatura. Se pueden encontrar 3 clases de inhibidores: los termodinámicos (altera potencial químico de la fase acuosa), cinéticos (modifica la cinética de formación) y anti-aglomerante (busca evitar la aglomeración de cristales).

2. REDES NEURONALES ARTIFICIALES

“Basados en la eficiencia de los procesos llevados a cabo por el cerebro, e inspirados en su funcionamiento, varios investigadores han desarrollado desde hace mas de 30 años la teoría de las Redes Neuronales Artificiales (RNA), las cuales emulan las redes neuronales biológicas, y que se han utilizado para aprender estrategias de solución basadas en ejemplos de comportamiento típico de patrones”¹² .

2.1 ANALOGÍA ENTRE UNA RED NEURONAL BIOLÓGICA Y UNA RED NEURONAL ARTIFICIAL

En la figura 15 se observa un elemento de procesamiento en forma general y su similitud con una neurona biológica:




Figura 15. De la neurona biológica a la neurona artificial

Fuente: Tutorial de redes neuronales Universidad Tecnológica de Pereira

¹² Universidad Tecnológica de Pereira, Tutorial de redes neuronales, Facultad de Ingeniería Eléctrica. p. 4.

De la observación del proceso biológico se han hallado los siguientes análogos con el sistema artificial:

- ✓ Las entradas X_i representan las señales que provienen de otras neuronas y que son capturadas por las dendritas.
- ✓ Los pesos W_i son la intensidad de la sinapsis que conecta dos neuronas.
- ✓ θ es la función umbral que la neurona debe sobrepasar para activarse; este proceso biológicamente ocurre en el cuerpo de la célula.

Las señales de entrada $X_1, X_2, X_i, \dots, X_n$ son variables continuas en lugar de impulsos eléctricos como es el caso de una neurona biológica. Cada señal de entrada pasa a través de una ganancia o peso, conocida como conexión sináptica que hace el papel de sinapsis de una neurona biológica. Estos pesos pueden ser positivos (excitatorios) o negativos (inhibitorios), el nodo sumatorio acumula todas las entradas y toma cada señal de entrada y la multiplica por el respectivo peso sináptico. El valor obtenido pasa a través de la función umbral o de transferencia y genera una salida.

Una idea clara del proceso descrito se muestra en la figura 16, donde se puede observar el recorrido de un conjunto de conjunto de señales que entran a la red:

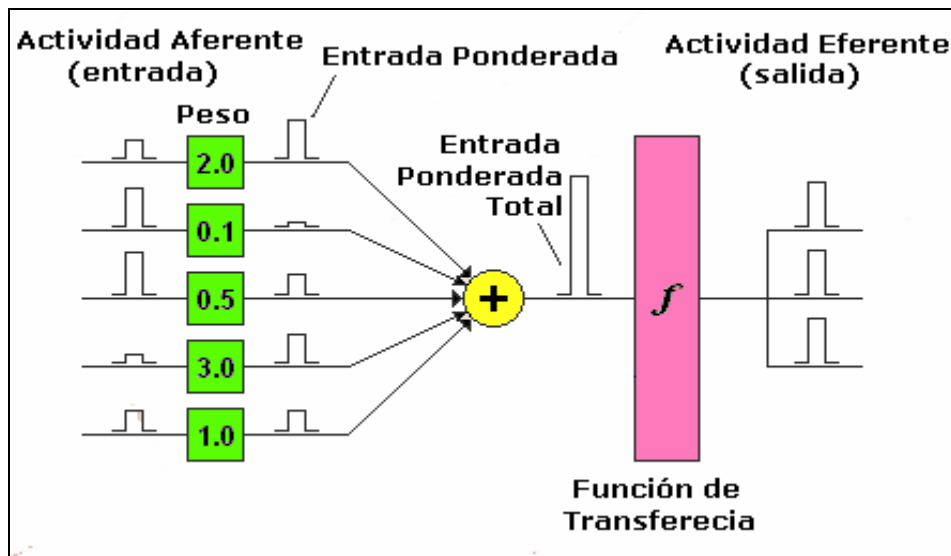


Figura 16. Proceso de una red neuronal

Fuente: Tutorial de redes neuronales Universidad Tecnológica de Pereira

Una vez todas las entradas hallan pasado a través del nodo sumatorio, el valor de la salida equivale a:

$$x_i = f_i(neta_i) \dots\dots\dots Ec.1$$

Donde f_i representa la función umbral o de activación para ese elemento de procesamiento, que corresponde a la función escogida para transformar la entrada neta x_i . La elección de dicha función va a depender de las características específicas de la red.

2.2 TOPOLOGÍA DE UNA RED NEURONAL

Por lo general una neurona tiene más de una entrada, en la figura 17 se observa una red neuronal con R entradas:

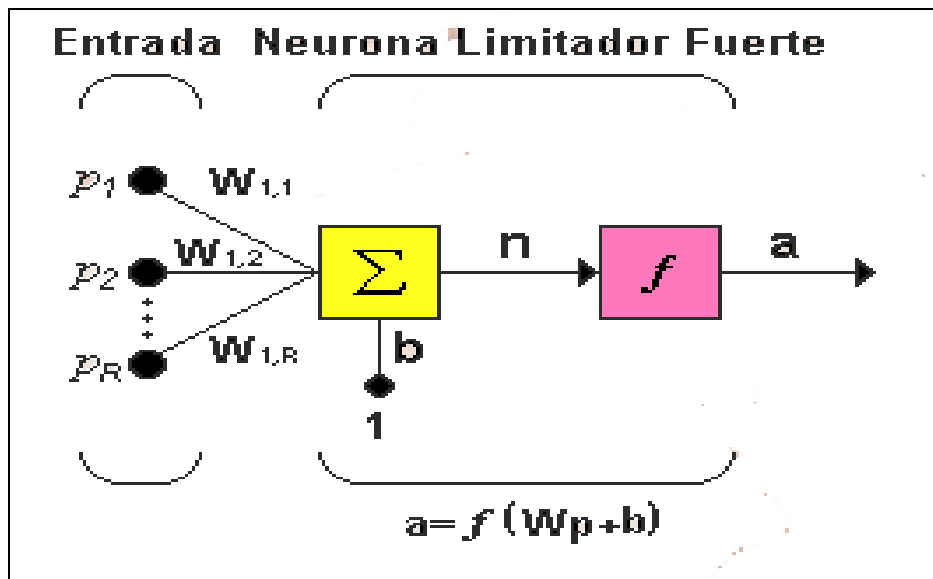


Figura 17. Neurona con varias entradas.

Fuente: Tutorial de redes neuronales Universidad Tecnológica de Pereira

Cada neurona tiene una ganancia b , que llega al nodo sumatorio donde también están las entradas multiplicadas por los pesos, para formar la salida n ,

$$n = w_{1,1}p_1 + w_{1,2}p_2 + \dots + w_{1,R}p_R + b \quad \dots\dots\dots\text{Ec.2}$$

Expresado en forma matricial

$$n = \mathbf{Wp} + b \quad \dots\dots\dots\text{Ec.3}$$

Las dimensiones de p son $R \times 1$, lo que indica que es un vector fila de R elementos. Las entradas pasan a la matriz de pesos, la cual tiene 1 fila y R columnas para el caso de una sola neurona. La salida de la red a es en este caso un escalar, si la red tuviera más de una neurona a , sería un vector.

En una red neuronal los elementos de procesamiento se encuentran agrupados por capas, una capa es una colección de neuronas, de acuerdo a la ubicación de cada capa, esta recibe diferentes nombres.

- Capa de entrada: Recibe las señales de la entrada de la red. Dentro de esta capa no se realiza ningún proceso, razón por la cual varios autores no consideran el vector de entrada como una capa.
- Capas ocultas: Estas capas son las que determinan las diferentes topologías de la red, no tienen contacto con el medio exterior y sus elementos pueden tener diferentes conexiones.
- Capa de salida: Recibe la información de la capa oculta y transmite la respuesta al medio externo.

Si se considera una red con varias capas, o red multicapa, cada capa tendrá su propia matriz de pesos W , su propio vector de ganancias b , un vector de entradas netas n y su propio vector de salidas a . En la figura 18 se muestra una red de tres capas:




Figura 18. Red de tres capas

Fuente: Tutorial de redes neuronales Universidad Tecnológica de Pereira

Para esta red se tienen R entradas, S1 neuronas para la primera capa, S2 neuronas para la segunda capa, las cuales pueden ser diferentes; las salidas de la primera y segunda capa serán la entrada a la segunda y tercera capa respectivamente.

2.3 FUNCIONES DE TRANSFERENCIA

Existen varios tipos de funciones de transferencia, determinar qué tipo de función usar dependerá siempre del problema que se trate de resolver con la red. A continuación se hará una breve descripción de las funciones de transferencia más utilizadas.

- Limitador fuerte (Hardlim): La figura 19 muestra como ésta función de transferencia acerca la salida a uno si el argumento de la función es mayor o igual a cero y lo lleva a cero si el argumento de la función es menor que cero.

Esta función crea neuronas que clasifican las entradas en dos categorías diferentes.

$$a = \begin{cases} 1 & \text{si } n \geq 0 \\ 0 & \text{si } n < 0 \end{cases}$$

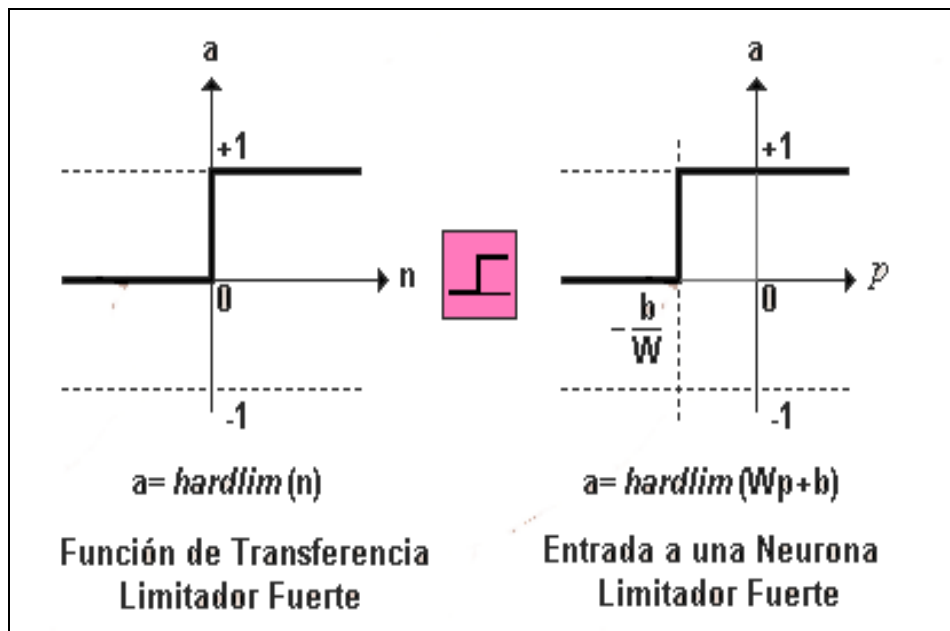


Figura 19. Función de transferencia de Hardlim

Fuente: Tutorial de redes neuronales Universidad Tecnológica de Pereira

- Función de transferencia lineal (Purelin): La salida generada por la función de transferencia es igual a su entrada. A continuación se presenta su representación en la figura 20:




Figura 20. Función de transferencia de Purelin

Fuente: Tutorial de redes neuronales Universidad Tecnológica de Pereira

- Función de transferencia sigmoideal (logsig): Ésta función toma las entradas, que pueden variar desde infinito hasta menos infinito y restringe la salida entre cero y uno.

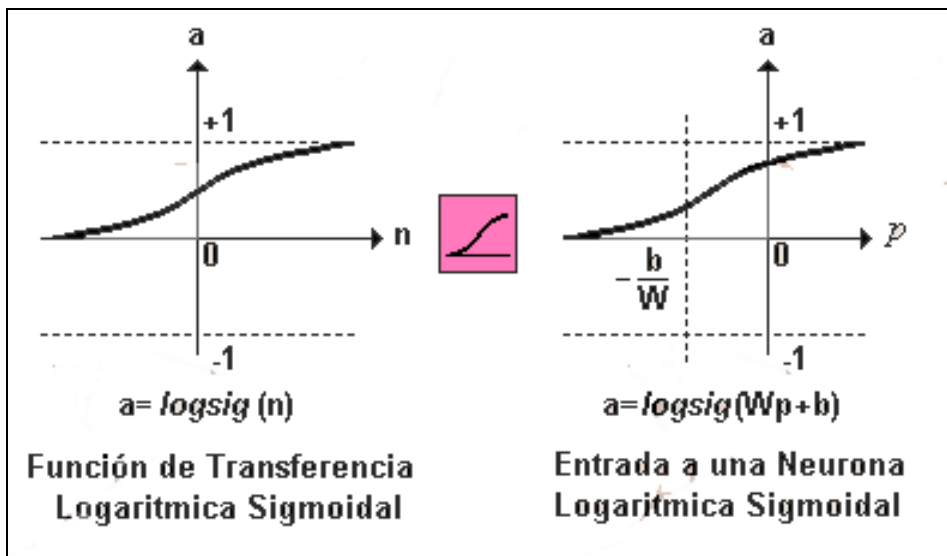


Figura 21. Función de transferencia sigmoideal

Fuente: Tutorial de redes neuronales Universidad Tecnológica de Pereira

2.4 MODELO PERCEPTRÓN

“En general las redes neuronales se pueden clasificar de diversas maneras, según su topología, forma de aprendizaje (supervisado o no supervisado), tipos de funciones de activación, valores de entrada (binarios o continuos)”¹³. Para este trabajo solo se mencionarán el modelo perceptrón que es la base de las redes multicapa y el backpropagation.

2.4.1 Perceptrón simple

El perceptrón simple en su estado inicial no es capaz de clasificar patrones, sin embargo tras un proceso de aprendizaje es capaz de lograrlo. En síntesis el proceso de aprendizaje consiste en reforzar el valor de las conexiones sinápticas que contribuyan a obtener una respuesta correcta y disminuir el valor de las conexiones sinápticas que ayuden a obtener una respuesta incorrecta. Una vez concluido este proceso de aprendizaje la red estará en capacidad de reconocer patrones. A continuación se presenta el esquema del perceptrón simple:

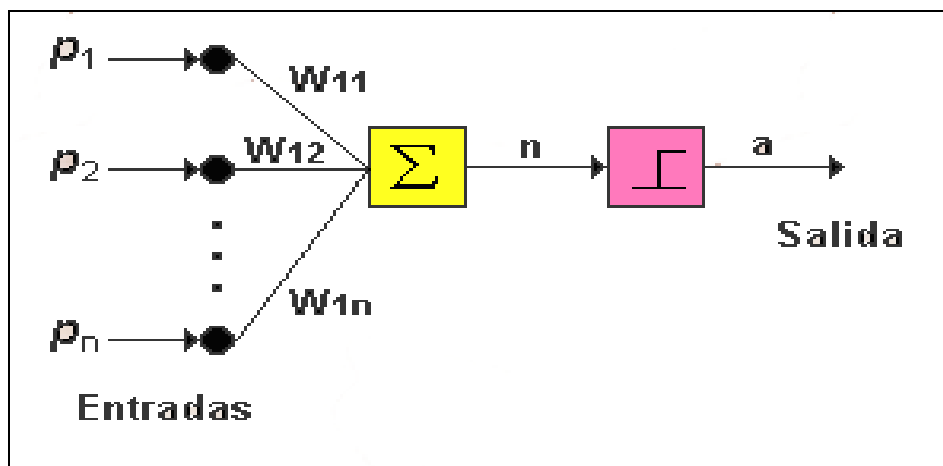


Figura 22. Perceptrón simple

Fuente: Tutorial de redes neuronales Universidad Tecnológica de Pereira

¹³ Universidad Tecnológica de Pereira, Tutorial de redes neuronales, Facultad de Ingeniería Eléctrica.

2.4.2 Regla de aprendizaje

El perceptrón es un tipo de red de aprendizaje supervisado, es decir se necesita conocer la salida esperada para cada una de las entradas presentadas; su comportamiento está definido por pares de esta forma:

$$\{p_1, t_1\}, \{p_2, t_2\}, \dots, \{p_Q, t_Q\} \dots\dots\dots \text{Ec.4}$$

Cuando la entrada p es presentada a la red, la salida generada por la red es comparada con el valor esperado t , y la salida de la red está determinada por:

$$a = f\left(\sum_i w_i p_i + b_i\right) = \text{hardlims}\left(\sum_i w_i p_i + b_i\right) \dots\dots\dots \text{Ec.5}$$

La modificación de los pesos sinápticos se puede lograr utilizando diferentes algoritmos de entrenamiento.

2.4.3 Perceptrón multicapa

Una forma de darle solución al problema de la función XOR es descomponer el espacio en tres regiones, una región pertenecería a la primera clase y las otras dos regiones pertenecerían a la segunda clase. Esta solución se puede ver gráficamente en la figura 23.

Para alcanzar esta solución es necesario agregar otra capa con una neurona a la red. Las dos zonas o regiones que contiene los puntos (0,0) y (1,1) se asocian a una salida nula de la red y la zona central se asocia a la salida con valor 1.




Figura 23. Perceptrón multicapa para dar solución a la función XOR
Fuente: Tutorial de redes neuronales Universidad Tecnológica de Pereira

Un perceptrón multicapa es una red con alimentación hacia delante que tiene varias capas ocultas, lo que le permite establecer regiones de decisión más complejas que el perceptrón simple. Cada una de las neuronas de cada capa actuará como un perceptrón simple y sus salidas serán las entradas de las neuronas de las capas siguientes.

“Es importante recalcar que no existe una técnica para determinar el número de capas ocultas, ni el número de neuronas que debe contener cada una de ellas para un problema específico, esta elección es determinada por la experiencia del diseñador, el cual debe cumplir con las limitaciones de tipo computacional”¹⁴.

¹⁴ Universidad Tecnológica de Pereira, Tutorial de redes neuronales, Facultad de Ingeniería Eléctrica. p. 49.

2.4.4 Propagación Inversa (Backpropagation)

Este es un tipo de red de aprendizaje supervisado que maneja dos fases de propagación. La primera se presenta una vez se ha aplicado un patrón a la entrada de la red, el cual se propaga a través de la red desde la primera capa a través de las capas superiores de la red, hasta generar una salida. La señal de salida se compara con la deseada y se calcula una señal de error.

En la segunda, las salidas de error se propagan hacia atrás, partiendo de la capa de salida, hacia todas las neuronas de la capa oculta que contribuyen directamente a la salida. Este proceso se repite capa por capa, hasta que todas las neuronas de la red hayan recibido una señal de error de acuerdo a su contribución relativa al error total.

En base a la señal de error, se actualizan los pesos de conexión de cada neurona, hasta que la red converja a un estado que permita clasificar correctamente todos los patrones de entrenamiento. El objetivo del algoritmo de aprendizaje es ajustar los parámetros de la red para minimizar el error medio cuadrático. Para el caso de una red con una capa oculta (figura 24) se tiene el siguiente esquema:

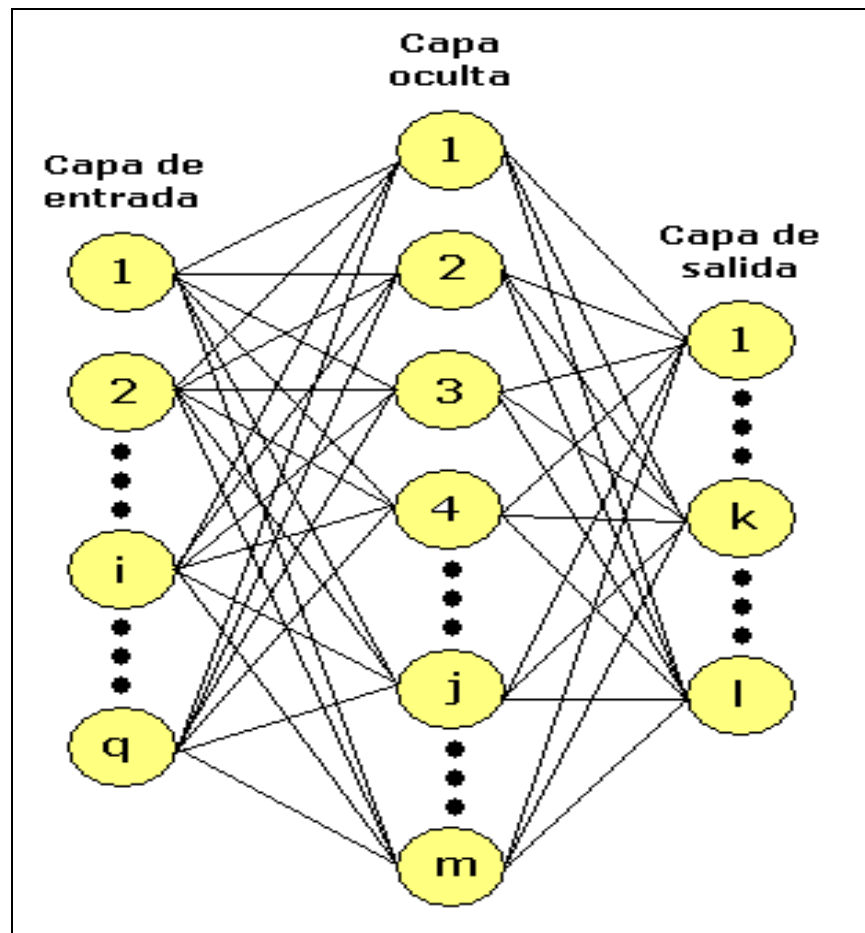


Figura 24. Esquema general de una RNA multicapa

Fuente: Autores

Donde:

q: número de componentes del vector entrada

m: número de neuronas de la capa oculta

l: número de neuronas de la capa de salida

3. MODELOS EMPIRICOS PARA LA PREDICCION DE CONDICIONES DE FORMACION DE HIDRATOS DEL GAS NATURAL

Los modelos empíricos se basan en correlaciones o métodos gráficos sencillos que permiten obtener estimaciones iniciales de las condiciones de formación de hidratos. En la literatura consultada para la realización de esta monografía se hallaron diversos métodos empíricos aplicables para gases dulces y gases ácidos, entre ellos están: el método de Hammerschmidt (1934), el método de K-valores (Carson & Katz, 1942), el método de Berge (1986), el método de Sloan (Kobayashi *et al.* 1987) y por último el método de Motiee (1991).

Es importante recalcar que para este trabajo se parte de las condiciones de presión y gravedad específica para verificar y predecir la temperatura de formación de hidratos del gas natural.

3.1 MODELOS EMPÍRICOS COMPOSICIONALES

“Los modelos composicionales dependen directamente de la composición del gas o mezcla de gases a tratar. Se distinguen los dependientes e independientes de la gravedad específica”¹⁵

¹⁵ VIRNA N., MARIA M., ALEXIS B., YAMILET S., JENNY M. Evaluación de modelos empíricos para la predicción de hidratos de gas natural. Caracas, Venezuela: Universidad Simón Bolívar. 2009. p 3 y 4.

3.1.1 Modelos dependientes de la gravedad específica

“Los modelos empíricos composicionales dependientes de la gravedad específica son los modelos desarrollados por Berge (1986), Sloan (Kobayashi *et al.* 1987), y Motiee (1991).”¹⁶

- Modelo de Berge (1986): “Se distinguen dos ecuaciones explícitas en temperatura según el rango de gravedad específica de la mezcla gaseosa. Se recomienda la aplicación de ambas ecuaciones para temperaturas comprendidas entre 32 y 80 °F y presiones entre 40 y 4400 psi.”¹⁷

Para gravedad específica entre 0,555 y 0,579:

$$T = -96,03 + 25,37 \times \ln P - 0,64 \times (\ln P)^2 + \left(\frac{\gamma_g - 0,555}{0,025} \right) \times (80,61 \times P + 96,03 - 25,37 \times \ln P + 0,64 \times (\ln P)^2) \dots \dots \dots Ec 6$$

Para gravedad específica entre 0,580 y 1,000:

$$T = \left(80,61 \times P - 2,1 \times 10^4 - \left(\frac{1,22 \times 10^3}{\gamma_g - 0,535} \right) - \left[1,23 \times 10^4 + \left(\frac{1,71 \times 10^3}{\gamma_g - 0,509} \right) \right] \right) \times \left(P + 260,42 + \left(\frac{15,18}{\gamma_g - 0,535} \right) \right)^{-1} \dots \dots \dots Ec 7$$

¹⁶ VIRNA N., MARIA M., ALEXIS B., YAMILET S., JENNY M. Evaluación de modelos empíricos para la predicción de hidratos de gas natural. Caracas, Venezuela: Universidad Simón Bolívar. 2009. p 3 y 4.

¹⁷ VIRNA N., MARIA M., ALEXIS B., YAMILET S., JENNY M. Evaluación de modelos empíricos para la predicción de hidratos de gas natural. Caracas, Venezuela: Universidad Simón Bolívar. 2009. p 4.

- Modelo de Sloan (Kobayashi et al. 1987): “Se basa en el ajuste de quince constantes determinadas por medio de una regresión de los datos experimentales. La ecuación aplicada varía con la presión, temperatura y composición de la mezcla a tratar. Los rangos de aplicación recomendados para este método son: temperaturas comprendidas entre 34 y 60 °F, presiones entre 65 y 1500 psi y gravedades específicas entre 0,552 y 0,900.”¹⁸

$$T = 1 / [c_1 + c_2 \times \ln P + c_3 \times \ln \gamma_g + c_4 \times (\ln P)^2 + c_5 \times \ln P \times \ln \gamma_g + c_6 \times [\ln \gamma_g]^2 + c_7 \times (\ln P)^3 + c_8 \times \ln \gamma_g \times (\ln P)^2 + c_9 \times [\ln \gamma_g]^2 \times \ln P + c_{10} \times [\ln \gamma_g]^3 + c_{11} \times (\ln P)^4 + c_{12} \times \ln \gamma_g \times (\ln P)^3 + c_{13} \times [\ln \gamma_g]^2 \times (\ln P)^2 + c_{14} \times [\ln \gamma_g]^3 \times \ln P + c_{15} \times [\ln \gamma_g]^4] \dots \dots \dots Ec 8$$

- Modelo de Motiee (1991): “Este modelo requiere del ajuste de seis constantes a través de una regresión similar a la desarrollada para el modelo de Sloan”¹⁹
Su aplicación es recomendable para temperaturas mayores a 60 °F y presiones mayores a 2031 psi. La ecuación del modelo es la siguiente:

$$T = b_1 + b_2 \times \log P + b_3 \times (\log P)^2 + b_4 \times \gamma_g + b_5 \times \gamma_g^2 + b_6 \times \gamma_g \times \log P \dots \dots Ec.9$$

3.1.2 Modelos independientes de la gravedad específica

A continuación se presentan correlaciones que a diferencia de las mencionadas anteriormente, dependen únicamente de la presión y de la temperatura:

¹⁸ . VIRNA N., MARIA M., ALEXIS B., YAMILET S., JENNY M. Evaluación de modelos empíricos para la predicción de hidratos de gas natural. Caracas, Venezuela: Universidad Simón Bolívar. 2009. p 4.

¹⁹ VIRNA N., MARIA M., ALEXIS B., YAMILET S., JENNY M. Evaluación de modelos empíricos para la predicción de hidratos de gas natural. Caracas, Venezuela: Universidad Simón Bolívar. 2009. p 4.

- Modelo de K-valores (Carson & Katz, 1942): Este modelo fue uno de los primeros modelos empíricos. “Supone que la unidad básica del hidrato es una solución sólida, por lo que emplea la constante de equilibrio sólido-vapor para predecir las condiciones de presión y temperatura a las que el hidrato se forma.”²⁰

La constante de equilibrio sólido-vapor para el componente i se define como:

$$\frac{y_i}{x_i} = K_{i(v-s)} \dots\dots\dots \text{Ec.10}$$

- Modelo de McLeod-Campbell (1961): Se desarrolló un procedimiento empírico que puede ser utilizado para obtener estimados rápidos y exactos de temperaturas de formación de hidratos cuando las presiones se encuentran entre 5947 y 99931 psi. A continuación se presentan las ecuaciones:

$$T = A \times C'^{0.5} \dots\dots\dots \text{Ec.11}$$

$$C' = \sum y_i \times C_i \dots\dots\dots \text{Ec.12}$$

Las constantes dependientes de la composición fueron halladas mediante un ajuste de regresión al igual que para los modelos de Sloan (Kobayashi *et al.* 1987) y Motiee (1991).

²⁰ VIRNA N., MARIA M., ALEXIS B., YAMILET S., JENNY M. Evaluación de modelos empíricos para la predicción de hidratos de gas natural. Caracas, Venezuela: Universidad Simón Bolívar. 2009. p 4.

3.2 MODELOS EMPÍRICOS NO COMPOSICIONALES

Los modelos no composicionales no dependen directamente de la composición del gas puro o mezcla de gases a tratar. A continuación se presenta el modelo propuesto por Hammerschmidt (1934):

- Modelo de Hammerschmidt (1934): “Esta correlación es una de las más sencillas y puede ser empleada para obtener un primer estimado de las condiciones de formación de hidratos del gas natural. Se obtienen mejores resultados en sistemas con valores bajos de presión y temperatura, así como gravedades específicas menores a 0,555.”²¹

$$T = 8,9 \times P^{0,285} \dots\dots\dots \text{Ec.13}$$

²¹ VIRNA N., MARIA M., ALEXIS B., YAMILET S., JENNY M. Evaluación de modelos empíricos para la predicción de hidratos de gas natural. Caracas, Venezuela: Universidad Simón Bolívar. 2009. p 6.

4. ANALISIS DE ERROR

Un análisis de error estadístico se utilizó para comprobar el rendimiento y la precisión de las correlaciones y del software especializado (Membrain y Statistica) en la predicción de las condiciones de formación de hidratos.

4.1 ANÁLISIS DE ERROR ESTADÍSTICO

La precisión de las correlaciones en relación con los valores experimentales se determina por varias medidas estadísticas. Los criterios utilizados en esta monografía son el porcentaje de error promedio relativo, porcentaje de error promedio absoluto, mínimo y máximo porcentaje absoluto de error relativo y la desviación estándar.

4.2 PORCENTAJE DE ERROR PROMEDIO RELATIVO

“Es un indicativo de la desviación relativa en porcentaje a partir de los valores experimentales y se calcula por medio de la siguiente ecuación.”²²

$$Er = \left(\frac{1}{n_d}\right) \times \sum_{i=1}^{n_d} E_t \dots\dots\dots Ec.14$$

²² ABDEL FATTAH, Khaled Ahmed. Evaluation of empirical correlations for natural gas hydrates predictions. Kingdom of Saudi Arabia: King Saud University. 2004. p 5.

4.3 PORCENTAJE DE ERROR PROMEDIO ABSOLUTO

Es definido por medio de la siguiente ecuación:

$$Ea = \left(\frac{1}{n_d}\right) \times \sum_{i=1}^{n_d} |E_i| \dots\dots\dots Ec.15$$

“Es un indicativo de la desviación relativa absoluta en porcentaje a partir de los datos experimentales. Valores bajos implica mayor correlación entre los datos.”²³.

4.4. MÍNIMO Y MÁXIMO PORCENTAJE ABSOLUTO DE ERROR RELATIVO

“Después de que el porcentaje de error absoluto relativo de cada punto de datos se calcula, tanto los valores mínimo y máximo se analizan para saber el margen de error para cada correlación y cada software. La precisión de una correlación puede ser examinada por el máximo porcentaje de error absoluto relativo. Cuanto menor sea el valor mayor será la precisión de la correlación.”²⁴

4.5 DESVIACIÓN ESTÁNDAR

La desviación estándar es una medida de la dispersión de los datos y es expresada como:

$$SD = \left(\frac{1}{n_d - 1}\right) \times \sum_{i=1}^{n_d} E_i^2 \dots\dots\dots Ec.16$$

²³ ABDEL FATTAH, Khaled Ahmed. Evaluation of empirical correlations for natural gas hydrates predictions. Kingdom of Saudi Arabia: King Saud University. 2004. p 6.

²⁴ Ibid. p 6.

5. PROYECTO NEUROCOMPUTACIONAL

“La neurocomputación es una rama de la inteligencia artificial que basa su funcionamiento en la emulación de procesos biológicos”²⁵, siendo sus herramientas principales las Redes Neuronales Artificiales y los Algoritmos Evolutivos. Estas herramientas se caracterizan por su capacidad de adaptación al entorno de información facilitando de esta manera la resolución de problemas complejos.

Para el diseño y planeación de este proyecto de neurocomputación se utiliza una metodología general que permite obtener un lineamiento guía en el desarrollo y promueve un esquema de trabajo ordenado con elementos importantes para tener éxito. Esta metodología consta de 6 fases que se describen brevemente a continuación.

5.1 IDENTIFICAR SI EL PROBLEMA ES ADECUADO PARA INTENTAR RESOLVERLO UTILIZANDO REDES NEURONALES

¿Puede desarrollarse con RNA?, es decir existe algún patrón que la red pueda identificar entre la presión y gravedad específica para obtener la temperatura de formación de hidratos.

²⁵ . MATEUS C., ROJAS D. Análisis y diagnóstico de problemas en el equipo de subsuelo de unidades de bombeo mecánico utilizando redes neuronales. Universidad Industrial de Santander. 2007. p 88.

Se puede desarrollar el problema utilizando Redes Neuronales, por tanto la red identificará características entre las variables mencionadas, que permita establecer una tendencia, para finalmente predecir la temperatura de formación de hidratos.

5.2. DISEÑO Y CONSTRUCCIÓN DE UN PROTOTIPO QUE OFREZCA SOLUCIONES AL PROBLEMA

“En esta fase se define la topología de la red, el tipo de algoritmo de entrenamiento, el tipo de pre-procesamiento y/o codificación de los datos de entrenamiento y además se determina con que información se entrenará la red”²⁶.

Los patrones de entrenamiento deben contener un mínimo de ruido asociado como sea posible además que cada patrón este estudiado y analizado con el fin de que la información se traduzca en proposiciones.

5.3 ENTRENAMIENTO DE LA RED Y VALIDACIÓN

En esta etapa los datos de entrada y salida (esperados) son presentados a la red, para que de esta manera la red logre identificar características que le permita encontrar tendencias o patrones y por tanto predecir resultados de las diferentes variables de entrada.

²⁶ MATEUS C., ROJAS D. Análisis y diagnostico de problemas en el equipo de subsuelo de unidades de bombeo mecánico utilizando redes neuronales. Universidad Industrial de Santander. 2007. p 91.

5.4 PROBAR Y OPTIMIZAR EL PROTOTIPO

“En este proceso se determina si se debe cambiar la topología de la red, si se requieren más datos de entrenamiento o si es necesario cambiar el modelo original incluyendo el algoritmo de entrenamiento”.²⁷

Para optimizar el prototipo se deben volver a las fases 2 y 3; y volver a la fase de prueba una vez realizada alguna modificación. El modelo será óptimo una vez este arroje las salidas requeridas en la fase de prueba. Para esto se deben evaluar las entradas presentadas a la red, salidas y las diferentes topologías de la red.

5.5 FASE DE MANTENIMIENTO

Se realiza una vez se haya construido el sistema. En esta fase se trata de corregir los errores y analizar mejoras en todos los sentidos desde los patrones de entrenamiento, tratamiento de la información, presentación de resultados, entre otros.

5.6 RECOLECCIÓN DE LA INFORMACIÓN.

Esta etapa la información es recolectada y puede que esta sea requerida en cualquiera de las fases de desarrollo del proyecto.

²⁷ MATEUS C., ROJAS D. Análisis y diagnóstico de problemas en el equipo de subsuelo de unidades de bombeo mecánico utilizando redes neuronales. Universidad Industrial de Santander. 2007. p 92.

6. METODOLOGÍA PARA LA DETERMINACIÓN DE LA TEMPERATURA DE FORMACIÓN DE HIDRATOS DEL GAS NATURAL

De acuerdo a las consideraciones anteriormente mencionadas es posible solucionar el problema físico utilizando Redes Neuronales, que permita hacer un estimativo de la temperatura de formación de hidratos del gas natural, a partir de datos de presión y gravedad específica.

6.1 ETAPA 1

En esta etapa se busca recolectar, establecer y organizar la información disponible en una base de datos. Para esto 325 datos de temperatura, presión y gravedad específica fueron tomados de la gráfica de condiciones de formación de hidratos para gases naturales del libro Handbook of Natural Gas Engineering - Donald L. Katz, la cual tiene 13 curvas de gravedad específica (0.55, 0.56, 0.57, 0.58, 0.59, 0.60, 0.62, 0.64, 0.68, 0.7, 0.8 y 0.9). De cada curva se tomaron 25 puntos, asegurando tener información en todo el rango de temperatura y presión.

Para facilitar la recolección de los datos se utilizó el Software GetData Graph Digitizer (figura 25). Éste software permite digitalizar gráficas y obtener los datos originales cuando los valores que se utilizaron para generar las gráficas no están disponibles. Los pasos necesarios son los siguientes.

- Abrir la imagen.
- Establecer el sistema de coordenadas, indicando cual es el máximo y mínimo valor para los respectivos ejes.




Figura 25. Software GetData Graph Digitizer

Fuente: Software

- Para obtener los datos basta con hacer clic sobre la curva e inmediatamente se almacena un registro al lado derecho del software.
- Finalmente, los datos se pueden copiar y pegar en una hoja de Excel.

6.2 ETAPA 2

Para crear los patrones de entrenamiento se tomó aleatoriamente el 70 % de los datos, mientras el 30 % restante se usó para propósitos de verificación. Los patrones de entrenamiento se presentan en forma de pares, utilizando 228 datos,

siendo los valores de entrada la presión y gravedad específica del gas y los valores de salida la temperatura de formación de hidratos. Los 98 datos restantes se utilizaron para probar la red neuronal en Membrain.

Antes de ser ingresados los patrones de entrenamiento y verificación a la red neuronal en el software especializado Membrain, los datos fueron normalizados entre 0 y 1, con el fin de mantener todos los datos a una misma escala mediante la expresión:

$$x_{new} = \frac{x_{old} - x_{min}}{x_{max} - x_{min}} \dots\dots\dots Ec.17$$

A continuación se presentan los 325 datos tomados de la gráfica de Katz.

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R	S	T	U
1	GE	0.555		GE	0.56		GE	0.57		GE	0.58		GE	0.59		GE	0.6		GE	0.62	
2	T	P		T	P		T	P		T	P		T	P		T	P		T	P	
3	33.10	400.85		32.92	358.20		32.99	282.77		33.00	228.31		33.07	190.67		33.07	166.57		33.08	128.57	
4	33.34	419.11		33.94	378.13		33.95	296.88		33.96	244.14		33.97	201.61		33.97	176.13		33.98	135.95	
5	33.86	458.55		35.96	418.66		35.97	324.25		35.98	272.93		35.98	230.52		35.99	195.91		35.99	153.71	
6	37.17	523.92		37.78	468.04		37.79	377.91		37.79	312.08		37.80	260.63		37.81	222.63		37.82	173.78	
7	39.81	595.57		39.82	523.22		39.82	427.24		39.83	348.87		39.84	297.39		39.85	251.69		39.85	198.69	
8	41.79	654.62		41.79	591.54		41.80	477.62		41.81	398.89		41.82	336.90		41.82	287.77		41.83	227.78	
9	43.77	721.81		43.77	661.69		43.78	539.99		43.78	450.97		43.79	395.21		43.80	329.04		43.81	259.75	
10	45.75	818.11		45.75	738.27		45.76	610.50		45.76	509.86		45.77	440.44		45.78	372.00		45.78	297.00	
11	47.72	914.59		47.73	835.81		47.73	690.21		47.74	576.44		47.75	497.85		47.75	425.34		47.76	339.58	
12	49.76	1045.67		49.76	944.97		49.77	780.37		49.78	653.06		49.78	563.33		49.79	480.86		49.80	388.26	
13	51.68	1192.26		51.68	1096.93		51.69	928.22		51.69	793.50		51.70	693.35		51.71	596.05		51.72	443.94	
14	53.71	1351.72		53.72	1221.47		53.72	1031.66		53.73	871.35		53.74	752.72		53.68	642.97		53.69	519.15	
15	55.63	1545.53		55.63	1396.60		55.70	1178.58		55.71	1007.57		55.71	870.38		55.72	751.88		55.73	600.28	
16	57.73	1747.28		57.73	1596.79		57.74	1363.85		57.74	1178.23		57.75	1029.33		57.75	879.23		57.76	708.90	
17	59.71	1939.44		59.71	1825.33		59.71	1595.00		59.72	1362.41		59.73	1190.24		59.73	1029.18		59.74	830.17	
18	61.74	2284.17		61.75	2111.06		61.75	1844.28		61.76	1611.21		61.76	1407.60		61.77	1215.34		61.77	981.78	
19	63.84	2611.43		63.84	2440.91		63.85	2156.58		63.85	1962.96		63.86	1664.59		63.86	1454.23		63.87	1174.17	
20	65.92	3019.73		65.92	2822.48		65.92	2493.71		65.93	2203.24		65.93	1946.60		65.94	1725.32		65.94	1404.36	
21	67.85	3431.67		67.85	3300.54		67.86	2916.03		67.86	2605.58		67.87	2328.14		67.87	2103.80		67.88	1698.64	
22	69.83	4037.50		69.83	3903.41		69.83	3448.73		69.84	3081.51		69.84	2784.57		69.85	2516.24		69.85	2101.45	
23	40.80	609.36		40.81	537.02		40.81	446.67		40.82	361.50		40.83	306.39		40.83	261.42		40.84	210.12	
24	52.70	1273.50		52.70	1136.30		52.71	930.91		52.71	821.24		52.72	712.76		52.69	614.09		52.70	505.41	
25	56.71	1633.35		56.71	1462.96		56.72	1236.62		56.73	1083.21		56.73	947.63		56.74	821.53		56.75	691.63	
26	46.73	880.00		46.74	780.38		46.75	664.64		46.75	544.32		46.76	466.83		46.76	400.68		46.77	325.88	
27	66.83	3059.68		66.84	2768.16		66.84	2554.53		66.85	2177.52		66.85	1943.93		66.85	1702.07		66.86	1441.06	
28																					
29																					
30																					
31	GE	0.64		GE	0.66		GE	0.68		GE	0.7		GE	0.8		GE	0.9				
32	T	P		T	P		T	P		T	P		T	P		T	P				
33	33.03	108.59		33.10	94.87		33.10	85.73		33.10	76.60		33.11	68.22		33.11	62.55				
34	33.93	113.54		33.93	101.45		34.00	91.67		34.00	81.91		34.01	73.19		34.01	66.89				
35	35.91	128.37		35.91	114.70		35.92	103.65		35.92	92.61		35.92	83.69		35.93	76.48				
36	37.92	146.78		37.93	129.68		37.93	117.19		37.94	104.71		37.94	95.69		37.94	87.45				
37	39.86	165.94		39.87	149.95		39.87	132.48		39.87	119.72		39.88	109.41		39.88	99.38				
38	41.84	187.61		41.84	169.53		41.85	149.78		41.85	135.35		41.85	123.69		41.86	114.32				
39	43.82	216.94		43.82	191.67		43.82	169.34		43.83	153.02		43.83	141.43		43.83	130.71				
40	45.79	245.26		45.80	219.15		45.80	191.45		45.81	172.00		45.81	159.89		45.81	149.45				
41	47.77	280.43		47.77	247.76		47.78	218.90		47.78	197.81		47.79	182.82		47.79	172.81				
42	49.81	320.62		49.81	283.28		49.82	247.48		49.82	223.63		49.82	211.39		49.82	197.59				
43	51.72	370.76		51.73	323.90		51.73	282.97		51.74	255.70		51.74	241.71		51.74	228.48				
44	53.70	428.72		53.70	374.54		53.71	327.20		53.71	289.09		53.72	276.36		53.72	261.23				
45	55.74	490.17		55.74	437.97		55.75	378.34		55.75	338.06		55.75	319.55		55.69	302.07				
46	57.77	579.68		57.78	506.42		57.78	442.42		57.79	390.83		57.79	365.36		57.79	353.22				
47	59.75	685.96		59.75	598.92		59.76	517.28		59.76	457.11		59.76	432.09		59.77	408.44				
48	61.78	810.76		61.79	700.37		61.79	605.01		61.80	534.54		61.80	505.28		61.80	477.62				
49	63.88	960.62		63.88	828.24		63.89	715.47		63.89	632.13		63.90	590.84		63.90	552.25				
50	65.85	1121.86		65.86	1015.17		65.86	895.74		65.87	796.06		65.87	706.87		65.87	661.99				
51	67.83	1324.63		67.83	1225.48		67.83	1046.77		67.83	925.31		67.84	844.43		67.84	781.11				
52	69.86	1595.00		69.87	1533.25		69.87	1309.66		69.88	1170.21		69.88	1081.52		69.88	1022.32				
53	40.85	175.11		40.85	157.18		40.86	137.77		40.86	125.72		40.87	115.15		40.87	105.38				
54	52.71	421.20		52.72	373.64		52.72	319.82		52.73	291.87		52.73	270.48		52.73	250.47				
55	56.75	568.08		56.76	501.90		56.76	426.95		56.77	388.91		56.77	361.89		56.77	335.72				
56	46.78	271.59		46.79	242.35		46.79	209.91		46.79	191.56		46.80	176.43		46.80	162.47				
57	66.87	1200.91		66.87	1050.39		66.88	874.06		66.89	797.68		66.89	743.82		66.89	704.24				
58																					
59																					

Figura 26. Datos Tomados Gráfica Katz

Fuente: Autores

Los siguientes datos fueron utilizados en el entrenamiento de la red neuronal.

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R	S	T	
1	33.3397	419.112	0.555		57.7379	1363.33	0.57		66.85	1943.33	0.59		63.6768	980.615	0.64		63.6265	153.022	0.7		
2	35.8573	468.55	0.555		58.7138	1695	0.57		33.0744	86.574	0.6		67.8861	134.69	0.64		45.8057	173.003	0.7		
3	37.7449	523.919	0.555		61.7303	864.28	0.57		33.3732	176.131	0.6		63.8594	1795	0.64		47.1625	197.808	0.7		
4	39.8126	585.969	0.555		63.8463	2158.58	0.57		39.8453	251.688	0.6		40.85	175.11	0.64		51.7366	255.702	0.7		
5	41.7903	654.619	0.555		65.6227	2433.71	0.57		41.6221	287.774	0.6		52.71	421.2	0.64		53.7136	289.091	0.7		
6	43.768	731.912	0.555		67.6597	2936.09	0.57		45.7761	371.959	0.6		55.75	563.08	0.64		59.7621	457.112	0.7		
7	45.7457	818.108	0.555		40.81	446.67	0.57		47.7529	425.336	0.6		33.0962	94.8704	0.68		61.7981	534.536	0.7		
8	47.7233	914.579	0.555		52.71	390.91	0.57		51.7065	556.048	0.6		33.9945	101.449	0.66		63.8938	632.13	0.7		
9	49.702	1015.67	0.555		46.75	664.64	0.57		55.789	751.876	0.6		37.6289	123.661	0.66		65.8668	756.057	0.7		
10	51.7142	1121.72	0.555		66.84	2554.53	0.57		57.7549	873.226	0.6		39.8653	149.949	0.68		67.9028	935.312	0.7		
11	53.691	1233.35	0.555		33.9606	244.136	0.58		59.7306	1028.18	0.6		43.9196	191.665	0.66		40.86	125.72	0.7		
12	55.7056	1351.44	0.555		37.7949	312.078	0.58		63.8676	1454.23	0.6		45.7966	218.146	0.66		52.73	231.67	0.7		
13	57.727	1475.5	0.555		41.8095	398.886	0.58		65.8366	1733.32	0.6		51.7274	323.902	0.68		56.77	388.91	0.7		
14	59.691	1605.33	0.555		43.7867	450.372	0.58		40.83	261.42	0.6		53.7038	374.536	0.66		46.79	191.56	0.7		
15	61.6853	1741.73	0.555		45.7639	503.898	0.58		52.69	634.09	0.6		55.7398	437.374	0.66		69.69	787.68	0.7		
16	63.7142	1884.17	0.555		47.7412	576.435	0.58		56.74	821.53	0.6		57.7762	506.422	0.68		33.1064	69.2107	0.8		
17	65.691	2032.35	0.555		49.7178	653.061	0.58		46.76	400.68	0.6		59.7517	588.924	0.66		34.0071	73.9899	0.8		
18	67.733	2186.38	0.555		51.6946	753.591	0.58		33.0945	128.573	0.62		61.7877	700.367	0.66		35.3239	83.6865	0.8		
19	69.7449	2346.46	0.555		53.7312	871.354	0.58		33.9832	135.949	0.62		63.8833	828.238	0.66		37.8406	95.6886	0.8		
20	71.733	2512.63	0.56		57.7436	1178.23	0.58		35.9004	153.706	0.62		67.8522	1225.48	0.66		41.8547	123.619	0.8		
21	73.7449	2684.91	0.56		63.7989	1362.41	0.58		37.8776	173.763	0.62		69.8656	1533.25	0.66		45.8669	153.832	0.8		
22	75.7719	2863.23	0.56		67.863	1605.58	0.58		39.8544	198.693	0.62		40.85	157.18	0.66		47.7856	182.817	0.8		
23	77.7498	3047.63	0.56		69.8395	1801.51	0.58		41.8312	227.181	0.62		52.72	373.64	0.66		49.822	211.386	0.8		
24	79.7268	3238.06	0.56		52.71	821.64	0.58		43.808	259.764	0.62		46.79	242.35	0.66		51.7917	241.705	0.8		
25	81.7041	3434.51	0.56		56.73	1083.21	0.58		47.7816	339.579	0.62		33.1001	85.7284	0.68		55.752	319.551	0.8		
26	83.6814	3636.6	0.56		46.75	544.32	0.58		55.7276	600.262	0.62		35.9156	103.647	0.68		57.7688	365.356	0.8		
27	85.7138	3844.73	0.56		66.85	2177.52	0.58		57.7631	709.903	0.62		37.8328	117.185	0.68		61.8003	505.277	0.8		
28	87.7088	4059.73	0.56		33.0632	190.67	0.59		59.7391	830.173	0.62		43.8246	163.94	0.68		63.8964	590.839	0.8		
29	89.745	4280.06	0.56		33.968	201.609	0.59		61.7748	981.776	0.62		45.8089	191.452	0.68		65.8744	708.671	0.8		
30	91.8345	4505.91	0.56		38.8387	237.932	0.59		63.8638	1174.17	0.62		47.7786	218.902	0.68		69.8793	1081.52	0.8		
31	93.8853	4737.54	0.56		43.7928	285.208	0.59		65.8449	1404.36	0.62		49.8159	247.477	0.68		40.87	115.15	0.8		
32	95.8949	4974.16	0.56		45.7696	440.439	0.59		67.8795	1698.64	0.62		51.7526	282.959	0.68		52.73	270.48	0.8		
33	97.9393	5216.91	0.56		47.7468	497.35	0.59		69.8533	2101.45	0.62		53.7454	378.342	0.68		46.8	176.49	0.8		
34	99.9327	5465.98	0.56		49.7837	569.326	0.59		40.84	210.12	0.62		61.7934	605.009	0.68		66.89	749.82	0.8		
35	101.948	5721.16	0.56		51.7	658.349	0.59		52.7	505.41	0.62		63.867	855.735	0.68		33.1123	62.5486	0.9		
36	103.9829	5982.769	0.57		53.7369	752.715	0.59		46.77	325.88	0.62		67.8983	1046.77	0.68		34.0106	66.8959	0.9		
37	105.9527	6250.381	0.57		55.7132	870.383	0.59		66.86	444.06	0.62		69.8786	1303.66	0.68		35.9274	76.4795	0.9		
38	107.933	6534.249	0.57		57.7498	1028.33	0.59		33.091	198.594	0.64		40.86	137.77	0.68		45.8714	149.448	0.9		
39	109.9248	6824.23	0.57		59.7252	1190.24	0.59		33.9902	113.593	0.64		56.76	426.15	0.68		47.7877	172.81	0.9		
40	111.8925	7119.619	0.57		61.7607	1407.6	0.59		37.8241	146.779	0.64		46.79	209.91	0.68		49.8246	197.58	0.9		
41	113.877	7423.989	0.57		63.8393	1664.93	0.59		41.8386	187.807	0.64		66.88	874.06	0.68		53.7177	261.233	0.9		
42	115.875	7736.495	0.57		65.8323	1946.6	0.59		47.769	280.427	0.64		33.1045	76.6001	0.7		65.8736	367.989	0.9		
43	117.875	8057.312	0.57		67.8674	2326.14	0.59		51.7222	370.756	0.64		37.8371	104.707	0.7		67.9079	471.113	0.9		
44	119.882	8395.223	0.57		56.73	947.69	0.59		53.6986	428.7	0.64		39.874	119.74	0.7		69.8812	602.342	0.9		
45	121.895	8750.58	0.57		46.76	468.83	0.59		57.771	573.679	0.64		41.8512	135.348	0.7		52.73	250.47	0.9		
46																		56.74	335.72	0.9	

Figura 27. Datos para entrenamiento

Fuente: Autores

Los siguientes datos fueron utilizados en el proceso de verificación de la red neuronal en Membrain.

	A	B	C	D	E	F	G	H	I	J	K	L
1												
2	51.6774	1182.26	0.555		51.6774	1182.26	0.555		39.8701	132.482	0.68	
3	57.7283	1747.28	0.555		37.808	222.626	0.6		41.8473	149.782	0.68	
4	67.8517	3491.67	0.555		43.7989	329.035	0.6		53.709	327.204	0.68	
5	69.8281	4037.5	0.555		49.7902	480.859	0.6		57.7814	442.424	0.68	
6	66.8	609.16	0.555		53.6829	642.972	0.6		59.7574	517.377	0.68	
7	66.83	3059.68	0.555		61.7664	1215.94	0.6		63.889	715.47	0.68	
8	32.9247	358.201	0.56		57.7498	1028.33	0.59		45.8714	149.448	0.9	
9	35.8616	418.659	0.56		69.8464	2516.24	0.6		34.0028	81.9118	0.7	
10	39.817	523.218	0.56		66.85	1702.07	0.6		35.92	92.6108	0.7	
11	51.6813	1068.33	0.56		45.7848	296.997	0.62		49.8198	223.629	0.7	
12	53.7181	1221.47	0.56		49.7985	388.255	0.62		55.7498	338.056	0.7	
13	65.8179	2822.48	0.56		51.7152	443.937	0.62		57.7862	390.889	0.7	
14	69.8294	3909.41	0.56		53.6912	519.147	0.62		69.876	1170.21	0.7	
15	46.74	780.38	0.56		56.75	681.63	0.62		39.8775	109.405	0.8	
16	37.7875	377.907	0.57		35.9073	128.368	0.64		43.8315	141.425	0.8	
17	47.7342	690.212	0.57		39.8614	165.939	0.64		53.7155	276.361	0.8	
18	53.7247	1031.66	0.57		43.815	216.935	0.64		59.7643	432.091	0.8	
19	69.8342	3448.73	0.57		45.7922	245.261	0.64		67.9057	864.43	0.8	
20	56.72	1296.62	0.57		49.8059	320.623	0.64		56.77	361.88	0.8	
21	33.0022	228.313	0.58		55.7354	490.166	0.64		37.8441	87.4468	0.9	
22	35.8782	272.934	0.58		59.7465	685.561	0.64		39.881	99.9814	0.9	
23	39.8327	348.866	0.58		61.782	810.756	0.64		41.8578	114.317	0.9	
24	55.7076	1007.57	0.58		65.8518	1172.86	0.64		43.8346	130.707	0.9	
25	61.7555	1611.21	0.58		46.78	271.59	0.64		51.7409	228.475	0.9	
26	63.852	1862.96	0.58		66.87	1200.91	0.64		55.6941	302.07	0.9	
27	65.8275	2203.24										

6.3 ETAPA 3

Una vez establecidos los patrones de entrenamiento, varias redes neuronales con diferentes topologías y diferentes funciones de transferencia en cada capa se crearon con en el software Membrain. Las redes se entrenaron con el algoritmo Backpropagation.

Las salidas generadas de cada una de las redes neuronales entrenadas se evaluaron en términos del coeficiente de correlación cuadrático (R^2), encontrando que la topología de la red neuronal que generaba los mejores resultados estaba conformada por ***tres capas; una capa de entrada, una capa oculta y una capa de salida.***

La capa de entrada consta de 2 neuronas que representan la Presión y la Gravedad Específica del gas. La capa oculta tiene 10 neuronas y utiliza la función Logaritmo Sigmoidal como función de transferencia y la capa de salida consta de una neurona que corresponde a la temperatura de formación de hidratos, como se puede observar en la figura 29.

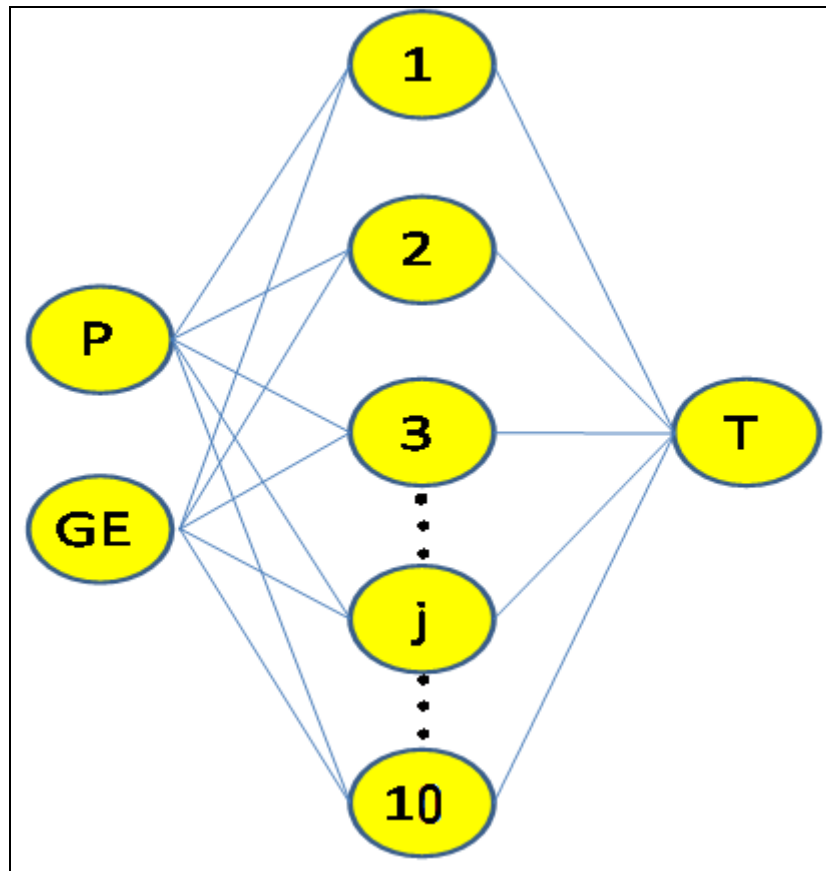
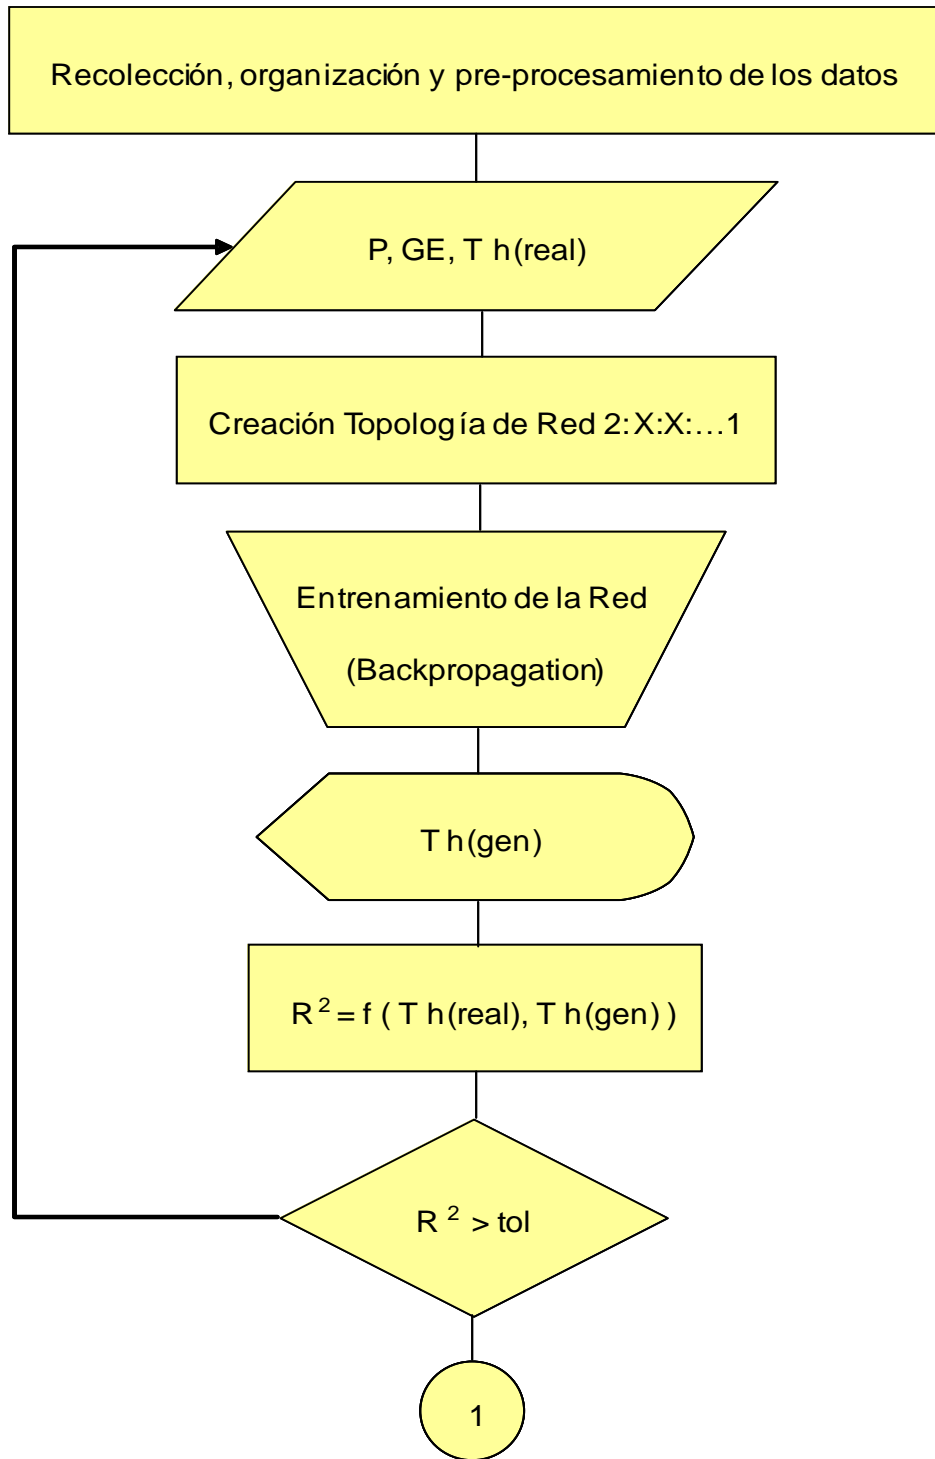


Figura 29. Topología Obtenida de la Red Neuronal en Membrain

Fuente: Autores

No existe una metodología definida que ayude a establecer el número de capas ocultas que debe tener una red, ni con cuantas neuronas debe contar cada capa. El diseño de la arquitectura depende más del nivel de experiencia que posea el programador, puesto que es un proceso de prueba y error hasta encontrar la red más óptima. La topología óptima de la red se escogió en base al coeficiente de correlación cuadrático obtenido entre los datos reales de temperatura de formación de hidratos y los obtenidos a partir de la red neuronal como se menciono anteriormente. A continuación se presenta el diagrama de flujo de la metodología (figura 30):



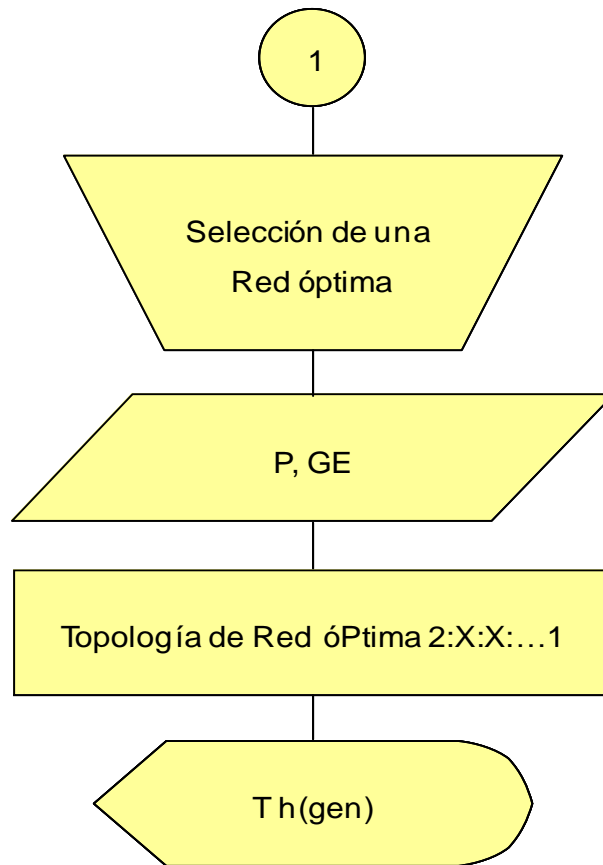


Figura 30. Diagrama de flujo de la metodología
Fuente: Autores

6.4 ETAPA 4

Finalmente con la topología de la red seleccionada se procede a estimar la temperatura de formación de hidratos utilizando Membrain. Adicionalmente cabe resaltar que se utilizó otro software de redes neuronales llamado Statistica, con el fin de comparar los resultados de salida de los 2 paquetes computacionales utilizando la misma topología de la red neuronal encontrada.

6.5 ESQUEMA DEL PROCESO




Figura 31. Esquema del Proceso de Obtención de la Temperatura de formación de Hidratos

Fuente: Autores

Como se puede observar en el esquema anterior, el proceso para generar la temperatura de formación de hidratos consta de dos variables (Presión y Gravedad Específica) que son las entradas a la Red Neuronal.

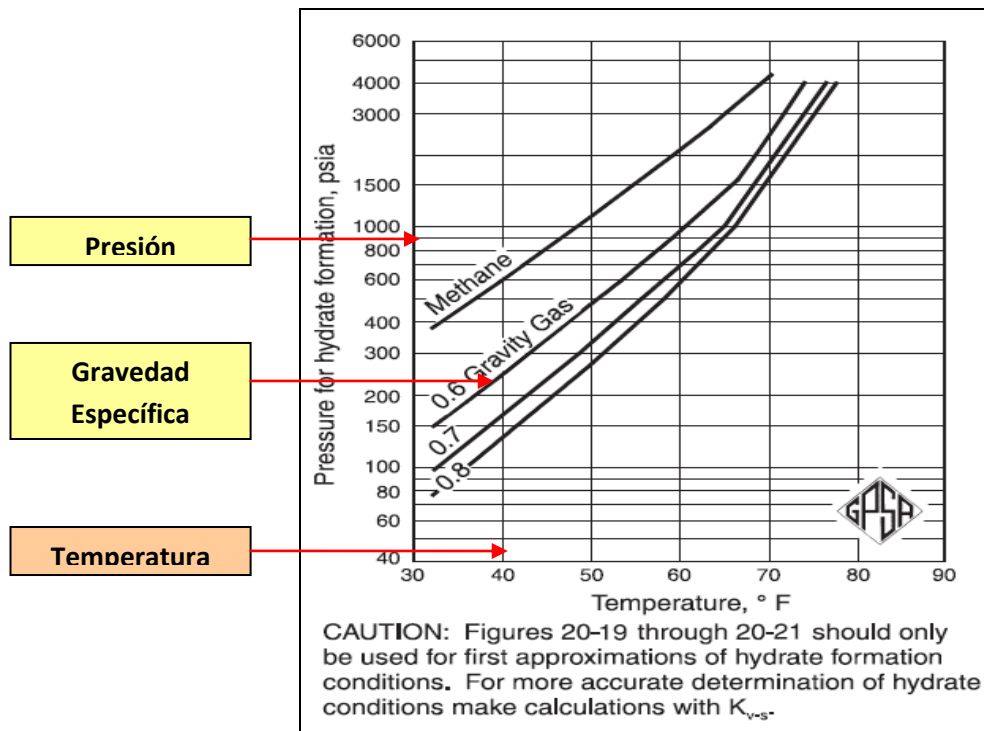


Figura 32. Datos de Entrada y Salida a la Red Neuronal

Fuente: Autores.

7. ANALISIS DE RESULTADOS

Antes de presentar y comparar los resultados obtenidos en la predicción de la temperatura de formación de hidratos utilizando las redes neuronales (Membrain y Statistica) y las correlaciones empíricas de Sloan, Motiee, Hammerschmidt, a continuación se muestra el procedimiento realizado para calcular las constantes de los modelos de Sloan y de Motiee necesarias para su aplicación.

7.1 CONSTANTES AJUSTADAS DE LOS MODELOS SLOAN Y MOTIEE

Los coeficientes de las ecuaciones de Motiee y Sloan se obtuvieron mediante una regresión multivariable desarrollada en el software Statistica. Éste software permite manejar entre muchos otros módulos la aplicación de redes neuronales y la aplicación de regresión multivariable. En el procedimiento para calcular las constantes la variable dependiente es la temperatura de formación de hidratos y las variables independientes se obtienen al realizar las operaciones que acompañan a cada uno de los coeficientes de la correlación. Así por ejemplo para la ecuación de Sloan se tienen 15 variables independientes, como se puede ver la siguiente ecuación:

$$T = 1/[c_1 + c_2 \times \ln P + c_3 \times \ln \gamma_g + c_4 \times (\ln P)^2 + c_5 \times \ln P \times \ln \gamma_g + c_6 \times [\ln \gamma_g]^2 + c_7 \times (\ln P)^3 + c_8 \times \ln \gamma_g \times (\ln P)^2 + c_9 \times [\ln \gamma_g]^2 \times \ln P + c_{10} \times [\ln \gamma_g]^3 + c_{11} \times (\ln P)^4 + c_{12} \times \ln \gamma_g \times (\ln P)^3 + c_{13} \times [\ln \gamma_g]^2 \times (\ln P)^2 + c_{14} \times [\ln \gamma_g]^3 \times \ln P + c_{15} \times [\ln \gamma_g]^4]$$

Las variables independientes se obtuvieron en Excel formulando cada operación que acompaña al coeficiente como lo muestra la siguiente gráfica:

Figura 33. Variables Independientes Modelo Sloan

Fuente: Autores

Los datos se ingresan en el software Statistica y se procede a seleccionar las variables independientes y la variable independiente.

Figura 34. Variables Independientes Modelo Sloan

Fuente: Software Statistica

Una vez identificadas las variables se procede a realizar la regresión multivariable obteniendo los siguientes resultados:

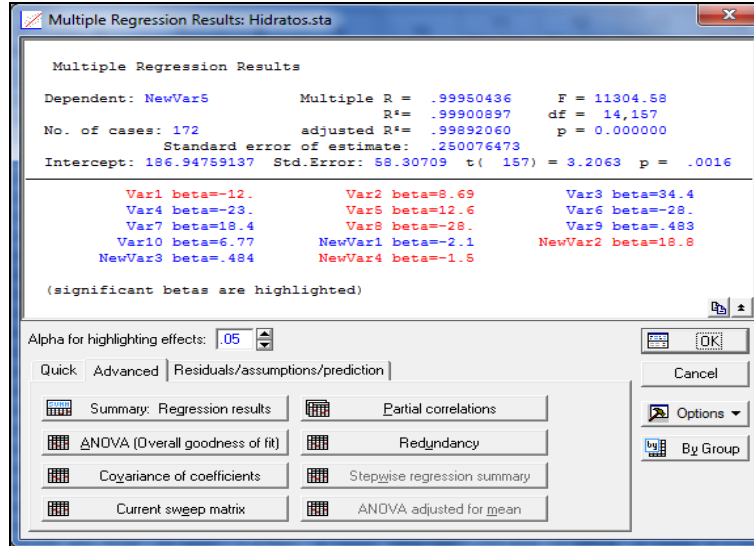


Figura 35. Resultados Regresión Multivariable Modelo Sloan
Fuente: Software Statistica

En la Columna B se pueden observar los coeficientes obtenidos.

	Beta	Std. Err. of Beta	B	Std. Err. of B	t(157)	p-level
Intercept			0.115062	0.042	2.75493	0.006564
Var1	-2.3388	7.5	-0.010684	0.034	-0.31350	0.754320
Var2	5.4209	4.6	0.136748	0.116	1.17563	0.241524
Var3	-28.8898	28.3	-0.011161	0.011	-1.01990	0.309346
Var4	-55.5644	23.5	-0.186369	0.079	-2.36709	0.019148
Var5	-27.0363	4.2	-0.923691	0.143	-6.44463	0.000000
Var6	71.5138	37.8	0.003058	0.002	1.89062	0.060518
Var7	136.6565	39.9	0.060325	0.018	3.42343	0.000789
Var8	94.1654	12.0	0.456281	0.058	7.83002	0.000000
Var9	5.7406	181936.4	0.310202	9831.197	0.00003	0.999975
Var10	-43.2635	17.4	-0.000226	0.000	-2.48867	0.013865
NewVar1	-93.1978	21.8	-0.005465	0.001	-4.28099	0.000032
NewVar2	-67.8476	7.8	-0.045822	0.005	-8.65573	0.000000
NewVar3	5.7394	181936.4	0.310137	9831.197	0.00003	0.999975
NewVar4	8.2263	0.7	0.732299	0.064	11.52943	0.000000

Figura 36. Resumen Regresión Multivariable Modelo Sloan
Fuente: Software Statistica

A continuación en la tabla 2 se presentan las constantes ajustadas obtenidas a partir de la regresión multivariable de los datos experimentales para el modelo de Sloan:

Constantes Correlación Sloan							
C_1	C_2	C_3	C_4	C_5	C_6	C_7	C_8
0,1151	-0,0107	0,1367	-0,0112	-0,1864	-0,9237	0,0031	0,0603
C_9	C_{10}	C_{11}	C_{12}	C_{13}	C_{14}	C_{15}	
0,4563	0,3102	- 0,0002	-0,0055	-0,0458	0,3101	0,7323	

Tabla 2. Constantes Correlación Sloan

Fuente: Autores

De igual forma se procedió para encontrar los coeficientes de la ecuación de Motiee, como sigue:

$$T = b_1 + b_2 \times \log P + b_3 \times (\log P)^2 + b_4 \times \gamma_g + b_5 \times \gamma_g^2 + b_6 \times \gamma_g \times \log P$$

	I	J	K	L	M	N	O	P	Q
		T	B1	log(P) B2	log(P) ² B3	GE B4	GE2 B5	GE*log(P) B6	
1									
2									
3		33.1006		2.602977554	6.775492148	0.555	0.308025	1.444652543	
4		33.9397		2.622330096	6.876615131	0.555	0.308025	1.455393203	
5		35.8573		2.670755942	7.132937303	0.555	0.308025	1.482269548	
6		37.7749		2.719181247	7.393946655	0.555	0.308025	1.509145592	
7		39.8126		2.767578077	7.659488413	0.555	0.308025	1.536005833	
8		41.7903		2.815988606	7.929791831	0.555	0.308025	1.562873677	
9		43.768		2.864399527	8.204784648	0.555	0.308025	1.589741737	
10		45.7457		2.912810664	8.484465822	0.555	0.308025	1.616609905	
11		47.7233		2.961221225	8.768831144	0.555	0.308025	1.64347778	
12		49.7602		3.019394648	9.116744043	0.555	0.308025	1.67576403	
13		51.6774		3.077212596	9.441565157	0.555	0.308025	1.705355713	
14		53.7142		3.13088674	9.802451776	0.555	0.308025	1.737642141	
15		55.691		3.189077439	10.17021492	0.555	0.308025	1.769937979	
16		57.7283		3.242362506	10.51291462	0.555	0.308025	1.799511191	
17		59.7056		3.295663843	10.86140017	0.555	0.308025	1.829093433	
18		61.742		3.358728423	11.28105662	0.555	0.308025	1.864094275	
19		63.8389		3.416888367	11.67512611	0.555	0.308025	1.896373044	
20		65.8153		3.479968114	12.11017807	0.555	0.308025	1.931382303	
21		67.8517		3.543033192	12.5530842	0.555	0.308025	1.966383421	
22		69.8281		3.606112535	13.00404762	0.555	0.308025	2.001392457	
23		32.9247		2.554126794	6.52356368	0.56	0.3136	1.430311005	
24		33.9436		2.578323974	6.647754516	0.56	0.3136	1.443861426	
25		35.8616		2.621860432	6.874152124	0.56	0.3136	1.468241842	
26		37.7793		2.670285754	7.13042601	0.56	0.3136	1.495366022	
27		39.817		2.718682676	7.391235495	0.56	0.3136	1.522462299	
28		41.7942		2.771982649	7.683887804	0.56	0.3136	1.552310283	

Figura 37. Variables Independientes Modelo Motiee

Fuente: Autores

	1 Var1	2 Var2	3 Var3	4 Var4	5 Var5	6 Var6	7 Var7	8 Var8	9 Var9	10 Var10	11 NewVar 1	12 NewVar 2	13 NewVar 3	14 NewVar 4	15 NewVar 5
6.149643	-0.58879	37.81811	-3.62083	0.34667	232.5678	-22.2668	2.131899	-0.20412	1430.209	-136.933	13.11042	-0.20412	0.12018	35.8573	
6.261146	-0.58879	39.20195	-3.68648	0.34667	245.4452	-23.0816	2.170554	-0.20412	1536.793	-144.517	13.59015	-0.20412	0.12018	37.7749	
6.372584	-0.58879	40.60983	-3.7521	0.34667	258.7895	-23.9105	2.209186	-0.20412	1649.158	-152.372	14.07822	-0.20412	0.12018	39.8126	
6.484053	-0.58879	42.04295	-3.81773	0.34667	272.6087	-24.7543	2.247829	-0.20412	1767.61	-160.509	14.57504	-0.20412	0.12018	41.7903	
6.595524	-0.58879	43.50093	-3.88336	0.34667	286.9114	-25.6128	2.286472	-0.20412	1892.331	-168.93	15.08048	-0.20412	0.12018	43.768	
6.706994	-0.58879	44.98377	-3.94899	0.34667	301.7059	-26.4859	2.325116	-0.20412	2023.54	-177.641	15.59454	-0.20412	0.12018	45.7457	
6.818464	-0.58879	46.49145	-4.01462	0.34667	317.0003	-27.3736	2.363759	-0.20412	2161.455	-186.546	16.11721	-0.20412	0.12018	47.7233	
6.952413	-0.58879	48.03605	-4.09349	0.34667	336.0522	-28.4596	2.410195	-0.20412	2336.374	-197.863	16.75667	-0.20412	0.12018	49.7602	
7.075183	-0.58879	50.05822	-4.16578	0.34667	354.171	-29.4736	2.452756	-0.20412	2505.825	-208.531	17.3537	-0.20412	0.12018	51.6774	
7.209133	-0.58879	51.9716	-4.24465	0.34667	374.6702	-30.6002	2.499193	-0.20412	2701.047	-220.601	18.01701	-0.20412	0.12018	53.7142	
7.343122	-0.58879	53.92144	-4.32354	0.34667	395.9517	-31.7483	2.545643	-0.20412	2907.522	-233.131	18.69296	-0.20412	0.12018	55.691	
7.465816	-0.58879	55.7384	-4.39578	0.34667	416.1326	-32.8181	2.588177	-0.20412	3106.769	-245.014	19.32285	-0.20412	0.12018	57.7283	
7.588546	-0.58879	57.58604	-4.46804	0.34667	436.9949	-33.9059	2.630724	-0.20412	3316.152	-257.297	19.96337	-0.20412	0.12018	59.7656	
6.037057	-0.57982	36.44605	-3.5004	0.336189	220.0269	-21.1321	2.029595	-0.19493	1328.315	-127.576	12.25278	-0.19493	0.113023	35.8616	
6.14856	-0.57982	37.80479	-3.56505	0.336189	232.445	-21.9199	2.067081	-0.19493	1429.202	-134.776	12.70957	-0.19493	0.113023	37.7793	
6.259998	-0.57982	39.18758	-3.62966	0.336189	245.3142	-22.7217	2.104546	-0.19493	1525.666	-142.238	13.17445	-0.19493	0.113023	39.817	
6.382726	-0.57982	40.73919	-3.70082	0.336189	260.0271	-23.6213	2.145805	-0.19493	1659.682	-150.769	13.69609	-0.19493	0.113023	41.7942	
6.494197	-0.57982	42.17459	-3.76546	0.336189	273.8901	-24.4536	2.183281	-0.19493	1778.696	-158.807	14.17866	-0.19493	0.113023	43.7719	
6.605667	-0.57982	43.63484	-3.83009	0.336189	288.2372	-25.3003	2.220756	-0.19493	1903.999	-167.125	14.66957	-0.19493	0.113023	45.7496	
6.728395	-0.57982	45.2713	-3.90125	0.336189	304.6032	-26.2491	2.262016	-0.19493	2049.491	-176.615	15.21974	-0.19493	0.113023	47.7273	
6.851091	-0.57982	46.93744	-3.97239	0.336189	321.5727	-27.2152	2.303265	-0.19493	2203.124	-186.454	15.77988	-0.19493	0.113023	49.7641	
6.973852	-0.57982	48.63461	-4.04357	0.336189	339.1706	-28.1992	2.344536	-0.19493	2365.325	-196.657	16.35045	-0.19493	0.113023	51.6813	
7.10781	-0.57982	50.52097	-4.12124	0.336189	359.0935	-29.2933	2.389571	-0.19493	2552.368	-208.209	16.94622	-0.19493	0.113023	53.7181	
7.241796	-0.57982	52.44361	-4.19893	0.336189	379.7859	-30.4078	2.434616	-0.19493	2750.332	-220.207	17.63099	-0.19493	0.113023	55.6949	
7.375751	-0.57982	54.4017	-4.2766	0.336189	401.2534	-31.5431	2.47965	-0.19493	2959.545	-232.654	18.28928	-0.19493	0.113023	57.7318	
7.509735	-0.57982	56.39612	-4.35428	0.336189	423.5199	-32.6995	2.524694	-0.19493	3180.523	-245.565	18.95978	-0.19493	0.113023	59.7086	
5.811886	-0.56212	33.77802	-3.26697	0.315978	196.314	-18.9873	1.836426	-0.17762	1140.955	-110.352	10.6731	-0.17762	0.099842	35.8703	
5.934648	-0.56212	35.22005	-3.33598	0.315978	209.0186	-19.7979	1.875216	-0.17762	1240.452	-117.493	11.12875	-0.17762	0.099842	37.7875	
6.057344	-0.56212	36.69141	-3.40495	0.315978	222.3525	-20.6249	1.913985	-0.17762	1346.26	-124.932	11.59367	-0.17762	0.099842	39.8248	
6.168813	-0.56212	38.05426	-3.46761	0.315978	234.7496	-21.391	1.949207	-0.17762	1448.127	-131.957	12.0243	-0.17762	0.099842	41.8025	
6.291541	-0.56212	39.58349	-3.53659	0.315978	249.0412	-22.2506	1.987987	-0.17762	1566.853	-139.991	12.5075	-0.17762	0.099842	43.7797	

Figura 38. Variables Independientes Modelo Motiee

Fuente: Software Statistica

Una vez identificadas las variables se procede a realizar la regresión multivariable obteniendo los siguientes resultados:

Multiple Regression Results

Dependent: **Var6** Multiple R = **.99974962** F = **8383.956**
 R² = **.99949929** df = **5, 21**
 No. of cases: **27** adjusted R² = **.99938008** p = **0.000000**
 Standard error of estimate: **.065495315**
 Intercept: **-1005.951558** Std. Error: **73.93451** t(**21**) = **-13.61** p = **.0000**

Var1 beta=7.09 **Var2 beta=-2.3** **Var3 beta=13.9**
Var4 beta=-8.0 **Var5 beta=-4.7**

(significant betas are highlighted)

Alpha for highlighting effects: **.05**

Quick | Advanced | Residuals/assumptions/prediction

Summary: Regression results Partial correlations
 ANOVA (Overall goodness of fit) Redundancy
 Covariance of coefficients Stepwise regression summary
 Current swagep matrix ANOVA adjusted for mean

Figura 39. Resultados Regresión Multivariable Modelo Motiee

Fuente: Software Statistica

En la Columna B se pueden observar los coeficientes obtenidos.

Regression Summary for Dependent Variable: Var6 (Spreadsheet5)						
R= .99974962 R ² = .99949929 Adjusted R ² = .99938008						
F(5,21)=8384.0 p<0.0000 Std.Error of estimate: .06550						
N=27	Beta	Std.Err. of Beta	B	Std.Err. of B	t(21)	p-level
Intercept			-1005.95	73.9345	-13.6060	0.000000
Var1	7.09272	0.814518	226.91	26.0584	8.7079	0.000000
Var2	-2.29642	0.541986	-10.65	2.5127	-4.2371	0.000369
Var3	13.88651	0.844265	2067.44	125.6951	16.4480	0.000000
Var4	-7.97535	0.449941	-1021.77	57.6446	-17.7253	0.000000
Var5	-4.65758	0.443636	-218.29	20.7919	-10.4987	0.000000

Figura 40. Resumen Regresión Multivariable Modelo Motiee

Fuente: Software Statistica

A continuación en la tabla 3 se presentan las constantes ajustadas obtenidas a partir de la regresión multivariable de los datos experimentales para el modelo de Motiee:

Constantes Correlación Motiee					
b_1	b_2	b_3	b_4	b_5	b_6
-1005,95	226,91	-10,65	2067,44	-1021,77	-218,29

Tabla 3. Constantes Correlación Motiee

Fuente: Autores

Una vez obtenidas las constantes ajustadas por medio de la regresión, los modelos de Sloan y Motiee pueden ser usados para predecir la temperatura de formación de hidratos, como se verá más adelante.

7.2 DEFINICION DE LA TOPOLOGIA DE LA RED NEURONAL

En el desarrollo de la aplicación se utilizaron tres distintas topologías de la Red Neuronal buscando un óptimo entrenamiento, que permitiera encontrar los valores de la temperatura de formación de hidratos que presentarían menor desviación. De acuerdo con lo anterior, se analizó el coeficiente de correlación cuadrático (R^2) para cada una de las tres distintas configuraciones y se eligió la topología que presentará el mayor R^2 , identificando de esta manera la metodología más acertada para la predicción de la temperatura de formación de hidratos.

7.2.1 Primera Alternativa. En primera instancia se creó en Membrain una red neuronal con la siguiente topología: 2 neuronas en la capa de entrada (presión y gravedad específica), 5 neuronas en la capa oculta y una neurona en la capa de salida (temperatura formación de hidratos). Como función de activación la función tangente hiperbólica (figura 41).

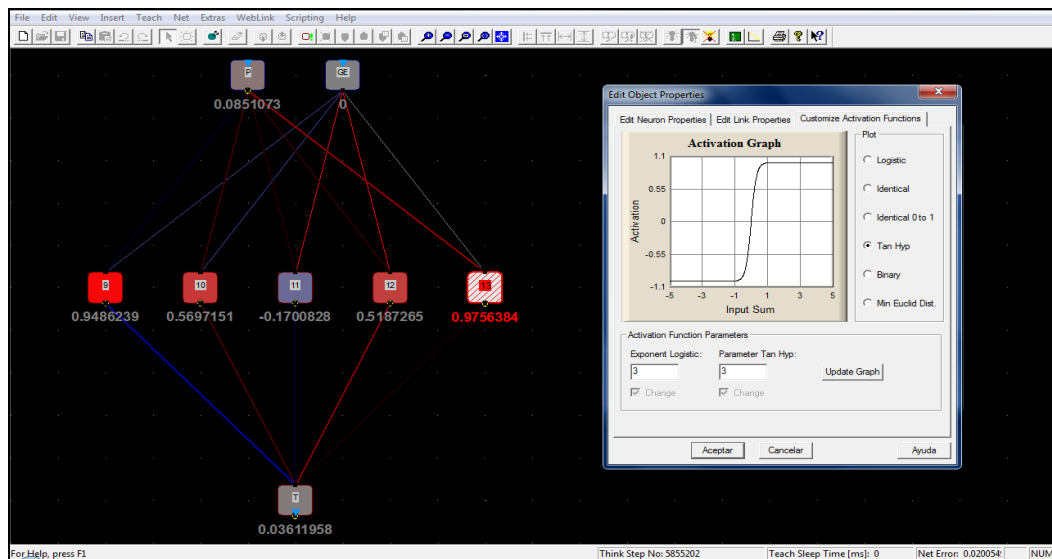


Figura 41. Topología de la Red Neuronal

Fuente: Membrain

Una vez creada la red empieza el proceso de entrenamiento. El software Membrain permite visualizar el comportamiento del error versus el número de lecciones, como se observa en la siguiente gráfica (figura 42). El error neto empieza a disminuir en un comienzo llegando aproximadamente a 0,12 %, pero pasadas las 100.000 lecciones el error comienza a incrementarse hasta un 8 %, quizá por el comportamiento que le da la función de activación actual a los datos.

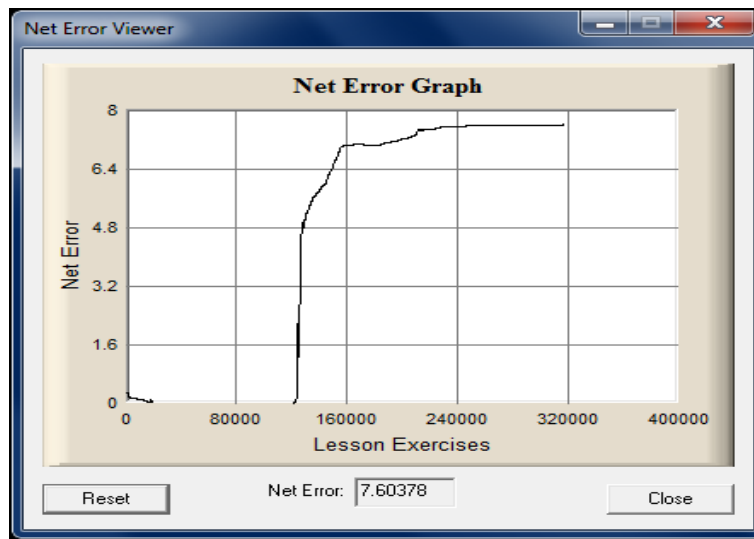


Figura 42. Error Neto vs Lecciones

Fuente: Membrain

El coeficiente de correlación cuadrático que se obtuvo con los datos de verificación antes de que el error comenzara a incrementarse fue de 0,812. Para obtenerlo se exportaron los datos, se llevaron a Excel y se graficaron contra los datos reales (figura 43).




Figura 43. R^2 Datos Verificación

Fuente: Membrain

7.2.2 Segunda Alternativa. En esta alternativa se creó en Membrain una red neuronal con la siguiente topología: 2 neuronas en la capa de entrada (P y G.E), 10 neuronas en la capa oculta y una neurona en la capa de salida (T). Como función de activación la función logaritmo sigmoidal (figura 44).

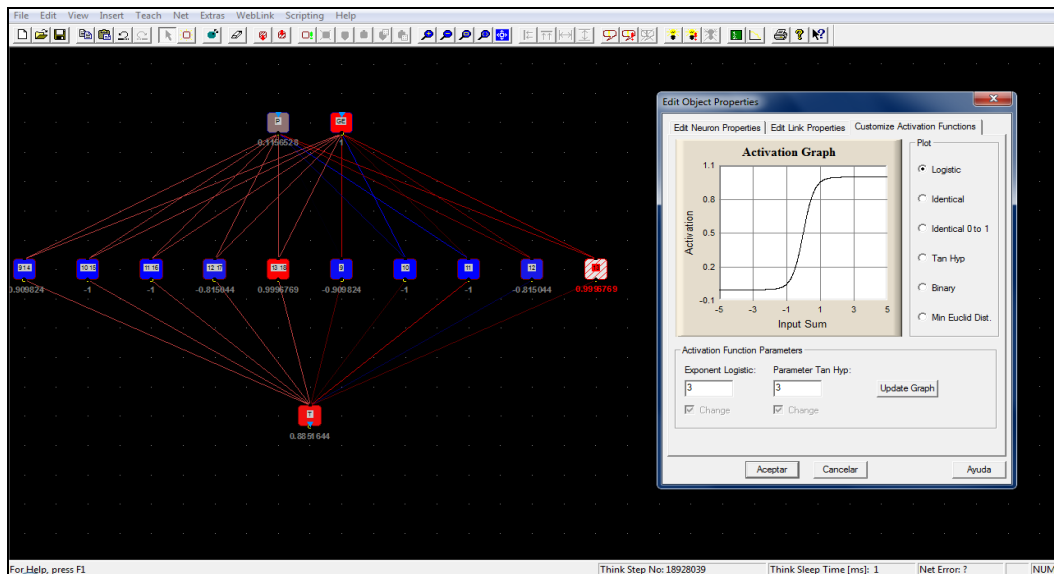


Figura 44. Topología de la Red Neuronal

Fuente: Membrain

Una vez creada la red empieza el proceso de entrenamiento. Al igual que con la anterior topología, se visualizó el comportamiento del error versus el número de lecciones (figura 45). Se puede observar que a medida que avanzan las lecciones el porcentaje de error disminuye, llegando aproximadamente a un 0,04 %. Cabe resaltar que desde el inicio del entrenamiento el porcentaje de error tiene un comportamiento descendente.

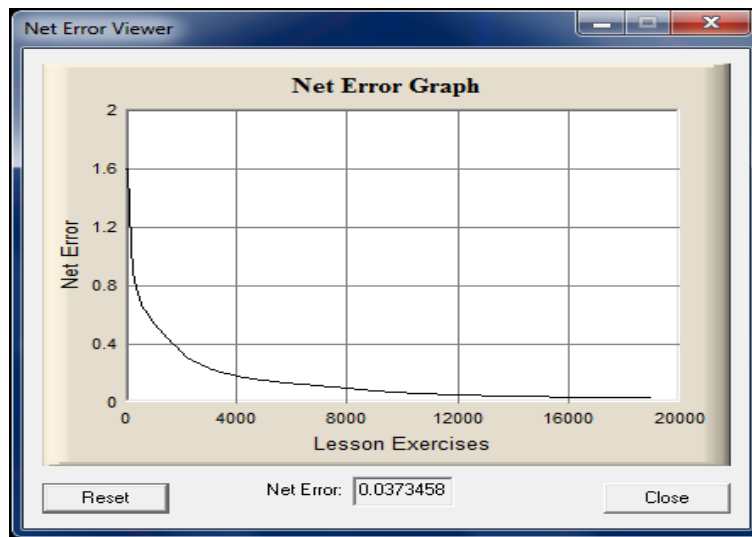


Figura 45. Error Neto vs Lecciones

Fuente: Membrain

El coeficiente de correlación cuadrático que se obtuvo con los datos de verificación fue de 0,998. Para obtenerlo se exportaron los datos, se llevaron a Excel y se graficaron contra los datos reales (figura 46).

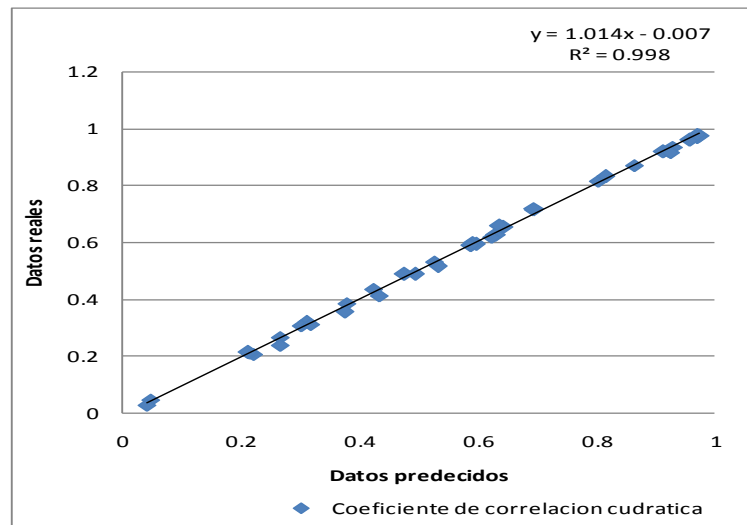
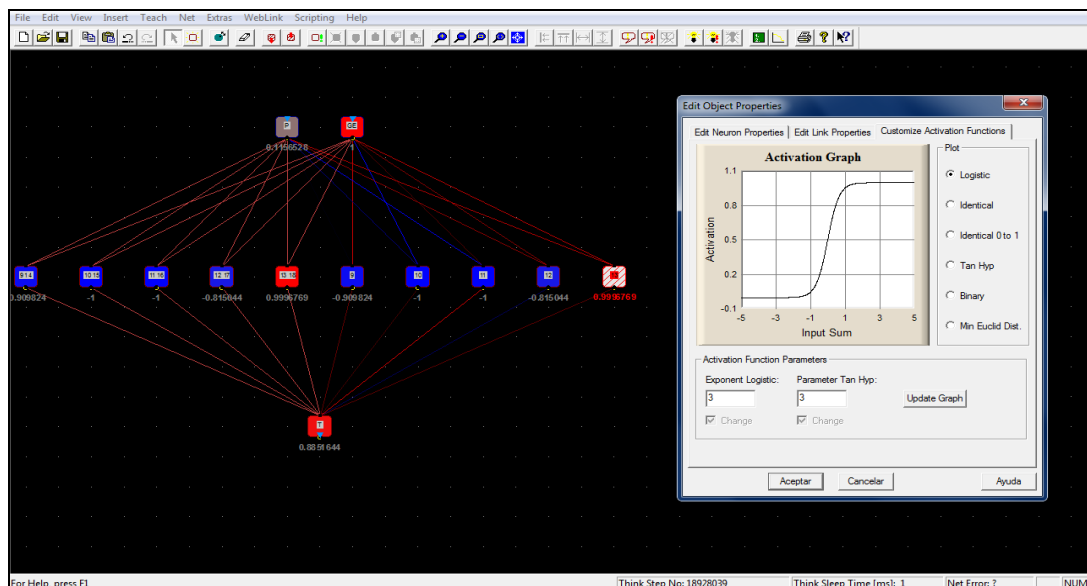


Figura 46. R² Datos Verificación

Fuente: Membrain

7.2.3 Tercera Alternativa. En esta alternativa se creó una red neuronal con la siguiente topología: 2 neuronas en la capa de entrada (P y G.E), 14 neuronas en la capa oculta y una neurona en la capa de salida (temperatura formación de hidratos). Como función de activación la función logaritmo sigmoideal (figura 47).



Fuente: Membrain

Una vez creada la red empieza el proceso de entrenamiento. Al igual que con las topologías anteriores, se visualizó el comportamiento del error neto versus el número de lecciones (figura 48). Se puede observar que a medida que avanzan las lecciones el porcentaje de error disminuye, llegando aproximadamente a un 0,05 %.

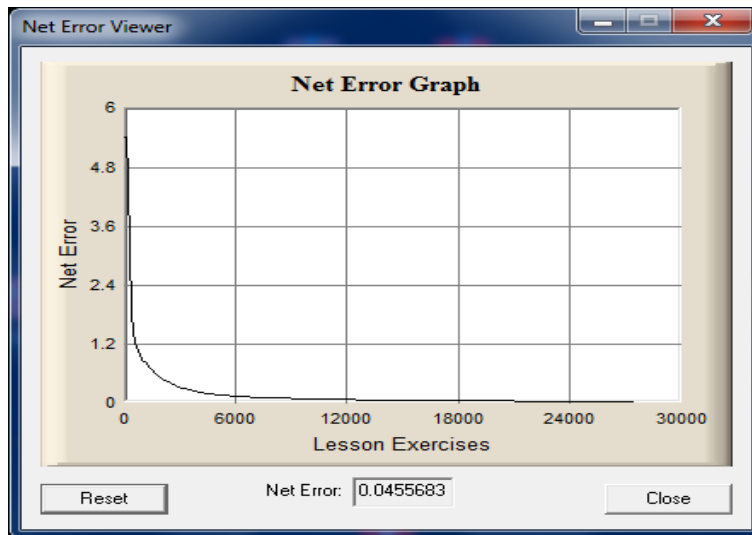


Figura 48. Error Neto vs Lecciones
Fuente: Membrain

El coeficiente de correlación cuadrático que se obtuvo con los datos de verificación fue de 0,998. Para obtenerlo se exportaron los datos, se llevaron a Excel y se graficaron contra los datos reales (figura 49).




Figura 49. R^2 Datos Verificación

Fuente: Membrain

Se puede observar de los resultados anteriores, que con la misma topología (capa de entrada, capa oculta y capa de salida) y la misma función de activación (logaritmo sigmoïdal), al incrementar el número de neuronas en la capa oculta no se obtiene una mejora significativa tanto en el error neto como en el coeficiente de correlación cuadrático (alternativas 2 y 3). Por lo anterior se concluye que la topología óptima es la descrita en la alternativa 2. A continuación se presentan los coeficientes de correlación cuadrático obtenidos para cada configuración.

Alternativa	Datos	R^2 Membrain
Primera	Verificación (30%)	0,812
Segunda	Verificación (30%)	0,998
Tercera	Verificación (30%)	0,998

Tabla 4. R^2 Diferentes alternativas

Fuente: Autores

7.3 PREDICCIÓN DE LA TEMPERATURA DE FORMACIÓN DE HIDRATOS

A continuación se presentan las predicciones de la temperatura de formación de hidratos de los modelos empíricos y las predicciones arrojadas con los programas Membrain y Statistica utilizando la topología de la red neuronal obtenida.

<i>Presión, psia</i>	Temperatura °F					
	<i>Experimental</i>	<i>Sloan</i>	<i>Motiee</i>	<i>Hammerschmidt</i>	<i>Redes Neuronales</i>	
					<i>Membrain</i>	<i>Statistica</i>
757	44	44,2	46,4	58,9	44,2	44,3
1236	52	52,5	53,2	67,7	52,3	52,4
1848	59	58,7	58,6	75,9	58,5	58,6

Tabla 5. Temperatura de formación de hidratos para un gas con 0,55 de gravedad específica

Fuente: Autores

<i>Presión, psia</i>	Error, E (%)				
	<i>Sloan</i>	<i>Motiee</i>	<i>Hammerschmidt</i>	<i>Redes Neuronales</i>	
				<i>Membrain</i>	<i>Statistica</i>
757	0,42	4,44	24,63	0,28	0,13
1236	0,38	1,65	22,7	0,12	0,06
1848	0,39	0,24	22,94	0	0,13

Tabla 6. Porcentaje de Error

Fuente: Autores

	<i>Sloan</i>	<i>Motiee</i>	<i>Hammerschmidt</i>	<i>Membrain</i>	<i>Statistica</i>
Er (%)	0,4	2,11	23,43	0,13	0,11
Ea (%)	0,4	2,11	23,43	0,13	0,11
Emin (%)	0,38	0,24	22,7	0	0,06
Emax (%)	0,42	4,44	24,63	0,28	0,13
SD	0,0002	0,021	0,011	0,001	0,0004

Tabla 7. Porcentajes de Error y Desviación estándar

Fuente: Autores

<i>Presión, psia</i>	Temperatura °F					
	<i>Experimental</i>	<i>Sloan</i>	<i>Motiee</i>	<i>Hammerschmidt</i>	<i>Redes Neuronales</i>	
					<i>Membrain</i>	<i>Statistica</i>
275	41	40,7	40	44,13	41,2	41,2
769	56	56,3	54,5	59,14	56,1	56
2200	68	61,9	68,7	79,8	68,5	68,5

Tabla 8. Temperatura de formación de hidratos para un gas con 0,6 de gravedad específica

Fuente: Autores

<i>Presión, psia</i>	Error, E (%)				
	<i>Sloan</i>	<i>Motiee</i>	<i>Hammerschmidt</i>	<i>Redes Neuronales</i>	
				<i>Membrain</i>	<i>Statistica</i>
275	0,95	2,65	0,5	0,35	0,33
769	0,62	2,59	11,5	0,20	0,16
2200	10,5	0,50	26,7	0,24	0,19

Tabla 9. Porcentaje de Error

Fuente: Autores

	<i>Sloan</i>	<i>Motiee</i>	<i>Hammerschmidt</i>	<i>Membrain</i>	<i>Statistica</i>
Er (%)	4,02	1,91	12,91	0,26	0,23
Ea (%)	4,02	1,91	12,91	0,26	0,23
Emin (%)	0,62	0,5	0,5	0,20	0,16
Emax (%)	10,5	2,65	26,7	0,35	0,33
SD	0,056	0,012	0,131	0,0008	0,0009

Tabla 10. Porcentajes de Error y Desviación estándar

Fuente: Autores

<i>Presión, psia</i>	Temperatura °F					
	<i>Experimental</i>	<i>Sloan</i>	<i>Motiee</i>	<i>Hammerschmidt</i>	<i>Redes Neuronales</i>	
					<i>Membrain</i>	<i>Statistica</i>
177	45	44,4	44	38,9	44,6	44,6
350	65	54,9	53,7	47,3	54,7	54,7
957	67	60,8	67,6	62,9	66,9	67

Tabla 11. Temperatura de formación de hidratos para un gas con 0,68 de gravedad específica

Fuente: Autores

<i>Presión, psia</i>	Error, E (%)				
	<i>Sloan</i>	<i>Motiee</i>	<i>Hammerschmidt</i>	<i>Redes Neuronales</i>	
				<i>Membrain</i>	<i>Statistica</i>
177	0,4	1,4	14,6	0,01	0,11
350	0,4	1,8	15,8	0,09	0,11
957	10,3	0,8	6,4	0,09	0,07

Tabla 12. Porcentaje de Error

Fuente: Autores

	<i>Sloan</i>	<i>Motiee</i>	<i>Hammerschmidt</i>	<i>Membrain</i>	<i>Statistica</i>
Er (%)	3,68	1,34	12,30	0,07	0,10
Ea (%)	3,68	1,34	12,30	0,07	0,10
Emin (%)	0,4	0,8	6,4	0,01	0,07
Emax (%)	10,3	1,8	15,8	0,09	0,11
SD	0,057	0,005	0,051	0,0004	0,0002

Tabla 13. Porcentajes de Error y Desviación estándar

Fuente: Autores

<i>Presión, psia</i>	Temperatura °F					
	<i>Experimental</i>	<i>Sloan</i>	<i>Motiee</i>	<i>Hammerschmidt</i>	<i>Redes Neuronales</i>	
					<i>Membrain</i>	<i>Statistica</i>
131	43	43	45,9	35,7	42,5	42,6
256	53	52,9	55,3	43,2	52,7	52,7
639	65	62,1	67,8	56,1	64,8	64,7

Tabla 14. Temperatura de formación de hidratos para un gas con 0,8 de gravedad específica

Fuente: Autores

<i>Presión, psia</i>	Error, E (%)				
	<i>Sloan</i>	<i>Motiee</i>	<i>Hammerschmidt</i>	<i>Redes Neuronales</i>	
				<i>Membrain</i>	<i>Statistica</i>
131	0,75	7,00	19,6	0,48	0,32
256	0,62	5,00	21,69	0,15	0,29
639	0,75	4,29	15,61	0,14	0,22

Tabla 15. Porcentaje de Error

Fuente: Autores

	<i>Sloan</i>	<i>Motiee</i>	<i>Hammerschmidt</i>	<i>Membrain</i>	<i>Statistica</i>
Er (%)	1,95	5,43	18,97	0,26	0,28
Ea (%)	1,95	5,43	18,97	0,26	0,28
Emin (%)	0,62	4,29	15,61	0,14	0,22
Emax (%)	4,49	7,00	21,69	0,48	0,32
SD	0,022	0,0141	0,0309	0,0019	0,0005

Tabla 16. Porcentajes de Error y Desviación estándar

Fuente: Autores

<i>Presión, psia</i>	Temperatura °F					
	<i>Experimental</i>	<i>Sloan</i>	<i>Motiee</i>	<i>Hammerschmidt</i>	<i>Redes Neuronales</i>	
					<i>Membrain</i>	<i>Statistica</i>
160	47	46,6	45,2	37,8	46,7	46,7
279	55	54,5	52,9	44,3	54,7	54,7
522	63	66,8	61,1	53	62,9	62,9

Tabla 17. Temperatura de formación de hidratos para un gas con 0,9 de gravedad específica

Fuente: Autores

<i>Presión, psia</i>	Error, E (%)				
	<i>Sloan</i>	<i>Motiee</i>	<i>Hammerschmidt</i>	<i>Redes Neuronales</i>	
				<i>Membrain</i>	<i>Statistica</i>
160	0,40	3,36	23,8	0,11	0,10
279	0,29	3,31	23,2	0,19	0,23
522	5,58	3,14	19,1	0,23	0,33

Tabla 18. Porcentaje de Error

Fuente: Autores

	<i>Sloan</i>	<i>Motiee</i>	<i>Hammerschmidt</i>	<i>Membrain</i>	<i>Statistica</i>
Er (%)	2,09	3,27	22,02	0,18	0,22
Ea (%)	2,09	3,27	22,02	0,18	0,22
Emin (%)	0,29	3,14	19,1	0,11	0,10
Emax (%)	5,58	3,36	23,8	0,23	0,33
SD	0,0303	0,0012	0,0258	0,0006	0,0011

Tabla 19. Porcentajes de Error y Desviación estándar

Fuente: Autores

7.4 EVALUACIÓN DEL MODELO DE SLOAN (KOBAYASHI ET AL 1987)

El modelo de Sloan arrojó resultados exactos en la mayoría de los sistemas como se puede observar en las tablas anteriores. Se obtuvo un error mínimo relativo absoluto del 0,29 %. Pero es importante mencionar que los errores en la temperatura de formación de hidratos se incrementaron cuando en el sistema la temperatura era mayor a 60 °F y cuando la presión era mayor a 2000 psia, como se observa en las tablas 7 y 10. Este comportamiento era de esperarse ya que estos puntos se encuentran por fuera del rango recomendado para la aplicación del modelo.

Finalmente es importante recalcar que el modelo de Sloan requiere el ajuste de 15 constantes para su aplicación, las cuales se obtuvieron a partir de datos experimentales de las distintas mezclas (temperatura, presión y gravedad específica), por lo que los sistemas estudiados tenían más de 15 puntos experimentales para garantizar que al realizar la regresión, se obtuviera una solución única estadísticamente válida. Debido a lo anterior, se sugiere utilizar este modelo con fines evaluativos de las condiciones de formación de hidratos y no predictivos.

7.5 EVALUACIÓN DEL MODELO DE MOTIEE (1991)

El modelo de Motiee, al igual que el modelo de Sloan, arrojó resultados con buena exactitud en todos los sistemas propuestos. Se obtuvo un error mínimo relativo absoluto del 0,24 %. Es importante mencionar que a pesar que solo un sistema se encuentra en el rango de presión recomendado para el modelo (tabla 7), se evidencio que aquellos sistemas que presentaban presiones más altas (tablas 4 y 7), fueron los que arrojaron los menores errores porcentuales (0,24 % y 0,5 %).

Igualmente se observó que los mayores errores en la temperatura de formación de hidratos calculada con el modelo de Motiee, la presentaron aquellos sistemas que tienen temperaturas menores a 44 °F. Este comportamiento es acertado ya que estos puntos se encuentran por fuera del rango recomendado de temperatura ($T > 60$ °F) para la aplicación del modelo. Se obtuvo un error máximo del 7 %.

7.6 EVALUACIÓN DEL MODELO DE HAMMERSCHMIDT (1934)

Cuando se desarrolló el modelo de Hammerschmidt (1934) solo se tomaron en cuenta la presión y la temperatura como variables de formación de los hidratos de gas natural. Junto con el modelo de Berge son los únicos que no requieren ajustes a partir de datos experimentales, por lo que se puede decir que el modelo de Hammerschmidt es el modelo más confiable para predecir las condiciones de formación de hidratos del gas natural, a pesar que fue la primera aproximación empírica desarrollada. Se obtuvo un error mínimo del 0,5 % y un error máximo del 26,7 %.

7.7 EVALUACIÓN MEMBRAN Y STATISTICA (REDES NEURONALES)

Los datos generados de temperatura de formación de hidratos del gas natural para las combinaciones aleatorias de presión y gravedad específica presentaron alta exactitud (Tablas 4 - 18). Específicamente con Membrain se obtuvo un error máximo del 0,48 % y con Statistica se obtuvo un error máximo del 0,33 %.

Visto lo anterior se puede asegurar que las Redes Neuronales al ser una aplicación matemática que actúa como un interpolador perfecto, permitieron predecir la temperatura de formación de hidratos de manera acertada y precisa.

Adicionalmente es de suma importancia agregar que no se tienen *restricciones* de temperatura, presión o gravedad específica utilizando las redes neuronales cuando se predice la temperatura de formación de hidratos del gas natural, por lo cual se puede decir que es el método más efectivo y funcional a la hora de predecir condiciones de formación de hidratos.

7.8 COEFICIENTES DE CORRELACIÓN CUADRÁTICO (R²) OBTENIDOS CON LOS MODELOS EMPÍRICOS.

Se analizó el coeficiente de correlación cuadrático (R²) para cada una de las correlaciones empíricas utilizadas en la predicción de la temperatura de formación de hidratos. El coeficiente R² varía desde $0 \leq R^2 \leq 1$. Valores cercanos a 1 indican una buena correlación entre los datos examinados. A continuación se presentan graficados los datos de temperatura predichos contra los datos experimentales para cada modelo empírico y los respectivos R²:

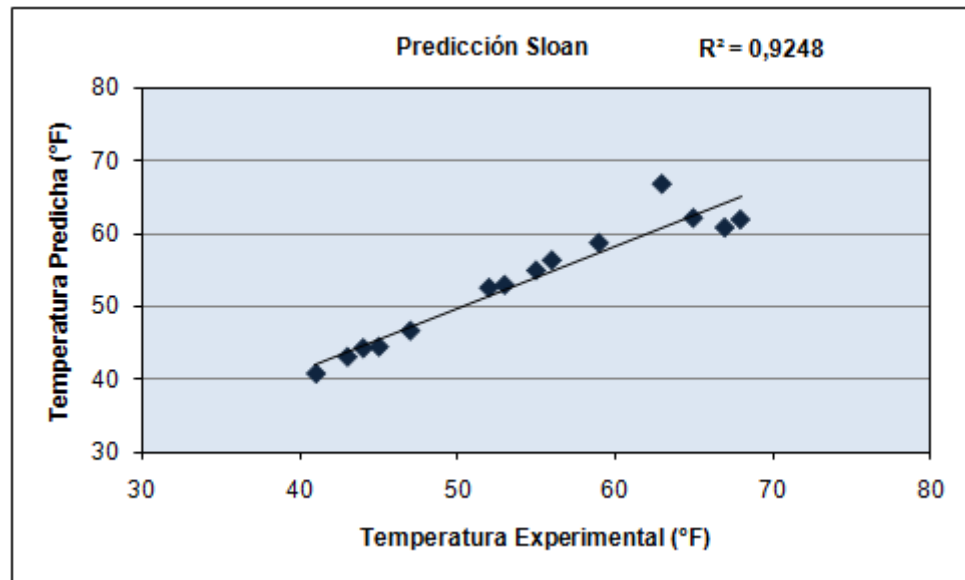


Figura 50. Temperatura de formación de hidratos predicha por modelo Sloan

Fuente: Autores




Figura 51. Temperatura de formación de hidratos predicha por modelo Motiee

Fuente: Autores




Figura 52. Temperatura de formación de hidratos predicha por modelo Hammerschmidt

Fuente: Autores

Como se puede observar de las figuras anteriores, el modelo empírico que presenta una mejor correlación entre los datos es el de Motiee, obteniendo un coeficiente de correlación cuadrático $R^2 = 0,9643$. Por otro lado el modelo de

Hammerschmidt tiene el menor coeficiente cuadrático ($R^2 = 0,4359$). Esto concuerda con los porcentajes de error calculados, ya que de las 3 correlaciones empíricas utilizadas en el desarrollo del trabajo es el modelo que presenta mayores porcentajes de error.

7.9 COEFICIENTES DE CORRELACIÓN CUADRÁTICO (R^2) OBTENIDOS CON MEMBRAIN Y CON STATISTICA.

Se calculó el coeficiente de correlación cuadrático (R^2) para Membrain y para Statistica, programas especializados utilizados en la predicción de la temperatura de formación de hidratos. A continuación se presentan graficados los datos de temperatura predichos contra los datos experimentales para cada software y los respectivos R^2 :




Figura 53. Temperatura de formación de hidratos predicha por Membrain

Fuente: Autores




Figura 54. Temperatura de formación de hidratos predicha por Statistica
Fuente: Autores

Como se puede observar de las gráficas anteriores, los coeficientes de correlación cuadrático calculados utilizando Membrain y Statistica son similares y muy cercanos a 1, con lo cual se puede asegurar que la temperatura de formación de hidratos generada por medio de las redes neuronales presentan una desviación mínima. A continuación se presenta una tabla con los coeficientes de correlación cuadrático obtenidos con los modelos empíricos y con los paquetes computacionales:

Coeficiente de correlación cuadrático, R^2				
<i>Sloan</i>	<i>Motiee</i>	<i>Hammerschmidt</i>	<i>Membrain</i>	<i>Statistica</i>
0,9248	0,9643	0,4359	0,9989	0,9988

Tabla 20. R^2 Modelos Empíricos, Membrain y Statistica
Fuente: Autores

Analizando los coeficientes de correlación cuadrático presentados en la tabla anterior, se concluye que las redes neuronales presentaron los valores más altos (muy cercanos a 1), lo cual indica una alta exactitud en la predicción de la temperatura de formación de hidratos del gas natural y por consiguiente son la vía más acertada en comparación con los modelos empíricos, para calcular las condiciones de formación de hidratos del gas natural, cumpliendo con el objetivo planteado en el desarrollo de este trabajo.

8. CONCLUSIONES

- Las redes neuronales artificiales pueden usarse en la ingeniería de petróleos como una herramienta alterna para solucionar problemas que no pueden ser resueltos con los métodos de modelamiento matemático convencional. En este caso son una vía útil para predecir las condiciones de formación de hidratos.
- Las redes neuronales son una aplicación matemática que actúa como un interpolador perfecto, que permite la identificación de patrones establecidos a partir de datos existentes, en este caso datos de Presión, Temperatura y Gravedad Específica.
- La metodología desarrollada para predecir la temperatura de formación de hidratos, es viable y funcional, ya que ayuda a la caracterización de la información que se requiere en los cálculos de la ingeniería del gas y ayuda a mitigar los problemas operativos que generan tales como: bloqueo de tuberías, bloqueo de equipos e instrumentos, falsas lectura de presión y errores de medición.
- Las redes neuronales artificiales fueron el método más exacto en la predicción de la temperatura de formación de hidratos del gas natural en un rango de presión de 63 - 4038 psia, un rango de temperatura de 33 - 70 °F y un rango de gravedad específica de 0,555 - 0,9.
- En cuanto al desempeño de los modelos empíricos, Motiee (1991) resulto ser el modelo que arrojó los menores errores porcentuales para todas las combinaciones de datos.

- Al evaluar los modelos empíricos predictivos, Hammerschmidt (1934) arrojó las mayores desviaciones en la temperatura de formación de hidratos para la mayoría de las combinaciones de datos.
- Los modelos empíricos de Motiee (1991) y Sloan (Kobayashi *et al* 1987) requieren el ajuste de varias constantes para su aplicación, las cuales se obtuvieron a partir de datos experimentales de las distintas mezclas. Debido a lo anterior, estos modelos deben ser utilizados con fines evaluativos de las condiciones de formación de hidratos y no predictivos.
- El modelo de Hammerschmidt (1934) solo tiene en cuenta la presión y la temperatura como variables de formación de los hidratos de gas natural, no requiere ajustes a partir de datos experimentales, por lo que se puede decir que es el modelo más confiable para predecir las condiciones de formación de hidratos del gas natural.
- Se obtuvo una mayor desviación en la predicción de la temperatura de formación de hidratos, cuando se aplicaron los modelos empíricos con datos que estaban por fuera de los rangos recomendados para su uso.

BIBLIOGRAFIA

ABDEL FATTAH, Khaled Ahmed. Evaluation of empirical correlations for natural gas hydrates predictions. Kingdom of Saudi Arabia: King Saud University. 2004.

AMIR H., KEIVAN S., LADAN K. Prediction of hydrate formation temperature for natural gas using artificial neural network. Iran: Mohaghegh-e-Ardebily University. 2006.

Canadian Association of Petroleum Producers (CAAP). Prevention and Safe Handling of Hydrates. Calgary, Alberta. 1994.

GPSA Engineering Data Book, 12th ed., Gas Processors Suppliers Association, Tulsa, Ok., 2004.

Katz, D.I. Handbook of Natural Gas Engineering, McGraw-Hill, New York, 1959.

KATZ, Donald. Prediction of conditions for hydrate formation in natural gas. New York. SPE945140.

Universidad Tecnológica de Pereira, Tutorial de redes neuronales, Facultad de Ingeniería Eléctrica.

VIRNA N., MARIA M., ALEXIS B., YAMILET S., JENNY M. Evaluación de modelos empíricos para la predicción de hidratos de gas natural. Caracas, Venezuela: Universidad Simón Bolívar. 2009.

ANEXOS

Anexo A. Red Neuronal en Statistica

Una vez establecida la topología de red óptima en Membrain, la misma se ingresa en Statistica para comparar los resultados obtenidos con los dos software. Para ello primero se ingresan los datos. En la capa de entrada se ingresan las variables independientes (presión y gravedad específica) y en la capa de salida las variables dependientes (temperatura de formación de hidratos).

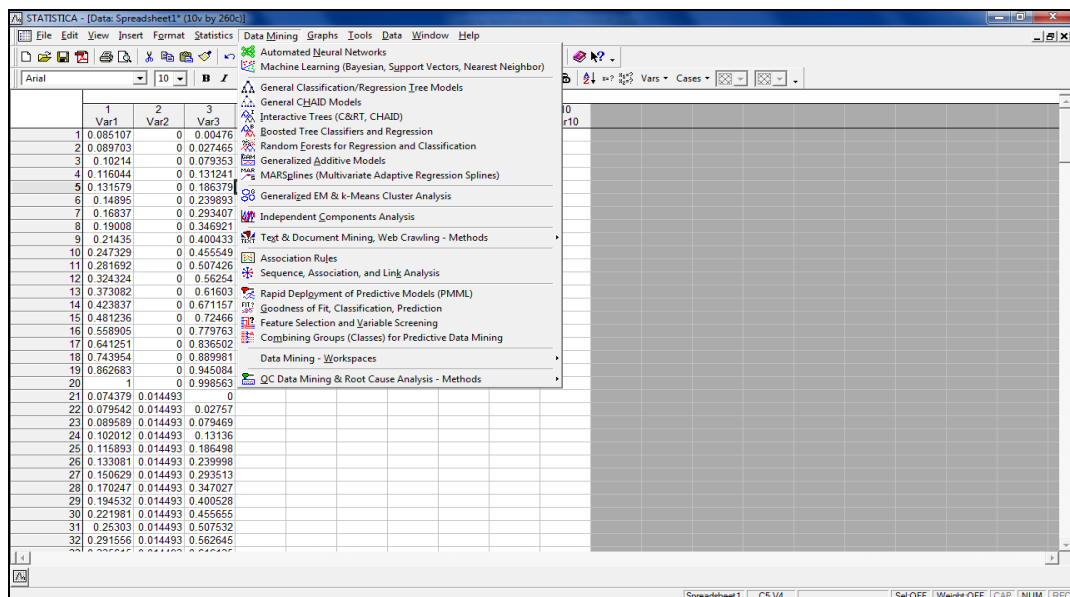


Figura 55. Red Neuronal

Fuente: Statistica

Este software tiene un valor agregado puesto que una vez ingresada la topología de la red ofrece la posibilidad de establecer un porcentaje de los datos ingresados como datos de prueba y se encarga de realizar el proceso de verificación internamente y de converger al error mínimo global evitando converger a valores mínimos locales.

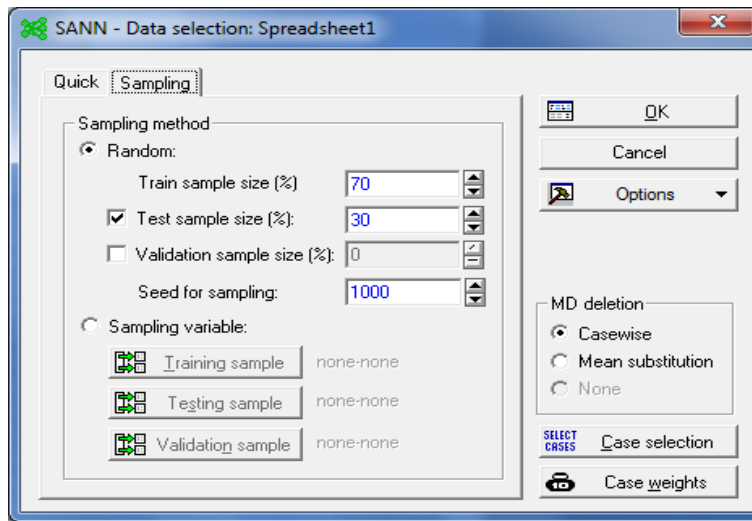


Figura 56. Selección de Datos

Fuente: Statistica

Posteriormente se ingresa el número de neuronas de la capa oculta, se define la función de activación y el algoritmo de entrenamiento y se procede a realizar el entrenamiento de la red neuronal.

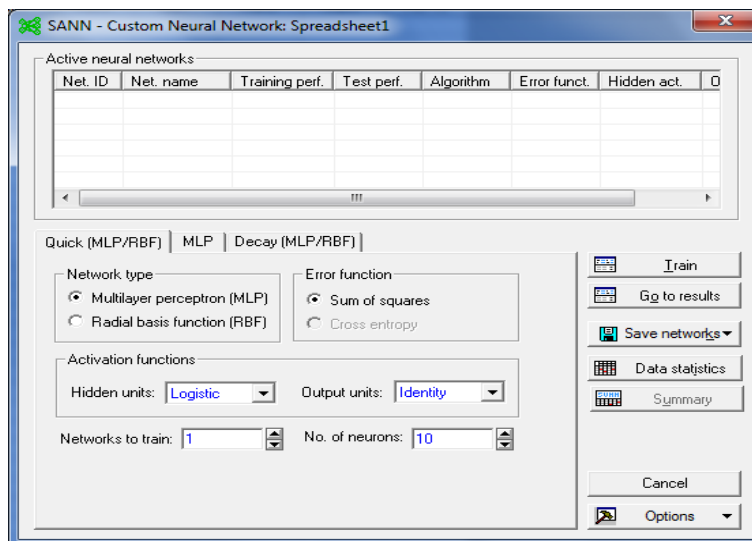


Figura 57. Selección de información

Fuente: Statistica

Una vez converge al error mínimo global se habilita la siguiente ventana donde se procede a ingresar los valores de verificación. Para esto se hace click sobre el botón predictions y la red neuronal ahora está lista para realizar las predicciones necesarias.

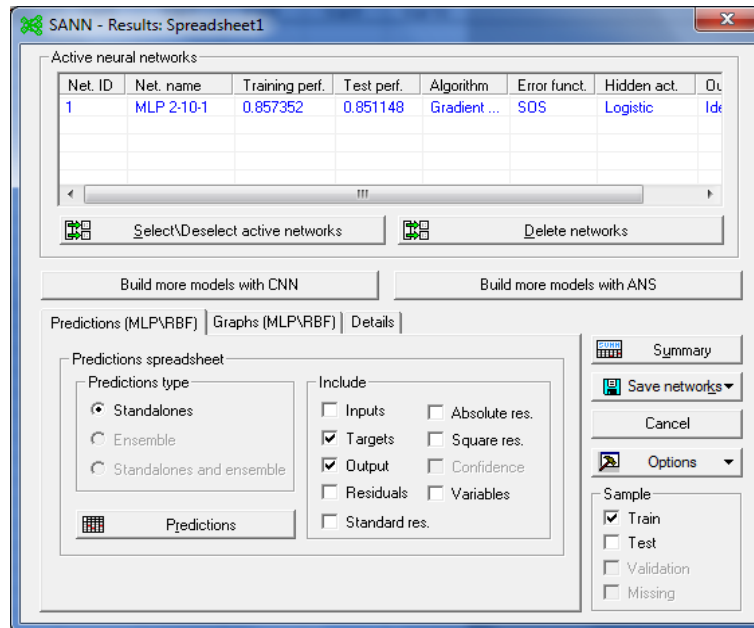


Figura 58. Predicciones en Statistica

Fuente: Statistica

Anexo B. Calculo R^2 Modelos Empíricos y Redes Neuronales en Excel.

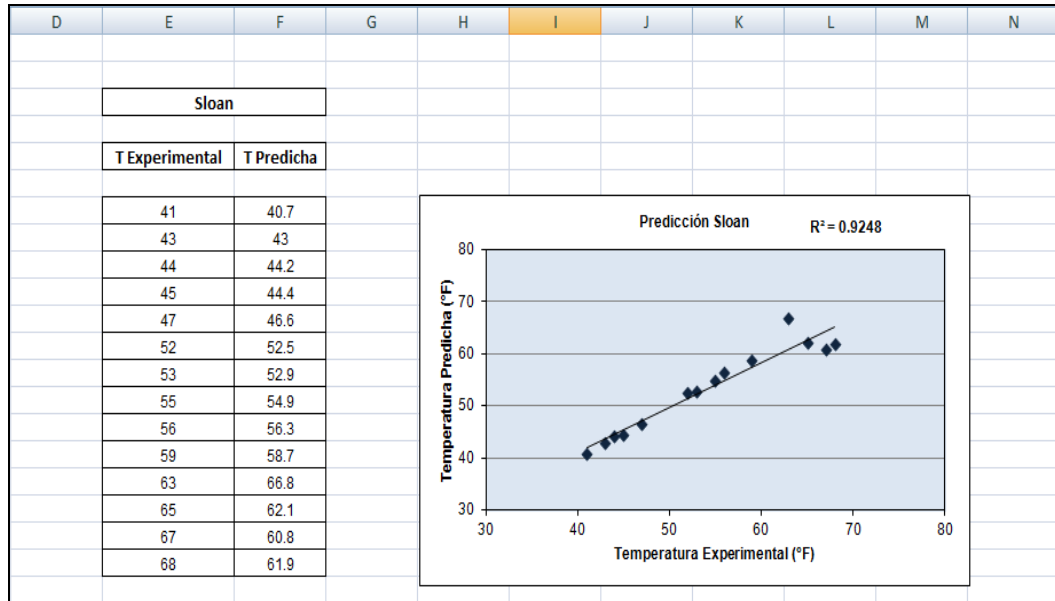


Figura 59. R^2 Modelo Sloan

Fuente: Autores




Figura 60. R^2 Modelo Sloan

Fuente: Autores




Figura 61. R^2 Modelo Hammerschmidt

Fuente: Autores

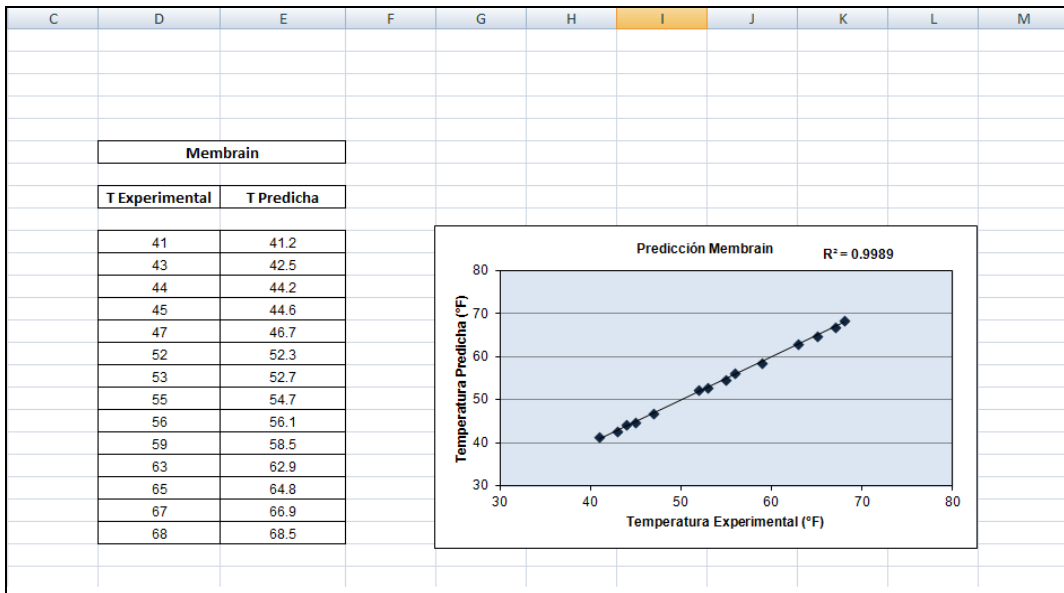


Figura 62. R^2 Membrain

Fuente: Autores

