

**DETERMINACIÓN DEL PATRÓN DE FLUJO MULTIFÁSICO EN TUBERÍAS DE
RECOLECCIÓN DE PETRÓLEO EMULSIONADO, A PARTIR DE LOS DATOS
HISTÓRICOS DE PRODUCCIÓN APOYADO EN UNA APLICACIÓN CON REDES
NEURONALES ARTIFICIALES**

**JORGE EDUARDO FLÓREZ SÁNCHEZ
FREDDY ALBERTO PORRAS MEJÍA**

**UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FÍSICO MECÁNICAS
ESCUELA DE INGENIERÍA DE SISTEMAS E INFORMÁTICA
BUCARAMANGA
2007**

**DETERMINACIÓN DEL PATRÓN DE FLUJO MULTIFÁSICO EN TUBERÍAS DE
RECOLECCIÓN DE PETRÓLEO EMULSIONADO, A PARTIR DE LOS DATOS
HISTÓRICOS DE PRODUCCIÓN APOYADO EN UNA APLICACIÓN CON REDES
NEURONALES ARTIFICIALES**

**JORGE EDUARDO FLÓREZ SÁNCHEZ
FREDDY ALBERTO PORRAS MEJÍA**

Trabajo de grado presentado para optar el título de
Ingeniero de Sistemas.

Director:
ING. JUAN CARLOS REYES FIGUEROA
Profesor Escuela de Ingeniería de Sistemas, UIS

Codirector:
M.E. FERNANDO RUIZ DÍAZ
Profesor Escuela de Ingeniería de Sistemas, UIS

**UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FÍSICO MECÁNICAS
ESCUELA DE INGENIERÍA DE SISTEMAS E INFORMÁTICA
BUCARAMANGA
2007**

*A Dios, a Viviana y Jorge, mis padres
A mi prima Carol Daniela
A mi tía Adriana.*

JORGE EDUARDO

*A Dios, a mis padres, Carmen y Tito,
a mis hermanas Carmen y Ayde,
a mi sobrino Santiago.*

FREDDY ALBERTO

AGRADECIMIENTOS

Los autores expresan sus agradecimientos a:

ING. JUAN CARLOS REYES FIGUEROA. UIS. Director del proyecto. Por su valioso apoyo, orientación y por su dedicación a este proyecto.

M.E. FERNANDO RUIZ DÍAZ. UIS. Codirector. Por la confianza depositada en nosotros.

ING. JAIRO ARRIETA URZOLA. UIS. Ingeniero de petróleos. Por su continuo apoyo, por la idea de este trabajo de grado, por su entusiasmo y paciencia.

A NUESTRAS FAMILIAS, por su paciencia y apoyo incondicional.

TABLA DE CONTENIDO

	PÁG.
INTRODUCCIÓN	21
OBJETIVOS	22
<i>OBJETIVO GENERAL</i>	<i>22</i>
<i>OBJETIVOS ESPECÍFICOS</i>	<i>22</i>
DEFINICIÓN DEL PROBLEMA	23
JUSTIFICACIÓN	24
1. REDES NEURONALES ARTIFICIALES	25
1.1. <i>GENERALIDADES</i>	<i>25</i>
1.2. <i>TIPOS DE RED</i>	<i>28</i>
1.2.1. <i>Perceptrón Multicapa Con Algoritmo Backpropagation (PMC)</i>	<i>29</i>
1.2.2. <i>Redes De Función De Base Radial</i>	<i>31</i>
1.3. <i>APLICACIONES</i>	<i>34</i>
1.3.1. <i>Aplicaciones En La Industria Del Petróleo</i>	<i>35</i>
2. FLUJO MULTIFÁSICO	39
2.1. <i>FLUJO MULTIFÁSICO</i>	<i>39</i>
2.2. <i>PATRONES DE FLUJO MULTIFÁSICO</i>	<i>39</i>
2.2.1. <i>Patrones De Flujo Multifásico En Tubería Horizontal</i>	<i>39</i>
2.3. <i>MAPAS DE REGÍMENES DE FLUJO PARA TUBERÍAS HORIZONTALES</i>	<i>42</i>
2.3.1. <i>Correlación De Baker</i>	<i>42</i>
2.3.2. <i>Correlación De Govier & Omer:</i>	<i>43</i>
2.3.3. <i>Correlación De Mandhane</i>	<i>44</i>
2.3.4. <i>Correlación De Taitel & Dukler</i>	<i>45</i>

2.3.5.	<i>Correlación De Beggs & Brill</i>	45
2.4.	HOLDUP O COLGAMIENTO	46
2.4.1.	<i>Velocidades Superficiales</i>	46
2.4.2.	<i>Velocidad De La Mezcla</i>	47
2.4.3.	<i>Holdup Del Líquido Sin Deslizamiento.</i>	47
2.4.4.	<i>Holdup Del Líquido</i>	47
2.4.5.	<i>Velocidades Reales</i>	48
2.4.6.	<i>Velocidad De Deslizamiento</i>	48
2.4.7.	<i>Correlación De Beggs & Brill</i>	48
2.4.8.	<i>Correlación De Lockhart & Martinelli Y Sus Modificaciones</i>	49
2.4.9.	<i>Correlación De Hughark & Pressburg</i>	50
2.5.	GRADIENTES DE PRESIÓN	51
2.5.1.	<i>Correlación De Lockhart & Martinelli</i>	51
2.5.2.	<i>Correlación De Dukler, Wicks & Cleveland</i>	53
2.5.3.	<i>Método De Beggs & Brill</i>	54
3.	NEURAL ANALYZER (NEURALYZER V1.0)	58
3.1.	<i>ORIGEN DE LA IDEA</i>	58
3.2.	<i>ANÁLISIS</i>	59
3.3.	<i>DISEÑO</i>	59
3.4.	<i>DESARROLLO</i>	60
3.4.1.	<i>Diagrama De Casos De Uso</i>	60
4.	METODOLOGÍA	66
4.1.	<i>PLANTEAMIENTO DE LA METODOLOGÍA</i>	66
4.1.1.	<i>Adquisición De Los Datos, Proceso De Normalización</i>	68
4.1.2.	<i>Definir El Número Y El Rango De Entradas/Salidas</i>	69
4.1.3.	<i>Prueba De Las Diferentes Arquitecturas</i>	70

4.1.4.	<i>Prueba Para Cada Arquitectura Con Las Redes Sugeridas</i>	71
4.1.5.	<i>Realizar Una Afinación En Base A Los Resultados</i>	72
4.2.	APLICACIÓN DE LA METODOLOGÍA	72
4.2.1.	<i>Adquisición De Datos</i>	72
4.2.2.	<i>Definición De Entradas/Salidas</i>	74
4.2.3.	<i>Prueba De Las Diferentes Arquitecturas/Afinación De Redes</i>	74
5.	COMPARACIÓN Y GRÁFICOS	77
5.1.	<i>POZO 1</i>	78
5.2.	<i>POZO2</i>	80
5.3.	<i>POZO3</i>	82
5.4.	<i>POZO4</i>	84
5.5.	<i>POZO5</i>	86
5.6.	<i>POZO6</i>	88
5.7.	<i>POZO7</i>	90
5.8.	<i>POZO8</i>	92
5.9.	<i>POZO9</i>	94
5.10.	<i>POZO10</i>	96
6.	CONCLUSIONES	99
7.	RECOMENDACIONES	100
8.	ANEXO 1: MANUAL DE USUARIO	101
8.1.	<i>INTRODUCCIÓN</i>	101
8.1.1.	<i>¿Qué Puede Hacer?</i>	101
8.1.2.	<i>Recomendaciones</i>	102
8.2.	<i>DESDE CERO</i>	102
8.2.1.	<i>¿Cómo Crear?</i>	103
8.2.2.	<i>¿Cómo Salvar?</i>	104

8.2.3.	<i>¿Cómo Cargar?</i>	105
8.2.4.	<i>Entrenamiento</i>	106
8.2.5.	<i>Simulación</i>	107
8.3.	AVANZADAS	108
8.3.1.	<i>Normalización</i>	108
8.3.2.	<i>Edición</i>	110
8.3.3.	<i>Entradas/Salidas</i>	112
8.3.4.	<i>Convertir Caudales</i>	114
8.3.5.	<i>Datos De La Facilidad</i>	114
8.3.6.	<i>Exportar Datos A Excel</i>	115
8.3.7.	<i>Reportes</i>	116
8.3.8.	<i>Gráficas En 2D</i>	117
8.3.9.	<i>Separador Decimal</i>	118
	BIBLIOGRAFÍA	132
	ANEXO 1. ANÁLISIS DE LOS ALGORITMOS IMPLEMENTADOS EN NEURALYZER	
		120

LISTA DE FIGURAS

	PÁG.
Figura 1. Modelo de neurona artificial	26
Figura 2. Clasificación de las redes neuronales	28
Figura 3. Taxonomía de las redes neuronales	29
Figura 4. Función de activación radial	32
Figura 5. Patrones de flujo segregado	40
Figura 6. Patrones de flujo intermitente	41
Figura 7. Patrones de flujo distribuido	41
Figura 8. Mapa de regímenes de flujo, Baker (1953) [4]	42
Figura 9. Mapa de patrones de flujo de Govier & Omer [5]	43
Figura 10. Mapa de regímenes de flujo Mandhane (1974) [5]	44
Figura 11. Mapa de regímenes de flujo Taitel-Dukler (1976) [4]	45
Figura 12. Mapa del patrón de flujo Beggs & Brill[4]	46
Figura 13. Correlacion de Lockhart & Martinelli y las observaciones de Baker [4]	50
Figura 14. Correlación de holdup para mezclas Gas-Líquido [4]	51

Figura 15. Relaciones de Lockhart-Martinelli [5]	52
Figura 16. Función de Dukler, Wicks & Cleveland [5]	54
Figura 17. Evolución del número de referencias (miles) a las redes neuronales en la literatura	58
Figura 18. Diagrama de casos de uso	65
Figura 19. Diagrama de flujo para la consecución de una arquitectura de red adecuada.	67
Figura 20. Error en el entrenamiento y error durante la validación	69
Figura 21. Proceso de los datos para la entrada/salida en una red neuronal.	70
Figura 22. Arquitectura final PMC para determinar el patrón de flujo	75
Figura 23. Arquitectura final Base Radial para determinar el patrón de flujo	76
Figura 24. Diagrama del modelo realizado en HYSYS	77
Figura 25. Porcentajes de presencia de los patrones en Pozo1	78
Figura 26. Historial de producción de Pozo1, y su relación con el patrón de flujo	78
Figura 27. Grafico de Velocidades de Pozo1, y su relación con el patrón de flujo	79
Figura 28. Reporte HYSYS de Simulación de Pozo1	79
Figura 29. Porcentajes de presencia de los patrones en Pozo2	80
Figura 30. Historial de producción de Pozo2, y su relación con el patrón de flujo	80

Figura 31. Grafico de Velocidades de Pozo2, y su relación con el patrón de flujo	81
Figura 32. Reporte HYSYS de Simulación de Pozo2	81
Figura 33. Porcentajes de presencia de los patrones en Pozo3	82
Figura 34. Historial de producción de Pozo3, y su relación con el patrón de flujo	82
Figura 35. Grafico de Velocidades de Pozo3, y su relación con el patrón de flujo	83
Figura 36. Reporte HYSYS de Simulación de Pozo3	83
Figura 37. Porcentajes de presencia de los patrones en Pozo4	84
Figura 38. Historial de producción de Pozo4, y su relación con el patrón de flujo	84
Figura 39. Grafico de Velocidades de Pozo4, y su relación con el patrón de flujo	85
Figura 40. Reporte HYSYS de Simulación de Pozo4	85
Figura 41. Porcentajes de presencia de los patrones en Pozo5	86
Figura 42. Historial de producción de Pozo5, y su relación con el patrón de flujo	86
Figura 43. Grafico de Velocidades de Pozo5, y su relación con el patrón de flujo	87
Figura 44. Reporte HYSYS de Simulación de Pozo5	87
Figura 45. Porcentajes de presencia de los patrones en Pozo6	88
Figura 46. Historial de producción de Pozo6, y su relación con el patrón de flujo	88
Figura 47. Grafico de Velocidades de Pozo6, y su relación con el patrón de flujo	89

Figura 48. Reporte HYSYS de Simulación de Pozo6	89
Figura 49. Porcentajes de presencia de los patrones en Pozo7	90
Figura 50. Historial de producción de Pozo7, y su relación con el patrón de flujo	90
Figura 51. Grafico de Velocidades de Pozo7, y su relación con el patrón de flujo	91
Figura 52. Reporte HYSYS de Simulación de Pozo7	91
Figura 53. Porcentajes de presencia de los patrones en Pozo8	92
Figura 54. Historial de producción de Pozo8, y su relación con el patrón de flujo	92
Figura 55. Grafico de Velocidades de Pozo8, y su relación con el patrón de flujo	93
Figura 56. Reporte HYSYS de Simulación de Pozo8	93
Figura 57. Porcentajes de presencia de los patrones en Pozo9	94
Figura 58. Historial de producción de Pozo9, y su relación con el patrón de flujo	94
Figura 59. Grafico de Velocidades de Pozo9, y su relación con el patrón de flujo	95
Figura 60. Reporte HYSYS de Simulación de Pozo9	95
Figura 61. Porcentajes de presencia de los patrones en Pozo10	96
Figura 62. Historial de producción de Pozo10, y su relación con el patrón de flujo	96
Figura 63. Grafico de Velocidades de Pozo10, y su relación con el patrón de flujo	97
Figura 64. Reporte HYSYS de Simulación de Pozo10	97

Figura 65. Opciones para la creación de redes	103
Figura 66. Detalles de la red	104
Figura 67. Caja de diálogo para autogeneración de redes	104
Figura 68. Salvando una red	105
Figura 69. Opción de reserva para realizar test.	106
Figura 70. Parámetros de entrenamiento	107
Figura 71. Botón detener entrenamiento	107
Figura 72. Empezar la simulación de los datos	108
Figura 73. Opción para la normalización de datos	109
Figura 74. Normalización producto	109
Figura 75. Normalización Max-Min	110
Figura 76. Opciones para edición de redes	110
Figura 77. Caja de diálogo para los detalles de la red	111
Figura 78. Cambio de nombre de la red	111
Figura 79. Clonación de una red	112
Figura 80. Botón para activar la caja de diálogo de entradas/salidas	113
Figura 81. Caja de diálogo de entradas salidas	113

Figura 82. Edición del caption de las entradas y/o salidas	114
Figura 83. Opción de convertir caudales	114
Figura 84. Formulario de obtención de datos de tubería	115
Figura 85. Botón para exportar a Excel los datos de simulación	115
Figura 86. Opción para la generación de reportes	116
Figura 87. Caja de diálogo para la elaboración del reporte	116
Figura 88. Opción para ver las graficas generadas	117
Figura 89. Gráficas generadas de acuerdo a los datos suministrados	118
Figura 90. Menú operador decimal	119

LISTA DE TABLAS

	PÁG.
Tabla 1. Funciones de activación más comunes	27
Tabla 2. λ_L y λ_G para el holdup del líquido sin deslizamiento.	47
Tabla 3. Correlaciones para el cálculo del holdup, según Beggs & Brill	49
Tabla 4. Correlaciones para cada patrón de flujo según Baker	52
Tabla 5. Límites para los patrones de flujo según Beggs & Brill	55
Tabla 6. Comparación del PMC con la de función de base radial	71
Tabla 7. Variables pertenecientes al conjunto de datos	73
Tabla 8. Variables del patrón de flujo[20]	73
Tabla 9. Representación de las salidas de la red neuronal	74
Tabla 10. Propiedades de los pozos, según los parametros requeridos en la Tabla 7 77	
Tabla 11. Comparación de resultados de Hysys Vs PMC	98

TITULO: DETERMINACIÓN DEL PATRÓN DE FLUJO MULTIFÁSICO EN TUBERÍAS DE RECOLECCIÓN DE PETRÓLEO EMULSIONADO, A PARTIR DE LOS DATOS HISTÓRICOS DE PRODUCCIÓN APOYADO EN UNA APLICACIÓN CON REDES NEURONALES ARTIFICIALES^{*}

AUTOR(ES): FLÓREZ SÁNCHEZ Jorge Eduardo^{**}
PORRAS MEJÍA Freddy Alberto^{**}

PALABRAS CLAVES: REDES NEURONALES ARTIFICIALES, FLUJO MULTIFÁSICO, PATRONES DE FLUJO.

DESCRIPCIÓN

La efectividad de los procesos de búsqueda, perforación, extracción, transporte y tratamiento tanto del crudo como del gas, ha sido importante dentro de la industria petrolera, es por ello que distintas ramas del conocimiento colaboran en la optimización de dichos procesos. Las redes neuronales artificiales (RNA) han demostrado su competencia en este tipo de procesos, con la generación de modelos que permiten mayor exactitud en los resultados, actualmente producidos por complejos modelos matemáticos que en su mayoría no alcanzan la suficiente exactitud, dada la fuerte naturaleza no lineal de los problemas abordados, como lo es en el caso de; la determinación del patrón de flujo, el holdup o colgamiento y el posterior cálculo de la caída de presión. Todos estos relacionados estrechamente con el flujo multifásico que ocurre en las tuberías de transporte de gas y crudo. Estos cálculos son necesarios para la construcción/remodelación adecuada de las facilidades de superficie, porque en mayor parte se debe al mal diseño los problemas de depositación, rotura de líneas, represamiento, y sobrepresionamiento entre cabezales entre otros.

El desarrollo de una aplicación basada en RNA ayudará a establecer con mayor eficacia estos parámetros. Aunque la idea de utilizar las RNA para la determinación de estos datos no es nueva, si es naciente en el ámbito local, dados los altos costos de las herramientas existentes en el mercado y/o la complejidad del manejo de éstas.

^{*} Proyecto de grado

^{**} Facultad de Ciencias Físico-Mecánicas, Ingeniería de Sistemas e Informática, Ing. Juan Carlos Reyes Figueroa

TITLE: DETERMINATION OF MULTIPHASE FLOW PATTERN IN EMULSIONED OIL COLLECTION PIPES, STARTING FROM HISTORICAL PRODUCTION DATA SUPPORTED BY AN ARTIFICIAL NEURAL NETWORKS APPLICATION^{*}

AUTHOR(S): FLÓREZ SÁNCHEZ Jorge Eduardo^{**}
PORRAS MEJÍA Freddy Alberto^{**}

KEY WORDS: ARTIFICIAL NEURAL NETWORKS, MULTIPHASE FLOW, FLOW PATTERNS.

DESCRIPTION

Effectiveness in processes such as searching, drilling, extraction, transportation, treatment, for oil and gas, have been important in oil industry. That's why several knowledge fields are collaborating in the optimization of these processes. Artificial Neural Networks (ANN) have proved competence in this kind of processes, with the generation of models that allow at greater accuracy in results, unlike complex mathematical models that, most of cases, don't reach enough accuracy, considering the strong non-linear nature of problems like flow pattern and holdup determination and further pressure drop calculation. These calculations are necessary for adequate construction/remodeling of surface facilities since wrong design generally produce deposit problems, line breaking, halting and overpressure between bolsters among others.

The development of an ANN based application will help to establish with better accuracy these parameters. Although the idea of applying ANN in determination of these data is not new, it is budding in local ambit, because of the expensive and difficult to handle nature of available tools

^{*} Work of degree

^{**} Faculty of Physical-Mechanics Engineering's, Systems and Informatic Engineering, Ing. Juan Carlos Reyes Figueroa

INTRODUCCIÓN

El hecho de tener energía económica se ha convertido, desde hace varios años, en el aspecto fundamental para la evolución tecnológica. A lo largo de la historia, se han encontrado fuentes naturales como el viento, el sol, el calor interno de la tierra, la energía potencial del agua, basadas en reacciones químicas, el gas, entre otras. El petróleo surge como el de mayor relevancia debido a sus aplicaciones y facilidad de uso. Éste ha sido esencial en el desarrollo, desde el año 1859, fecha en la que se descubrió como fuente de energía¹.

El flujo multifásico en la industria de petróleo comenzó a estudiarse en la década del año 1950. Los primeros investigadores usaron datos que se obtenían en laboratorios de prueba. Estos datos (tasas de flujo del gas y del líquido, las propiedades físicas de cada fase, el diámetro del tubo, la inclinación y las presiones de entrada y salida del mismo, así como el holdup del líquido y el patrón de flujo) permitieron que se generaran herramientas como las correlaciones para el holdup del líquido, mapas empíricos de patrones de flujo y las ecuaciones de gradiente de presión (basadas en los principios de conservación de momento y masa aplicados a las mezclas homogéneas).

El uso de software y hardware para adquirir datos de calidad junto con su análisis, esclarecieron los complejos mecanismos dinámicos que existen durante el flujo multifásico. Al tiempo que se desarrollaron métodos teóricos como: ecuaciones que describen la conservación de masas, momento y energía para cada fase, además de correlaciones y modelos para cada patrón de flujo.

Actualmente, se utilizan simuladores de flujo transitorio así como modelos mecanísticos de estado estable que describen con más precisión este fenómeno físico. Aún persisten errores significativos en el ajuste de las predicciones, pero la investigación científica ha abierto oportunidades de mejoramiento, colocando en manos de los ingenieros soluciones a los retos que les plantean las necesidades y las restricciones actuales.

¹ Petróleo, Petróleo y el Hombre. Es.wikipedia.org. Revisado el 11 de septiembre del 2006

OBJETIVOS

OBJETIVO GENERAL

Desarrollar un software basado en redes neuronales artificiales para determinar el patrón de flujo multifásico promedio presente en una tubería a partir de los datos históricos de producción, con el fin de calcular la caída de presión.

OBJETIVOS ESPECÍFICOS

- i. Realizar el estado del arte sobre los modelos utilizados en la determinación del patrón de flujo multifásico en tuberías de recolección de petróleo emulsionado.
- ii. Formular una metodología que permita modelar el flujo en tuberías de recolección de petróleo emulsionado, apoyado en una aplicación de Redes Neuronales Artificiales.
- iii. Implementar una arquitectura de Red Neuronal Artificial que permita:
 - Determinar las variaciones que sufre el fluido y el patrón de flujo
 - Asociar las tasas óptimas de flujo con el patrón determinado
- iv. Comparar los resultados obtenidos por la aplicación de Redes Neuronales Artificiales desarrollada, contra el simulador HYSYS PLANT BUILD 3.2, para el caso de algunos pozos petroleros hipotéticos.

DEFINICIÓN DEL PROBLEMA

Una de las dificultades que afronta la comunidad internacional es el declive en la producción petrolera, predicho para el 2007², por esta razón es necesaria la optimización en los procedimientos de perforación, extracción, transporte y refinamiento. Para lograr este fin se integraron múltiples disciplinas, dentro de las que se encuentra la Ingeniería de Sistemas, la cual colabora con la elaboración de software de diferentes propósitos, entre los que sobresalen los de simulación, que permiten un mayor aprovechamiento de los recursos, basados en las condiciones de los yacimientos.

Una de las dificultades que se presentan en los yacimientos es la construcción y/o remodelación de las facilidades de superficie, porque en mayor parte se debe al mal diseño los problemas de depositación, rotura de líneas, represamiento, y sobrepresionamiento en cabezales, entre otros. Para generar un buen diseño, es necesario realizar una serie de análisis de los diferentes efectos que tienen en el sistema de facilidades, los cambios de elementos como: bombas, aislamientos de bloques de producción, cambios en los diámetros de las tuberías y cambios en la profundidad de las bombas.

Para realizar este análisis se debe conocer el comportamiento de la producción del yacimiento, principalmente, en lo que tiene que ver con: el histórico del estudio de los gradientes de presión, la distribución de las fases y el patrón de flujo que se presentan en el transporte del crudo.

El objetivo general de este proyecto es desarrollar un software basado en redes neuronales que sirva de apoyo para realizar la determinación del patrón de flujo multifásico, de paso colaborando en la industria petrolera con la búsqueda de soluciones más precisas y eficaces que ha tenido como resultado las recientes implementaciones con aplicaciones de Inteligencia Artificial, que toman fuerza por su precisión, robustez y fácil adaptación a los diferentes modelos de campos.

² Según la Teoría del pico de Hubbert, actualizada con datos recientes por la *Asociación para el estudio del pico del petróleo*.

JUSTIFICACIÓN

Los resultados del proyecto podrán servir en la determinación de factores estratégicos de producción en yacimientos reales, como la ubicación de facilidades de superficie y la mejora en porcentajes de rendimiento. Contribuyendo al incremento de la producción general. Esto, junto a la necesidad de optimizar los procesos de extracción, transporte y procesamiento se convierte en una ayuda eficaz al proceso de países que como Colombia dependen de la exportación de petróleo.

Existe novedad al investigar y desarrollar modelos, aplicando redes neuronales artificiales, en el área del flujo multifásico. Este fenómeno ocurre en casi todos los pozos productores de petróleo, en la mayoría de los de gas y en algunos de inyección; avances en esta área tendría efectos inmediatos sobre ellos.

La industria necesita cada vez más participación de tecnologías que, aplicadas, optimicen procedimientos, economicen gastos y mejoren productos. Por medio de este trabajo, se contribuye, en el ámbito académico local, con alternativas, proporcionando información valiosa a las investigaciones por venir.

Las redes neuronales artificiales se ajustan a los diferentes problemas en los cuales se han aplicado, y actualmente están muy difundidas como parte de sistemas de análisis y de predicción. Éstas han mostrado gran potencial para realizar exploraciones, con resultados exactos, de grandes bases de datos históricas. La tendencia parece ser la integración de técnicas emergentes entre si junto con herramientas convencionales, como análisis estadísticos, para construir sistemas que puedan resolver problemas desafiantes.

1. REDES NEURONALES ARTIFICIALES

1.1. GENERALIDADES

A finales de los años 40 se inició el desarrollo de las primeras teorías acerca de aprendizaje y del procesamiento neuronal, apoyados, desde ese entonces, por la computación como herramienta para modelar el comportamiento de las neuronas. Si bien en esa época se tenía un concepto acerca del papel de las neuronas dentro del aprendizaje, un ejemplo de estos sistemas no se desarrolló sino hasta finales de los años 50 con un trabajo realizado por Frank Rosenblatt, con su denominado *Perceptron*³.

El Perceptrón fue un experimento que ilustró propiedades generales de los sistemas inteligentes, sin tener en cuenta varias condiciones especiales. Rosenblatt creía que la conectividad entre las redes biológicas tenía un elevado porcentaje de aleatoriedad, por lo que era necesaria una teoría de probabilidades.

Al inicio hubo un prematuro pesimismo debido a las limitadas capacidades del perceptrón, ilustradas en *Perceptrons*⁴, escrito por Marvin Minsky y Seymour Papert. Gracias a estas debilidades, durante el lapso de tiempo que va desde 1969 hasta principios de los 80 la investigación en este campo fue pobre, por no decir que nula, por un tiempo sólo algunos investigadores continuaron trabajando, los más notables fueron Teuvo Kohonen, Stephen Grossberg, James Anderson y Kunihiko Fukushima.

Desde 1943 McCulloch-Pitts y a partir de su trabajo⁵, al cerebro se le consideró como un organismo computacional, después en 1949 Donald Hebb escribió un libro en el que exponía lo siguiente:

“Cuando un axón de la célula A esta suficientemente próximo para excitar a una célula B o toma parte de su disparo de forma persistente, tiene lugar algún proceso de crecimiento o algún cambio metabólico en una de las dos células, o en las dos, de tal modo que la eficiencia de A, como una de las células que desencadena el disparo de B, se ve incrementada.”⁶

³ Frank Rosenblatt. *The Perceptron: A probabilistic model for information storage and organization in the brain*. Psychological Review, 65:386-408, 1958

⁴ Marvin Minsky, Seymour Papert. *Perceptrons*. MIT Press. Cambridge. 1969

⁵ Warren S. McCulloch y Walter Pitts. *A logical calculus of the ideas immanent in nervous activity*. Bulletin of Mathematical Biophysics, 5:115-113. 1943

⁶ Donald O. Hebb. *The organization of Behavior*. Wiley. New York. 1949

Hebb sostenía que se aumentaba el área de la unión sináptica, pero actualmente, teorías más recientes afirman que se debe a un incremento de la velocidad con que se libera el neurotransmisor en la célula pre-sináptica, o en este caso, la célula A.

Las Redes Neuronales Artificiales (RNA) son una imitación del modelo biológico, basado en un conjunto de células, las neuronas, que envían impulsos gracias a conexiones nerviosas llamadas sinapsis, cuando un estímulo de estos es recibido, las sustancias químicas transmisoras se liberan de la sinapsis y entran a la dendrita, aumentando o disminuyendo el potencial eléctrico del cuerpo de la célula. Cuando el potencial alcanza un umbral se transmite un pulso eléctrico o una acción potencial a través del axón.

En las RNA las neuronas y conexiones son reemplazadas por los modelos matemáticos que simulan su comportamiento. Estos modelos son conocidos como funciones de activación. La neurona artificial recibe señales desde varias entradas, estas son multiplicadas en la entrada de la neurona por sus respectivos pesos sinápticos, estos pesos determinan la fuerza de cada conexión y son determinados por un algoritmo de aprendizaje que los modifica de acuerdo con patrones dados, después de esto, se realiza una sumatoria simple de todos los productos de las entradas por los pesos, este resultado es evaluado por medio de una función de activación que será a su vez evaluada por la función de salida de la neurona, que por lo general es una función lineal, y esta salida va a su vez como entrada de la siguiente capa de neuronas o si es su caso para la salida de la red.




Figura 1. Modelo de neurona artificial

Donde:

P_n = n-ésima entrada de la neurona.

W_{nj} = Peso de las conexión de la enésima entrada de la neurona j.

E = Sumatoria de los productos de las entradas $\sum_{i=1}^n P_i * W_{ij}$

FT = Función de transferencia.

S_j = Salida de la neurona j.

Las funciones de activación más comunes son la función identidad, escalón, lineal, sigmoideal y gaussiana (Tabla 1).

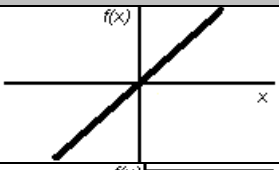

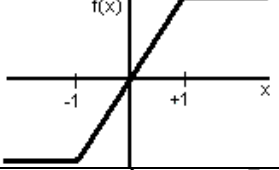
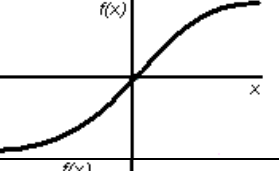
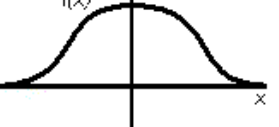
	Función	Grafica
Identidad	$f(x) = x$	
Escalón	$f(x) = H(x)$	
Lineal a tramos	$f(x) = \begin{cases} -1 & \text{si } x < -1 \\ x & \text{si } -1 \leq x \leq 1 \\ +1 & \text{si } x > 1 \end{cases}$	
Sigmoideal	$f(u_i) = \frac{1}{1 + e^{-u_i/\sigma}}$	
Gaussiana	$f(u_i) = ce^{-u_i^2/\sigma^2}$	

Tabla 1. Funciones de activación más comunes

La RNA se entrena introduciendo valores al azar inicialmente en los pesos de las neuronas, luego se le suministran entradas prefijadas y comparando las salidas de la red con un resultado esperado, luego se ajustan los pesos de cada neurona de acuerdo a la magnitud del error presentado, este proceso se realiza de manera iterativa hasta tener, con una gran aproximación, las respuestas adecuadas del sistema.

1.2. TIPOS DE RED

Las redes se dividen según algoritmo de aprendizaje, en redes de entrenamiento supervisado y no supervisado (Figura 2 y Figura 3).

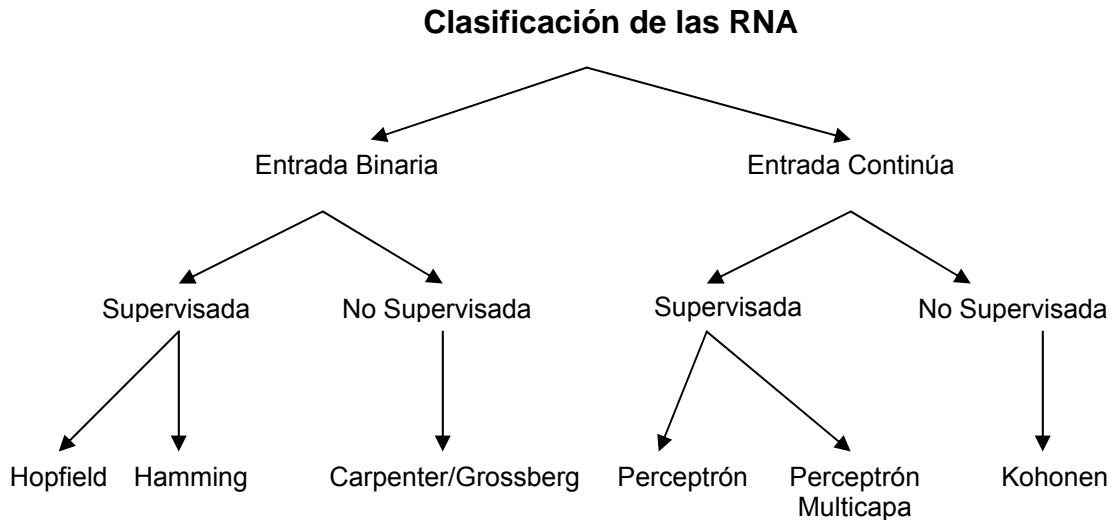


Figura 2. Clasificación de las redes neuronales

Las redes de tipo supervisado son las más desarrolladas, entre las que sobresale el perceptrón multicapa con algoritmo de aprendizaje de retro-propagación. Sus datos de entrenamiento se componen de valores entrada/salida, esto permite una rectificación de pesos en base a las que el supervisor quiere, de tal modo que la ecuación de redefinición de pesos sería de la forma:

$$W_{ij} = W_{ij} + \Delta W_{ij} \quad (1)$$

Por otro lado, en las redes no supervisadas los datos de entrenamiento consisten en patrones de entrada, en ellos la red trata de descubrir características comunes entre los datos presentados, formándose como "identificadores de patrones". Si en un conjunto nuevo de datos la red decide que pertenecen a una clase reconocida previamente, entonces la inclusión de este nuevo patrón a esta clase recompondrá la representación de la misma. Si por el conjunto de datos se determinó que no pertenece a ninguna de las clases reconocidas anteriormente, entonces la estructura y los pesos de la RNA serán reajustados para reconocer la nueva clase.

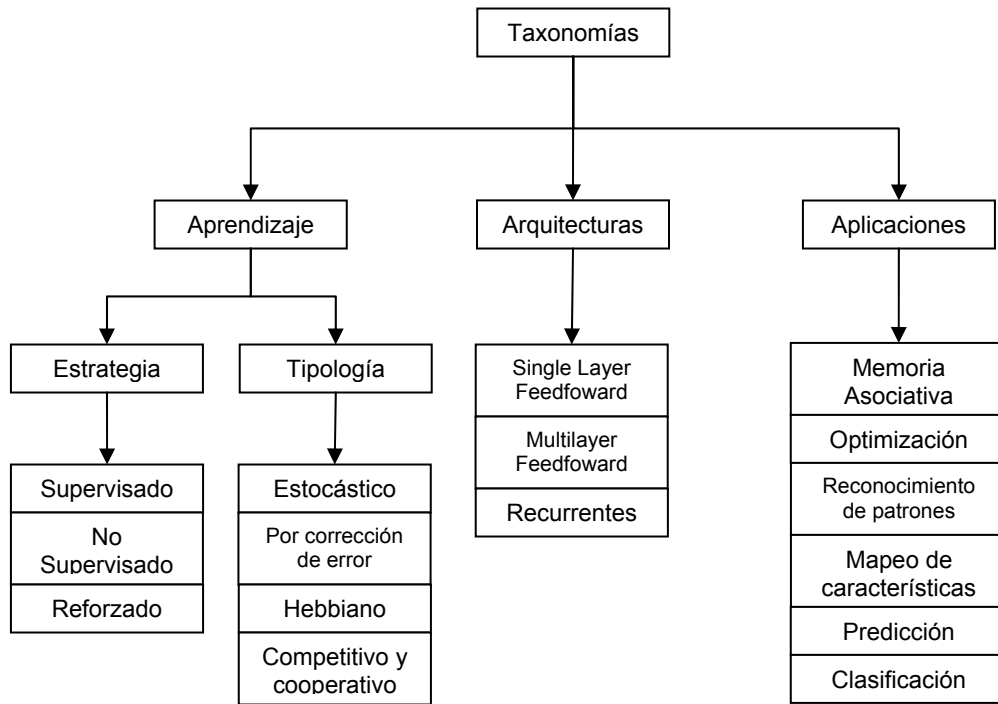


Figura 3. Taxonomía de las redes neuronales⁷

Dentro de las diferentes arquitecturas desarrolladas para crear redes neuronales eficientes para determinados tipos de problema, se habla de las capas como un grupo de neuronas que tienen conexiones a las mismas entradas y envían sus señales a un mismo destino, entonces los datos que son introducidos en una capa producirán los resultados que servirán de datos de entrada para la siguiente capa.

Toda red neuronal tiene como mínimo una capa de entrada y una capa de salida, las capas que están entre estas dos se denominan capas ocultas, de las cuales su número puede variar dependiendo de la complejidad del problema.

1.2.1. Perceptrón Multicapa Con Algoritmo Backpropagation (PMC)

En el año de 1986, se dio un importante paso en la construcción de arquitecturas de redes neuronales, con el desarrollo de un modelo que fue descubierto por Werbos en 1974, Parker en 1985 y Rumelhart *et al* en el 86, dando como resultado la implementación de una red de varias capas con un nuevo algoritmo de propagación del error, las llamadas redes backpropagation.

⁷ Rojas, R. *Neural Networks. A Systematic Introduction*, pp. 7. 1996.

Uno de los métodos más utilizados a través de la historia de las RNA es el método backpropagation, utilizado para clasificación y pronóstico, que consta precisamente de una formación de neuronas sencillas dispuestas en múltiples capas, conectadas entre sí por medio de conexiones ponderadas con pesos que se modifican por medio del entrenamiento. Backpropagation, como su nombre lo indica, propaga el error hacia atrás, para esto utiliza la llamada regla delta que distribuye de forma proporcionada el diferencial entre la salida obtenida en el proceso de entrenamiento y la salida deseada. El proceso de entrenamiento de la red sucede como sigue:

A la red le es presentado un conjunto de pares de datos de entrada-salida a manera de ejemplo, los datos de entrada provocan un estímulo en la primera capa, que se va propagando en las siguientes hasta llegar a la capa de salida, la salida obtenida se compara con el dato de salida que se desea obtener y se calcula entonces un valor del error para cada una de las neuronas de salida. Este error es trasladado hacia atrás yendo en dirección a la capa de entrada, pasando por todas las capas ocultas, recibiendo cada neurona de cada capa el error aproximado de su colaboración al error relativo total. Basándose en ese valor del error recibido por cada neurona se ajustan nuevamente los pesos de las conexiones entre las neuronas, de modo que la salida en la siguiente iteración tendera a ser más cercana a la salida deseada.

Se ha demostrado que el perceptrón multicapa con algoritmo de aprendizaje backpropagation es un aproximador de función universal. Esto significa que para cualquier grado de exactitud que sea necesario, existe una configuración de red que puede llenar los requerimientos involucrados. Desgraciadamente, esto no proporciona ninguna ayuda para fijar los parámetros de la red. Por esto, la configuración de la red es determinada por medio de reglas heurísticas.

El tamaño de la red es determinado por el número de capas ocultas y el número de neuronas en estas capas. Se pueden usar las siguientes guías para escoger el número de capas:

1. Cuando la función consiste en un número finito de puntos, una red de tres capas tiene la capacidad de aprender esta función.
2. Cuando la función es una función continua definida en un rango de valores, una red de tres capas tiene la capacidad de aprender esta función.
3. Una red de tres capas es también capaz de aprender varias funciones que no cumplan los criterios anteriores. Bajo ciertas condiciones, por ejemplo, las funciones con entradas normalmente distribuidas pueden ser aprendidas.
4. Todas las demás funciones pueden ser aprendidas por una red de cuatro capas.

El algoritmo backpropagation se ha hecho popular por su capacidad de modificar los pesos de sus conexiones para realizar aproximaciones muy exactas de determinados modelos y en la mayoría de casos superiores a los modelos actualmente existentes. Es una capacidad de generalización que le permite dar salidas muy cercanas para los conjuntos de datos evaluados, que la red, en su etapa de entrenamiento, no ha visto.

Para lograr un buen desempeño en el desarrollo de una PMC, con el fin de evitar problemas como el overfitting, consistente en el aprendizaje de “memoria” de la red, o la no convergencia del modelo, cuando el número de neuronas no es suficiente, se recomiendan los siguientes puntos:

- El número de casos para el entrenamiento debe ser suficientes y además representativos del conjunto de casos que se desee generalizar. La mejor red no es aquella cuyo error en el entrenamiento continuamente está bajando.
- Conservar alrededor de un 10% de los ejemplos de entrenamiento, el llamado conjunto de validación, no incluyéndolos en el entrenamiento, con el fin de hacer pruebas de testeo de la red una vez halla finalizado el entrenamiento, con el fin de ver la capacidad de generalización alcanzado, teniendo lo que se llama error de generalización.
- La clasificación de las entradas y las salidas deben estar en un adecuado rango de interpretación por parte de la red, no son recomendables los valores grandes ni aquellos que posean valores extremos, ya que afectaría el entrenamiento, lo más recomendado es la normalización de los datos.

1.2.2. *Redes De Función De Base Radial*

Inicialmente inducido por un artículo sobre funciones de base radial de Medgassy en 1961 y las aplicaciones a interpolación de funciones de Micchelli en 1986 y Powell en 1987, a la estimación de la función de densidad, de Parzen en 1962 y Specht en 1990, y a la aproximación de funciones multivariantes suaves, de Poggio y Girosi en 1989. Son un método alternativo a las redes Backpropagation, constan de sólo una capa oculta, fueron ideados por Bromead y Lowe en 1988, comprenden la clasificación no lineal, las funciones de activación en su capa oculta y de salida son diferentes, las neuronas de la capa oculta son activadas por medio de funciones radiales en base a un centroide o centro de gravedad. La función radial viene dada por la ecuación de una función gaussiana:

$$\phi_i(n) = e^{-\frac{\|X(n)-C_i\|^2}{2d_i^2}} \quad (2)$$

La RBF (*Radial Basis Function*) tiene como ventaja sobre la backpropagation que su aprendizaje se favorece entre más ejemplos de entrenamiento halla en el conjunto, no sufriendo el problema del overfitting. Por otro lado, como una de sus principales

desventajas está que requiere un volumen mayor de neuronas que la backpropagation y su gasto de cómputo y memoria es mayor.

El entrenamiento de la red de función de base radial ocurre sólo hacia delante, pertenece a un tipo de aprendizaje híbrido, los centroides son hallados mediante un proceso no supervisado, el más utilizado es el algoritmo denominado K-medias, y los pesos sinápticos entre la capa oculta y la de salida se hallan supervisadamente. El proceso de entrenamiento ocurre de manera resumida así:

- Por la naturaleza del algoritmo K-medias se le indican cuántos nodos o centros se van a tener en cuenta. Se inicializan estos pesos con puntos escogidos aleatoriamente entre los puntos de entrada.
- Entre los centros establecidos se reparten los puntos de entrada del conjunto de entrenamiento, teniendo como criterio que se asigna el punto al centro más cercano a él.
- Se calcula el centroide de todos los puntos pertenecientes al mismo nodo, se ajusta el valor del centro por el hallado.
- Se repiten los pasos anteriores hasta que el cambio de los centros con respecto a los centros anteriores sea casi nulos.
- Una vez se han establecido los centros finales, se procede a calcular los pesos sinápticos de conexión entre la capa oculta y la de salida, para lo cual se puede utilizar, como en nuestro caso, la regla delta generalizada tal como se haría con un PMC con algoritmo backpropagation.




Figura 4. Función de activación radial

Como la red de función de base radial necesita de un agrupamiento previo de los datos, se hace necesario implementar un algoritmo que realice la tarea, para este fin

existen varias opciones, como las implementaciones con redes auto-organizativas, algunos algoritmos de agrupamiento son:

- Clustering Probabilística
- Métodos de los k-vecinos (*kmedoids*)
- Métodos de las k-medias
- Algoritmos Basados en Densidad
- Clustering de Conectividad Basada
- Densidad *Density-Based*
- Clustering basado en Funciones de Densidad
- Métodos Basados en Rejillas
- Métodos Basados en la Co-Ocurrencia de Datos Categóricos
- Clustering Basado en Restricciones
- Algoritmos para Datos de Grandes Dimensiones
- Clustering Subespacial
- Técnicas de Co-Clustering

El método a utilizar en esta oportunidad es el K-medias, que es un método adecuado, sencillo pero a la vez robusto en sus clasificaciones [1]. Se trata de un algoritmo clasificado como de Particionado y Recolocación.

El de las k-medias, es hasta ahora el más utilizado en aplicaciones científicas e industriales. El nombre le viene porque representa cada uno de los clusters por la media (o media ponderada) de sus puntos, es decir, por su centroide. Éste únicamente se puede aplicar a atributos numéricos, y los valores extremos le pueden afectar negativamente. Sin embargo, la representación mediante centroides tiene la ventaja de que tiene un significado gráfico y estadístico inmediato.

La suma de las discrepancias entre un punto y su centroide, expresado a través de la distancia apropiada, se usa como función objetivo. La función objetivo, suma de los cuadrados de los errores entre los puntos y sus centroides respectivos, es igual a la varianza total dentro del propio cluster. La suma de los cuadrados de los errores se puede racionalizar, como el negativo del log-

likelihood, para modelos mixtos que utilicen distribuciones normales. Por lo tanto, el método de las k-medias se puede derivar a partir del marco probabilística (ver subsección *Clustering Probabilístico* del libro de Mitchell⁸).

1.3. APLICACIONES

En la última década, La Inteligencia Artificial ha madurado en un conjunto de herramientas analíticas (RNA, programación evolutiva, Lógica Borrosa entre otras) que facilitan la solución de problemas que habían sido difíciles o imposibles de resolver. La tendencia hoy parece ser la integración de estas herramientas entre si junto con herramientas convencionales, como análisis estadísticos, para construir sofisticados sistemas que puedan resolver problemas desafiantes. Estas herramientas son usadas en diferentes disciplinas y han encontrado su camino dentro de los productos comerciales.

En particular, las RNA son aplicadas en un amplio campo de problemas, sobre todo para lo que la realización de modelos matemáticos es compleja o imposible. Esto se debe a que los parámetros involucrados en un proceso particular no son conocidos y/o la interrelación de éstos es complicada para generar el modelo matemático del sistema. En estos casos, una RNA puede ser construida para observar la conducta del sistema (qué tipo de salida es producida como resultado de cierto conjunto de entradas) e intentar imitar su funcionalidad y conducta.

Debido a las grandes similitudes que presentan las RNA con las neuronas biológicas, es posible realizar tareas de clasificación, estimación y agrupamiento, que para el cerebro son fáciles de resolver, pero que por medio de un algoritmo computacional es poco menos que imposible.

La clasificación es de las aplicaciones más comunes que se tienen para las RNA. Muchas de las necesidades del ser humano comprenden clasificación, categorización, el problema se presenta cuando son cientos y a veces miles las clasificaciones que se tienen que llevar a cabo para determinadas tareas como la clasificación de riesgos, la detección de fraudes, el filtrado de datos, lo que se lleva a pensar en una automatización, que se puede lograr con RNA. Algunas de las aplicaciones ubicadas aquí son las siguientes:

- Detección de fraudes.
- Asignación de créditos.
- Reconocimiento de voz y texto.

⁸ Tom M. Mitchell. *Machine Learning*. McGraw-Hill. (1997)

- Reconocimiento de patrones.
- Limpieza de ruido.

La clasificación trata con conclusiones discretas, un si o un no, tipo de crédito, válido o no válido, está en esta clase o está en otra, en la estimación la salida es continua, dados los valores de entrada, la red devuelve un valor que se puede interpretar, según el problema, como peso, entradas de dinero, o porcentaje. Entre otras aplicaciones, dentro de las estimativas están:

- Estimación de los ingresos de un hogar.
- Estimación del tiempo de vida de una persona o artículo.
- Determinación de porcentajes de materiales compuestos.
- Estimación de probabilidades.

El sentido común indica que si un problema puede ser resuelto con métodos convencionales, las redes neuronales (o cualquier otra técnica de inteligencia artificial) no deben ser usadas para resolverlo. Por ejemplo, balancear una chequera con una red neuronal no es recomendable. Aunque hay valor académico en resolver problemas simples, como las ecuaciones polinómicas y diferenciales, con las redes neuronales para mostrar sus capacidades, estas deben usarse principalmente para resolver problemas que de otra manera consumen mucho tiempo o simplemente es imposible de resolver por métodos convencionales.

Las redes neuronales han mostrado gran potencial para generar análisis y resultados precisos de grandes bases de datos históricas, el tipo de datos que los ingenieros pueden considerar sin valor o irrelevantes en el modelamiento convencional y en procesos de análisis.

1.3.1. Aplicaciones En La Industria Del Petróleo

La industria de la producción del petróleo y gas no es ajena a la tendencia del uso de Las RNA como técnicas de computación emergente. En varios artículos Mohaghegh [2]⁹ hace un recuento de las aplicaciones de las RNA a la industria del petróleo y gas. Estas aplicaciones están basadas en la capacidad de éstas para resolver problemas combinados con herramientas convencionales tales como el análisis estadístico e inferencia de patrones de datos.

⁹ Mohaghegh S. and Ameri S. "Artificial Neural Network as a Valuable Tool for Petroleum Engineers", paper SPE 29220. 1995.

Mohaghegh Kumoluyi A.O. y Daltaban (1994)¹⁰ proponen la aplicación de las RNA de alto orden (redes de retro-propagación: Perceptrones multicapa, Redes de teoría de resonancia magnética, máquinas de Boltzmann y mapas auto-organizativos de Kohonen) a casos específicos de análisis de datos: interpretación de registros de pozo, modelamiento del flujo en tubería y tratamiento de datos sísmicos. Para estos casos se busca explotar la propiedad de las redes neuronales de alto orden para efectuar un reconocimiento de patrones que permite realizar una selección de los datos para un análisis estadístico posterior.

Ali J.K. (1994)¹¹ muestra el panorama de las aplicaciones directas de las RNA en la industria petrolera. Estas aplicaciones aunque novedosas no son necesariamente el resultado de una aproximación al azar.

Las empresas de petróleo y gas tratan de aumentar su posicionamiento global mejorando las predicciones de mercado y el tratamiento de la compleja información generada en el proceso de exploración y explotación de campos de petróleo y gas.

Las características de Las RNA se aplican a los siguientes casos:

- Problemas en los cuales se desconocen reglas detalladas para resolverlos o son difíciles de formalizar, pero hay conjuntos de datos de entrada y salida conocidos.
- Problemas que tienen “ruido” en los datos.
- Donde se requiere una alta velocidad de procesamiento.

Ali J.K. termina su artículo resumiendo las aplicaciones directas de las RNA a la industria petrolera de la siguiente manera:

- i) Geología y geofísica:
 - Estimación de reservas.
 - Identificación de minerales en los registros de los pozos.
 - Localización de pozos a perforar en datos geofísicos.
 - Comprensión de los datos sísmográficos en la prospección petrolera.

¹⁰ Kumoluyi A.O. and Daltaban T.S. “*High-Order Neural Networks in Petroleum Engineering*”, paper SPE 27905. 1994.

¹¹ Ali J.K. “*Neural Networks: A New Tool for the Petroleum Industry?*”, paper SPE 27561. 1994.

ii) Perforación y completamiento de pozos:

- Análisis de datos de perforación
- Diagnósticos de desgaste de brocas
- Selección y monitoreo de brocas y lodos de perforación

iii) Evaluación de formaciones

- Predicción de la porosidad
- Predicción de la permeabilidad
- Detección y delineamiento de fracturas
- Identificación e interpretación de registros
- Presiones de pozo

iv) Producción y facilidades

- Análisis e implantación de producciones de gas y petróleo
- Inspección de tuberías de producción
- Diagnóstico y mantenimiento
- Localización de plataformas de perforación costa afuera

v) Ingeniería de yacimientos

- Análisis de parámetros de producción de gas y petróleo
- Inversión de modelos de simulación
- Ajuste histórico automático
- Reconocimiento de patrones de presión en pruebas de pozo
- Predicción de propiedades de yacimiento
- Predicción de propiedades físicas

Vi) Negocios del petróleo

- Análisis de mercado de gas y petróleo
- Análisis de riesgo
- Optimización de portafolio de negocios
- Coordinación de datos económicos

En un estudio posterior Toomarian y colaboradores (1997)¹² han profundizado en la utilización de Las RNA en el campo de caracterización de propiedades del yacimiento, creando algoritmos para analizar los registros o perfiles eléctricos de pozo para estimar con una mayor exactitud las propiedades de los fluidos en la litología y columna estratigráfica del pozo.

En conclusión, Las RNA son usadas en la industria del petróleo para realizar cálculos de niveles de bomba, gradientes de presión en pozos y redes de tuberías, análisis nodal, patrones de flujo, holdup, etc. A lo largo de los años se ha verificado que las redes neuronales producen los mejores resultados donde se las aplica. Esto se confirma en el paper "Identificación del patrón de flujo y holdup del líquido usando redes neuronales artificiales" del doctor Osman Elsayed [3] donde él sostiene que, usando redes neuronales, se podría predecir los regímenes de flujo anular, estratificado, bache y ondulado con una exactitud de 100%, 98.6%, 98.5% y 94.7% respectivamente.

¹² Toomarian N.B., Barhen. J., Glove C.W. and Aminzadeh. "Oil Reservoir Properties Estimation Using Neural Networks". JPL Report. Nasa Research Press. 1999.

2. FLUJO MULTIFÁSICO

2.1. FLUJO MULTIFÁSICO

El flujo multifásico se define como el flujo simultáneo de dos o más fases (en estado líquido, sólido o gaseoso) en una tubería de conducción. En la industria del petróleo, el flujo multifásico se presenta en tuberías de superficie y en los pozos de producción de gas y aceite (la mayoría de pozos que producen líquidos producen algo de gas y viceversa).

Todos los intentos realizados para obtener una solución general para el problema del flujo multifásico han caído en el vacío, aun así se ha observado una asociación natural, es decir, para cada patrón hay un comportamiento similar, Esto hace que el problema sea algo más fácil, se analiza cada patrón por separado. De esta manera, el método lógico indica primero que hay que predecir el patrón de flujo en la tubería, y una vez determinado se desarrolla un modelo por separado el cual prediga las características del flujo, como caída de presión, colgamiento del líquido y el coeficiente de transferencia de calor.

2.2. PATRONES DE FLUJO MULTIFÁSICO

Se definen los patrones de flujo multifásico como una descripción cualitativa de la distribución de las fases en la tubería. Describe la forma en que se distribuyen las fases en un segmento de tubería. El patrón de flujo es influenciado por la geometría de la tubería, por las propiedades físicas de la mezcla (densidad, tensión superficial, viscosidad) y por las tasas de flujo.

Cuando la tubería posee una inclinación mayor que ± 5 grados, ya sea por la topografía del terreno o por razones de conveniencia, no se puede considerar la tubería como una tubería horizontal. Aunque los patrones de flujo en tubería inclinada se consideran como si fuera una tubería horizontal (los patrones de Beggs y Brill), se tiene que los valores de las caídas de presión y holdup son diferentes y son más complicados de determinar.

2.2.1. Patrones De Flujo Multifásico En Tubería Horizontal

Se considera flujo en tubería horizontal, el flujo que fluye por una tubería cuya elevación no supera los ± 5 grados.

Los patrones de flujo no afectan la presión significativamente en flujo horizontal como sí sucede en el vertical. En el flujo horizontal la energía potencial no influye. De todos

modos esto no indica que estos patrones de flujo horizontal no se tengan en cuenta. Pueden afectar las operaciones de producción y algunas correlaciones para caídas de presión los consideran.

Aunque se han realizado muchas descripciones y tipificaciones de los patrones de flujo (Alves definió ocho regímenes, Degance y Aterton definieron tres categorías), actualmente se usan las categorías definidas por Beggs y Brill las cuales son definidas a continuación.

2.2.1.1 Patrón De Flujo Segregado.

El flujo segregado es aquel en el que las fases se encuentran, en su mayor parte, separadas. Se subdivide en tres regímenes: flujo estratificado, flujo ondulado y flujo anular. El primero se caracteriza porque el líquido va fluyendo por la parte baja de la tubería, mientras el gas fluye a lo largo del tope de la tubería, con una interfase lisa entre las fases. Éste régimen ocurre cuando las tasas de las fases son relativamente bajas. A tasas más altas la interfase comienza a ondularse, originándose el flujo ondulado. Por último el flujo anular ocurre cuando hay tasas altas de gas y tasas relativamente altas de líquido. Éste flujo consiste de una capa fina de líquido en las paredes de la tubería y una fase gaseosa con pequeñas gotas de líquido fluyendo por la parte central de la tubería.

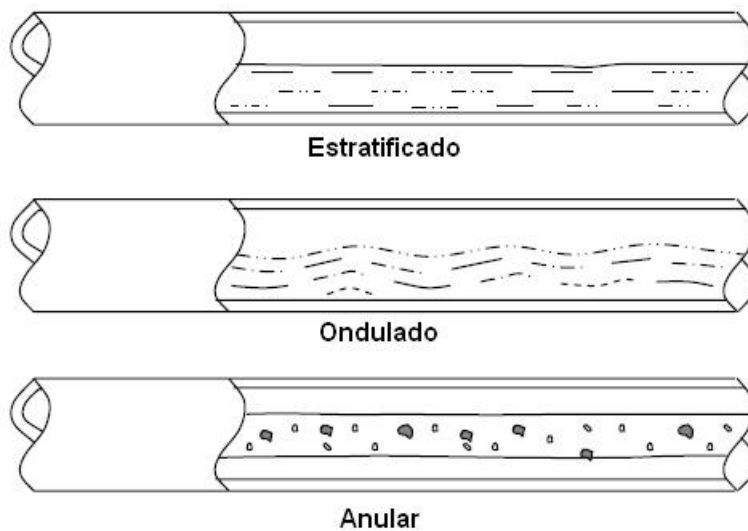


Figura 5. Patrones de flujo segregado

2.2.1.2 Patrón De Flujo Intermitente.

El patrón de flujo intermitente es aquel en el cual el gas y el líquido fluyen alternadamente a través de la tubería. Se divide en dos regímenes de flujo: flujo bache

y flujo tapón. El flujo bache consiste en grandes baches de líquido alternado con burbujas de gas a alta velocidad llenando la mayor parte de la tubería. El flujo tapón se distingue por el flujo de grandes burbujas de gas a lo largo de toda la tubería.




Figura 6. Patrones de flujo intermitente

2.2.1.3 Patrón De Flujo Distribuido.

Este flujo se caracteriza por una fase que se encuentra dispersa en la otra y se divide en dos regímenes: flujo tipo burbuja y flujo tipo niebla o disperso. El flujo tipo burbuja. El flujo tipo niebla se presenta a altas tasas de gas y bajas tasas de líquido y consiste en gas con gotas dispersas de líquido. Este régimen de flujo es considerado semejante al flujo anular, por lo que muchos mapas de patrones de flujo usan el nombre niebla-anular para denotar estos regímenes.




Figura 7. Patrones de flujo distribuido

Beggs y Brill definieron un nuevo patrón denominado Transición debido a que, cuando el patrón cambia de segregado a intermitente en determinada zona, observaron un decrecimiento grande pero lento de la fracción de líquido retenido que no era tan rápido como lo indicaban las ecuaciones.

2.3. MAPAS DE REGÍMENES DE FLUJO PARA TUBERÍAS HORIZONTALES

2.3.1. Correlación De Baker

Los mapas de regímenes de flujo son usados para predecir los patrones de flujo en una tubería horizontal. Uno de los primeros mapas que se diseñaron fue creado por Baker en 1953, más tarde modificado por Scoot mostrado en la siguiente figura, en la cual los ejes son G_l/λ y $G_l\lambda\varphi/G_g\lambda$ donde G_l y G_g son el flujo másico del líquido y del gas respectivamente y el parámetro λ y φ son:

$$\lambda = \left[\left(\frac{\rho_g}{0.075} \right) \left(\frac{\rho_l}{62.4} \right) \right]^{1/2} \quad (3) \quad \varphi = \frac{73}{\sigma_l} \left[\mu_l \left(\frac{62.4}{\rho_l} \right)^2 \right]^{1/3} \quad (4)$$

En la siguiente figura se muestra el mapa de regímenes de flujo de Baker. En él se puede observar que las transiciones de un patrón de flujo a otro no son abruptas, pero la transición ocurre en todo ese rango.

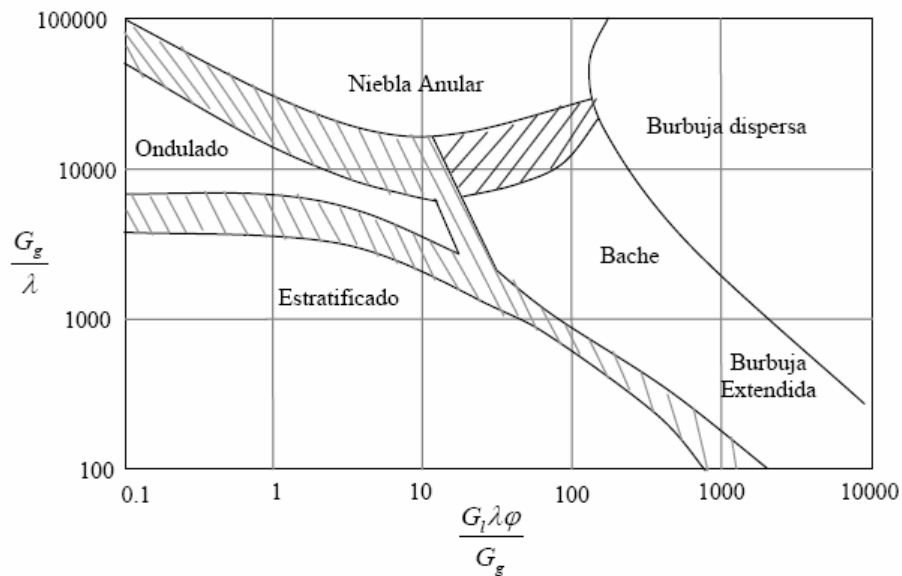


Figura 8. Mapa de regímenes de flujo, Baker (1953) [4]

2.3.2. Correlación De Govier & Omer:

En 1962 Govier & Omer propusieron un mapa de patrones de flujo, mejorándolo más tarde para ajustarla a modificaciones de diámetro y a las propiedades de los fluidos. Govier y Aziz sugieren una modificación de las coordenadas para aplicarlo a otros tipos de fluido diferentes al aire-agua. Recomiendan los siguientes parámetros de corrección:

$$X = \left(\frac{\rho_g}{0.0808} \right)^{1/3} \quad (5) \quad Y = \left[\left(\frac{\rho_g}{62.4} \right) \left(\frac{72.4}{\sigma} \right) \right]^{1/4} \quad (6)$$

Estos parámetros son usados para multiplicar las velocidades superficiales de los fluidos de la siguiente manera:

$$\tilde{V}_{SG} = X V_{SG} \quad (7) \quad \tilde{V}_{SL} = Y V_{SL} \quad (8)$$

\tilde{V}_{SG} y \tilde{V}_{SL} son usados en forma normal con el mapa modificado de patrones de flujo.




Figura 9. Mapa de patrones de flujo de Govier & Omer [5]

2.3.3. Correlación De Mandhane

En 1964, Mandhane propone un mapa de patrones de flujo en el cual, con base en las coordenadas de $\text{Log } V_{SL}$ vs $\text{Log } V_{SG}$, se localizan los límites de transición. El mapa diseñado por Mandhane usa como ejes de coordenadas las velocidades superficiales del líquido y del gas (V_{sl} Vs V_{sg}), el cual se muestra en la figura 7.




Figura 10. Mapa de regímenes de flujo Mandhane (1974) [5]

Mandhane introduce los siguientes factores de corrección para las diferentes propiedades físicas de los fluidos:

$$X' = \left(\frac{\rho_G}{0.0808} \right)^{0.2} \left(\frac{\rho_L}{62.4} \frac{72.4}{\sigma} \right)^{0.25} \left(\frac{\mu_G}{0.018} \right)^{0.2} \quad (9) \quad Y' = \left(\frac{\mu_L}{1.0} \right)^{0.2} \left(\frac{\rho_L}{62.4} \frac{72.4}{\sigma} \right)^{0.25} \quad (10)$$

Donde ρ_G y ρ_L están expresadas en lb_m/ft^3 , μ_G y μ_L están expresados en centipoises, y σ en dinas/cm. Hay que tener en cuenta que estos factores se aplican a las transiciones individuales, antes que a los ejes del mapa.

2.3.4. Correlación De Taitel & Dukler

En Taitel y Dukler se desarrolló un modelo en el año 1976 para las transiciones de regímenes de flujo horizontal, este modelo puede ser usado para elaborar mapas de regímenes de flujo para fluidos y diámetro de tuberías particulares, el cual se muestra en la figura 8.

En él presenta un análisis teórico, la teoría de la inestabilidad de Kelvin-Helmholtz, para predecir las transiciones que ocurren entre los patrones de flujo. Para esto ellos demuestran que cada transición está controlada por un par diferente de grupos adimensionales. Con este modelo, generalizado (Figura 11) se convirtieron en los primeros en la predicción analítica de los patrones de flujo.




Figura 11. Mapa de regímenes de flujo Taitel-Dukler (1976) [4]

2.3.5. Correlación De Beggs & Brill

En Beggs y Brill se realizó un mapa de patrones de flujo en el cual los ejes de coordenadas son el número de Froude (N_{FR}) contra la fracción de líquido entrante λ_L . Este mapa se caracteriza por presentar los cuatro patrones de flujo propuestos por ellos, sin tener en cuenta los diferentes regímenes de flujo.




Figura 12. Mapa del patrón de flujo Beggs & Brill[4]

2.4. HOLDUP O COLGAMIENTO

2.4.1. Velocidades Superficiales

Se define la velocidad superficial de determinada fase, como la velocidad a la que viajaría ésta si fluyera sola a través de toda el área de flujo de la tubería. Por lo tanto:

$$V_{SL} = \frac{Q_L}{A} = \frac{Q_L}{(\pi D^2 / 4)} \quad (11) \quad V_{SG} = \frac{Q_G}{A} = \frac{Q_G}{(\pi D^2 / 4)} \quad (12)$$

A = Área de la sección transversal de la tubería.

D = Diámetro.

Q_L = Flujo de líquido por la tubería.

Q_G = Flujo de gas por la tubería.

Puesto que las dos fases fluyen por la misma tubería al mismo tiempo, el área real para cada fase es una fracción del área total de flujo de la tubería. Por consiguiente, la velocidad superficial siempre es menor que la velocidad real de la fase. Las

velocidades superficiales de las fases son usadas para correlacionar muchos de los fenómenos observados en el flujo multifásico.

2.4.2. Velocidad De La Mezcla

La velocidad de la mezcla se define como la suma algebraica de la velocidad superficial del líquido y la velocidad superficial del gas:

$$V_M = V_{SL} + V_{SG} \quad (13)$$

2.4.3. Holdup Del Líquido Sin Deslizamiento.

El Holdup del líquido sin deslizamiento, λ_L y λ_G , se define en términos de las tasas volumétricas bajo determinadas condiciones de presión y temperatura de flujo. Se considera que no hay deslizamiento entre las fases, cuando las fases tienen la misma velocidad real. Lo que implica que:

Fase Líquida	Fase Gaseosa	
$\lambda_L = \frac{Q_L}{Q_L + Q_G}$	$\lambda_G = \frac{Q_G}{Q_L + Q_G}$	$\lambda_L + \lambda_G = 1$
$\lambda_L = \frac{V_{SL}}{V_{SL} + V_{SG}} = \frac{V_{SL}}{V_M}$	$\lambda_G = \frac{V_{SG}}{V_{SL} + V_{SG}} = \frac{V_{SG}}{V_M}$	

Tabla 2. λ_L y λ_G para el holdup del líquido sin deslizamiento.

2.4.4. Holdup Del Líquido

El Holdup del líquido se define como la relación entre el volumen de un segmento de tubería ocupado por el líquido y el volumen total de ese segmento. Este valor varía entre cero y uno, por lo que, la diferencia de 1 menos el Holdup de líquido (H_L) equivaldrá al Holdup del gas (H_G).

Físicamente, el Holdup del líquido se mide cerrando dos válvulas cercanas y midiendo la cantidad de líquido retenido. Dependiendo del método, se propone una ecuación diferente para su evolución y generalmente depende del patrón de flujo y de la posición de la tubería.

2.4.5. Velocidades Reales

La velocidad real de la fase líquida es aquella que considera el deslizamiento entre las fases:

$$V_L = \frac{Q_L}{A * H_L} \quad (14)$$

Análogamente, la velocidad real del gas es aquella que tiene en cuenta el deslizamiento entre las fases, así:

$$V_G = \frac{Q_G}{A * H_G} \quad (15)$$

2.4.6. Velocidad De Deslizamiento

Se define como la diferencia entre la velocidad real del gas y la velocidad real del líquido:

$$V_{SLIP} = V_G - V_L = \frac{Q_G}{A * H_G} - \frac{Q_L}{A * H_L} \quad (16)$$

Los siguientes son modelos empíricos desarrollados para la estimación del holdup en flujo horizontal:

2.4.7. Correlación De Beggs & Brill

Mencionamos aquí la correlación de Beggs y Brill, ya que ésta se puede usar en tubería horizontal y al mismo tiempo puede ajustarse para tuberías inclinadas. Dependiendo del patrón de flujo, Beggs y Brill proponen las siguientes correlaciones:

Patrón de flujo	Correlación
Segregado	$H_L(0) = \frac{0.98\lambda^{0.484}}{N_{FR}^{0.0868}}$
Transición	$H_L(0) = \frac{0.98\lambda^{0.4846}}{N_{FR}^{0.0868}} * \frac{(L3 - N_{FR})}{(L3 - L2)} + \frac{0.845 * \lambda^{0.5351}}{N_{FR}^{0.8609}} * \left(1 - \frac{(L3 - N_{FR})}{(L3 - L2)}\right)$

Intermitente	$H_L(0) = \frac{0.845\lambda^{0.5351}}{N_{FR}^{0.0173}}$
Distribuido	$H_L(0) = \frac{1.065\lambda^{0.5824}}{N_{FR}^{0.0609}}$

Tabla 3. Correlaciones para el cálculo del holdup, según Beggs & Brill

2.4.8. Correlación De Lockhart & Martinelli Y Sus Modificaciones

En el año de 1949, se presentó una correlación empírica para la fracción volumétrica promedio *in situ* de la fase líquida, E_L , como función de X, definido así:

$$X = \sqrt{\frac{\left(\frac{\Delta P}{L}\right)_{SL}}{\left(\frac{\Delta P}{L}\right)_{SG}}} \quad (17)$$

Donde $\left(\frac{\Delta P}{L}\right)_{SL}$ es el gradiente de presión que tendría lugar si el líquido estuviera fluyendo solo, a velocidad superficial, y $\left(\frac{\Delta P}{L}\right)_{SG}$ es el gradiente de presión que tendría lugar si el gas estuviera fluyendo solo, a velocidad superficial. X puede ser también notada de la forma:

$$X = \left(\frac{V_{SL}}{V_{SG}}\right)^{7/8} \left(\frac{\rho_L}{\rho_G}\right)^{3/8} \left(\frac{\mu_L}{\mu_G}\right)^{1/8} \quad (18)$$

En esta ecuación X es una razón de velocidades dependiente de las propiedades de los fluidos. Esta correlación fue realizada con datos para tubería de 1 pulgada, pero Baker comparó estos datos con los de tuberías de diámetros mayores y encontró que los valores de holdup eran mayores.

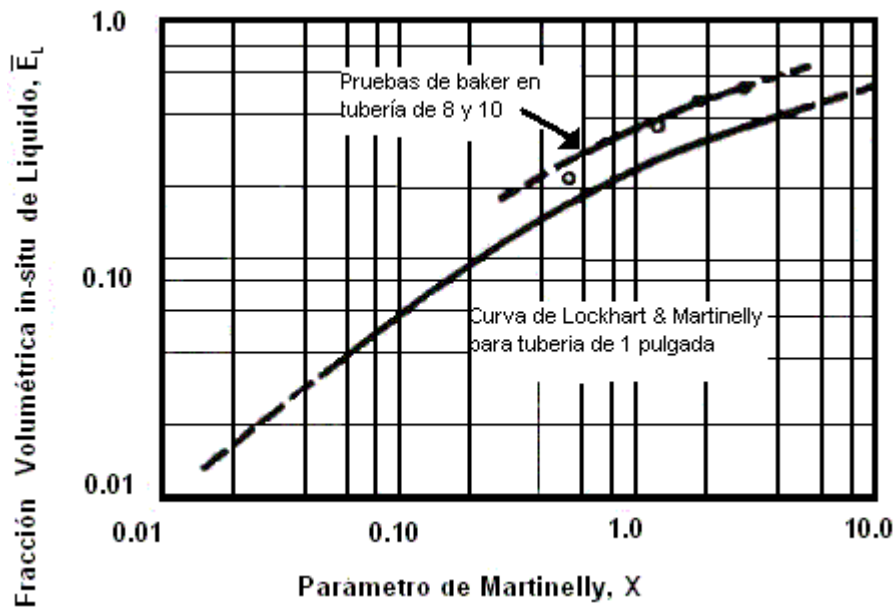


Figura 13. Correlación de Lockhart & Martinelli y las observaciones de Baker [4]

2.4.9. Correlación De Hughark & Pressburg

En el año de 1962 se desarrolló quizá la mejor correlación general para el holdup de mezclas Gas-Líquido, cubriendo un amplio arco de propiedades físicas y diámetros, inicialmente desarrollada para flujo en tubería vertical, demostró después ser útil también para flujo horizontal. Ellos desarrollaron una relación entre \bar{E}_G , la fracción volumétrica *in situ* promedio por unidad de volumen de la fase gaseosa, y una cantidad:

$$X' = 6 * 10^4 \left(\frac{V_{SL} \rho_L}{V_{SG} \rho_G} \right)^{0.9} \left(\frac{\mu_L^{0.19} \sigma^{0.205} \rho_G^{0.7} \mu_G^{2.75}}{G_M^{0.435} \rho_L^{0.72}} \right) \quad (19)$$

Donde $G_M = (V_{SL} \rho_L + V_{SG} \rho_G)$, la velocidad másica en $\text{lb}_m/\text{ft}^2 \cdot \text{sec}$, la μ y σ están en unidades de gr-cm-sec , y las densidades en lb_m/ft^3 .




Figura 14. Correlación de holdup para mezclas Gas-Líquido [4]

2.5. GRADIENTES DE PRESIÓN

Debido a efectos de gravedad, fricción y aceleración, se pueden producir pérdidas de energía en el sistema, que se verían reflejadas en la disminución de la presión. El procedimiento que se sigue para calcular la caída de presión en una tubería inclinada es el siguiente: se determina el patrón de flujo y el holdup asumiendo que la tubería es horizontal. El holdup hallado se corrige por el efecto de la inclinación con el fin de calcular la caída de presión posteriormente con alguno de los métodos que se plantean a continuación.

2.5.1. Correlación De Lockhart & Martinelli

Ellos basan su correlación en la premisa de que la caída de presión debe ser igual tanto para la fase líquida como para la fase gaseosa sin importar el patrón de flujo, con la condición que halla un delta de presión radial despreciable. Por medio de su trabajo, expresan la caída de presión en la fase líquida como sigue:

$$\left(\frac{\Delta P}{L}\right)_{lp} = 2f_L \left(\frac{\rho_L V_L^2}{D_L g}\right) \quad (20)$$

Donde D_L es el diámetro hidráulico equivalente de la región del tubo por la cual la fase líquida fluye. Igual ocurre con la fase gaseosa:

$$\left(\frac{\Delta P}{L}\right)_p = 2f_G \left(\frac{\rho_G V_G^2}{D_G g}\right) \quad (21)$$




Figura 15. Relaciones de Lockhart-Martinelli [5]

Baker ha realizado unas modificaciones a la correlación de Lockhart & Martinelli para tuberías de mayor diámetro, esta nueva correlación es expresada para cada patrón de flujo.

Patrón de Flujo	Correlación
Estratificado	$\phi_G = \frac{15400X}{G_{SL}^{0.8}}$
Burbujas Elongadas	$\phi_G = \frac{27.315X^{0.855}}{G_{SL}^{0.17}}$
Burbujas Dispersas	$\phi_G = \frac{14.2X^{0.75}}{G_{SL}^{0.1}}$
Bache	$\phi_G = \frac{1190X^{0.815}}{G_{SL}^{0.5}}$
Niebla Anular	$\phi_G = (4.8 - 0.3125D)X^{0.343-0.021D}$

Tabla 4. Correlaciones para cada patrón de flujo según Baker

Donde G_{SL} es la tasa de flujo másico superficial del líquido en $\text{lb}_m/\text{ft}^2 \cdot \text{hr}$. No existe una ecuación para el flujo ondulado. Por último, hay que tener en cuenta que las relaciones se aplican cuando el número de Reynolds superficial para cada fase supera 1000.

2.5.2. Correlación De Dukler, Wicks & Cleveland

En 1964 presentaron un estudio estadístico en el que analizaban varias de las correlaciones existentes en el momento, comparando su desempeño y concluyeron que aunque la de Lockhart & Martinelli tenía la mejor concordancia de todas, aún le faltaba para tener una buena consistencia. Debido a esto desarrollaron una nueva correlación para la caída de presión por fricción en el flujo bifásico. Se parte de la premisa de que el holdup es finito y constante, se supone la mezcla homogénea de las fases, en la que no hay deslizamiento de una sobre otra, y el resultado de esta correlación fue estadísticamente superior a las anteriormente estudiadas por ellos.

El gradiente de presión debido a la fricción es expresado como:

$$\frac{\Delta P}{L} = \frac{2G_M^2 f_{ipM}}{g_c D \rho_M} \quad (22)$$

Donde:

$$f_{ipM} = F \beta f \quad (23)$$

$$f = 0.0014 + 0.125 \text{Re}_M^{-0.32} \quad (24)$$

$$\text{Re}_M = \frac{DG_M}{\mu_M} \quad (25)$$

$$F = 1 + \frac{\gamma}{1.281 - 0.478\gamma + 0.444\gamma^2 - 0.094\gamma^3 + 0.00843\gamma^4} \quad (26)$$

$$\gamma = -\ln C_L \quad (27)$$

$$G_M = \rho_m * v_m \quad (28)$$

$$\beta = \frac{\rho_L C_L^2}{\rho_M \overline{E}_L} + \frac{\rho_G (1 - C_L)^2}{\rho_M \overline{E}_G} \quad (29)$$

En la ecuación de gradiente de presión, F es adimensional y esta en función de C_L , la fracción volumétrica del líquido en la corriente de entrada (Figura 16). El cálculo del factor β requiere conocer el valor de \overline{E}_G la fracción de gas *in situ*. Para esto, Dukler uso la correlación de Hughmark y ilustrada.

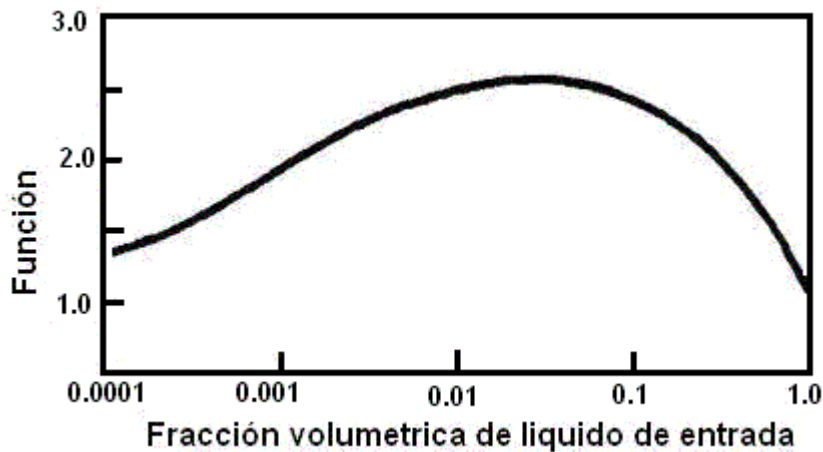


Figura 16. Función de Dukler, Wicks & Cleveland [5]

2.5.3. Método De Beggs & Brill

El método diseñado por Beggs y Brill es el más aplicado para el cálculo del gradiente de presión, ya sea para pozo vertical, direccional, tubería horizontal o inclinada. Para este cálculo es necesario conocer dos parámetros iniciales: el holdup y el patrón de flujo. Éste fue el primer modelo en proponer un procedimiento matemático para predecir de forma sistemática los patrones de flujo.

Para determinar el patrón de flujo se requiere de algunos cálculos con números adimensionales (como el número de Froude para dos fases) y además establecer límites entre los patrones de flujo.

Se necesitan las siguientes variables para determinar cualquier patrón de flujo:

$$N_{FR} = \frac{V_m^2}{gd} \quad (30)$$

$$\lambda_l = \frac{V_{sl}}{V_m} \quad (31)$$

$$L_1 = 316\lambda_L^{0.302} \quad (32)$$

$$L_2 = 0.0009252\lambda_L^{-2.4684} \quad (33)$$

$$L_3 = 0.10\lambda_L^{-1.4516} \quad (34)$$

$$L_4 = 0.5\lambda_L^{-6.738} \quad (35)$$

Los límites de patrones de flujo según Beggs y Brill para flujo horizontal son:

Patrón de Flujo	Límites
<i>Segregado</i>	$\lambda_L < 0.01$ y $N_{FR} < L_1$ ó $\lambda_L > 0.02$ y $N_{FR} < L_2$
<i>Transición</i>	$\lambda_L > 0.01$ y $L_2 < N_{FR} < L_3$
<i>Intermitente</i>	$0.01 < \lambda_L < 0.4$ y $L_3 < N_{FR} < L_1$ ó $\lambda_L > 0.4$ y $L_3 < N_{FR} < L_4$
<i>Distribuido</i>	$\lambda_L < 0.4$ y $N_{FR} > L_1$ ó $\lambda_L > 0.4$ y $N_{FR} > L_4$

Tabla 5. Límites para los patrones de flujo según Beggs & Brill

Cabe aclarar que el método de Beggs y Brill permite determinar el patrón de flujo, pero no el régimen de flujo, para lo cual se debe relacionar con otros regímenes de flujo como el de Mandhane, Taitel y Dukler o el de Baker.

Habiendo calculado el patrón de flujo, se utiliza la fórmula correspondiente para el cálculo del holdup, tratada en la sección 2.4.7. Después se procede a determinar:

(36)

$$(\Delta P)_T = (\Delta P)_G + (\Delta P)_F + (\Delta P)_A$$

Pérdidas por fricción:

$$(\Delta P)_F = \frac{f \rho_m V_m^2}{2D} \quad (37)$$

$$\frac{f}{f_N} = e^s \quad (38)$$

$$s = \frac{\text{Ln}(y)}{-0.0523 + 3.182 \text{Ln}(y) - 0.8725 [\text{Ln}(y)]^2 + 0.01853 [\text{Ln}(y)]^4} \quad (39)$$

$$y = \frac{\lambda_L}{H_L^2} \quad (40)$$

Si $1 < y < 1.2$ entonces:

$$s = \ln(2.2y - 1.2) \quad (41)$$

Pérdidas por gravedad

$$(\Delta P)_G = \rho_s g \quad (42)$$

$$\rho_s = \rho_l H_l + \rho_g H_g \quad (43)$$

Pérdidas por aceleración

$$(\Delta P)_A = \frac{\rho_s V_m V_{sg}}{P} \Delta P \quad (44)$$

También se puede definir la caída de presión de la siguiente manera:

$$(\Delta P)_T = \frac{(\Delta P)_F + (\Delta P)_G}{1 - E_K} \quad (45)$$

$$E_K = \frac{\rho_s V_m V_{sg}}{P} \quad (46)$$

Siendo P, la presión de entrada al tramo.

3. NEURAL ANALYZER (NEURALYZER V1.0)

3.1. ORIGEN DE LA IDEA

La propuesta del proyecto nació en parte por el vacío existente en la literatura local acerca del análisis del flujo multifásico apoyado con métodos de inteligencia artificial y debido a la necesidad de encontrar un modelo más adecuado para la determinación del patrón de flujo.

Dado el inicial desconocimiento del campo de acción que requería la realización de un análisis previo a la aplicación, se comienza el estudio del mismo con dos papers publicados por Beggs, Brill y Arirachakaran [6] que indicaron el camino a seguir para ahondar, primero en la idea de lo que es un flujo multifásico y las variables asociadas a él. Después de realizar una revisión, incluyendo bases de datos, como la de la SPE, de la literatura internacional y local acerca del tema se procede a revisar qué se ha hecho en éste, apoyándose en la inteligencia artificial, concretamente en el de las RNA. En este punto se encuentra a Mohaghegh como uno de los líderes actuales en su estudio, por lo tanto son de valiosa ayuda los papers publicados por él en la SPE¹³ [7], además de otros artículos que aportaron también al estado del arte¹⁴.

Resultó interesante encontrar que, a pesar de los buenos resultados que han tenido las RNA y en general la inteligencia artificial en varios campos de la industria, incluyendo la del petróleo, sólo recientemente han surgido investigaciones que intentan ampliar más la experiencia en estas (Figura 17).




Figura 17. Evolución del número de referencias (miles) a las redes neuronales en la literatura¹⁵

¹³ Shahab Mohaghegh. *Recent Developments in Application of Artificial Intelligence in Petroleum*. SPE, West Virginia U. and Intelligent Solutions Inc. April 2005

¹⁴ Véanse los libros 8-25. de la bibliografía.

¹⁵ Tomado de <http://www.cs.berkeley.edu/~russell/aima-bib.html> Consultado el 15 de septiembre del 2006.

3.2. ANÁLISIS

Después de organizar y estudiar toda la información recopilada hasta ese momento, se procede a realizar una nueva revisión dentro de las tesis realizadas en esta área con anterioridad en la UIS¹⁶, para enriquecer la visión de la idea y tener la seguridad de no estar repitiendo la investigación.

Las generalidades de los conceptos que fueron recogidos y estudiados para la realización del proyecto, se publicaron en el capítulo 1 y 2 de este libro, aquí se reúnen nociones de flujo multifásico, de holdup o colgamiento, de sus parámetros, de las correlaciones más importantes realizadas hasta la fecha, generalidades acerca de redes neuronales artificiales, de las redes que fueron implementadas en Neuralyzer v1.0, como son la PMC y la base radial.

Para realizar la aplicación, se propone un modelo de desarrollo en cascada, consistente en recolección de requerimientos, el posterior análisis de cada uno de estos, el diseño de la aplicación, construcción e implementación, para lo cual se eligió de antemano el lenguaje de programación Delphi[®], en su versión 7, que tiene grandes facilidades para la parte gráfica, componentes gratuitos que ayudan la construcción de software, además de contar ya con experiencia de programación en el mismo.

Para la recolección de requerimientos se buscó apoyo del Ingeniero de Petróleos Jairo Arrieta, con conocimientos en el área del transporte de fluidos por tubería, que orientó la investigación de la parte de flujo multifásico, y de los estudios realizados anteriormente con inteligencia artificial en ese campo. Para asesoría en la implementación de la algorítmia, así como para la realización del aplicativo, se contó con la ayuda del Ingeniero de Sistemas Juan Carlos Reyes, director del proyecto, con experiencia en el área de la inteligencia artificial, especialmente en redes neuronales artificiales y lógica difusa.

3.3. DISEÑO

Siendo el objetivo principal del software apoyar un proceso de determinación, se decide, inicialmente, por el diseño de un constructor/simulador de PMC, ampliando después la idea para las redes de función de base radial. Madurando más el concepto, se llega a la conclusión final de ayudar, mediante un editor de RNA, al análisis, de datos que al ser sometidos para el entrenamiento de una red previamente definida sean generalizados con el fin de lograr la clasificación/predicción de los mismos.

Un requerimiento extra, que ofrece un valor agregado es el de la generación de reportes y la creación de imágenes 2D. También se incluyó dentro del desarrollo de la

¹⁶ Véanse los libros 4,5,10-14 de la Bibliografía.

aplicación, la posibilidad para el usuario de normalizar datos de entrada/salida, esto último permite, realizado convenientemente, que la red comprenda los datos con más facilidad.

La aplicación desarrollada deberá ser útil en la construcción, entrenamiento y simulación de redes de aprendizaje supervisado e híbrido¹⁷, por esta razón se implementan dos de los más utilizados algoritmos en la industria para la determinación de resultados en base a un entrenamiento con datos de muestra¹⁸.

3.4. DESARROLLO

En la construcción del algoritmo básico de aprendizaje del PMC, surgieron problemas, puesto que la RNA no aprendía correctamente o se quedaba en mínimos locales, por ello fue necesario implementar un algoritmo de mayor complejidad, que incluye un momento en la actualización de los pesos, así como la posibilidad de elegir variadas funciones de activación en las diferentes capas.

En el desarrollo del algoritmo de aprendizaje y creación de la red de base radial, se decidió por el uso del algoritmo K-Medias para encontrar los centroides de los grupos iniciales, así como la regla delta generalizada para hallar los pesos ideales de conexión entre la capa de salida y la capa oculta.

El editor ya finalizado, permite además crear una red con una serie de parámetros propuestos por el usuario, o generar varias redes sugeridas de prueba. Permite revisar los detalles de una red ya creada, cargar, borrar, guardar una red ya entrenada o en "blanco" para ser utilizada en Matlab®, Excel (como Macro), Delphi® y/o Kylix. Así mismo permite borrar redes, cargar datos de entrenamiento y para simulación desde archivos de texto externos.

3.4.1. Diagrama De Casos De Uso

Crear RNA	
Actor	Usuario
Propósitos	Crear una RNA.
Resumen	Por medio de este caso de uso el actor crea una RNA.
Flujo principal	<ol style="list-style-type: none"> 1. El actor especifica los parámetros de creación de la RNA. 2. El sistema crea la red neuronal de acuerdo a estos parámetros. 3. El sistema pone a disposición del usuario la RNA creada.

¹⁷ El aprendizaje híbrido comprende tanto aprendizaje supervisado como no supervisado en un mismo tipo de red, como lo es en el caso de la red de función de base radial.

¹⁸ Ver en el capítulo 2 de este libro las referencias a las variadas tareas que pueden realizar redes de este tipo.

	1a: El actor cancela el proceso El sistema regresa al módulo principal.
Precondición	Ninguna

Generar RNA Sugeridas	
Actor	Usuario
Propósitos	Producir una serie de RNA en base a parámetros suministrados.
Resumen	Por medio de este caso de uso el actor puede generar una serie de RNA sugeridas por el sistema de acuerdo a parámetros suministrados por él.
Flujo principal	1. El actor suministra los parámetros de creación. 2. El sistema genera las RNA de acuerdo a los parámetros. 3. El sistema pone a disposición del usuario las RNA creadas. 1a: El actor cancela el proceso El sistema regresa al módulo principal
Precondición	Ninguna

Cargar RNA	
Actor	Usuario
Propósitos	Cargar una RNA.
Resumen	Por medio de este caso de uso el actor puede cargar una RNA desde un archivo válido
Flujo principal	1. El actor selecciona la ubicación y el nombre del archivo. 2. El sistema crea una RNA de acuerdo a los datos almacenados en el archivo. 3. El sistema pone a disposición del usuario la RNA cargada. 1a: El actor selecciona un archivo no válido. El sistema cancela la operación y retorna al módulo principal. 1b: El actor cancela la operación. El sistema retorna al módulo principal.
Precondición	Ninguna

Guardar RNA	
Actor	Usuario
Propósitos	Almacenar una RNA en un archivo válido.
Resumen	Por medio de este caso de uso el actor puede guardar en un archivo la red seleccionada en cualquiera de los formatos disponibles.
Flujo principal	1. El actor selecciona la RNA a guardar. 2. El actor suministra el nombre y el tipo del archivo.

	3. El sistema guarda la RNA en un archivo válido 2a: El actor cancela la operación. El sistema retorna al módulo principal
Precondición	Debe haber por lo menos una RNA creada

Entrenar RNA	
Actor	Usuario
Propósitos	Entrenar una RNA de acuerdo a los datos de entrenamiento suministrados.
Resumen	Por medio de este caso de uso el actor puede entrenar la RNA seleccionada con los datos especificados.
Flujo principal	1. El actor selecciona la RNA. 2. El actor carga o introduce los datos de entrenamiento. 3. El actor configura los parámetros de entrenamiento. 4. El sistema entrena la RNA de acuerdo a los datos y parámetros suministrados.
Precondición	Debe haber por lo menos una RNA creada, unos datos de entrenamiento y unos parámetros válidos.

Simular RNA	
Actor	Usuario
Propósitos	Simular una RNA de acuerdo a los datos de simulación suministrados.
Resumen	Por medio de este caso de uso el actor puede simular la RNA seleccionada con los datos especificados.
Flujo principal	1. El actor selecciona la RNA. 2. El actor carga los datos de simulación. 3. El actor configura los parámetros de simulación. 4. El sistema simula la RNA de acuerdo a los datos y parámetros suministrados.
Precondición	Debe haber por lo menos una RNA creada, unos datos de simulación, y unos parámetros válidos.

Cambiar Nombre	
Actor	Usuario
Propósitos	Cambiar el nombre a una RNA.
Resumen	Por medio de este caso de uso el actor puede cambiar el nombre de la RNA seleccionada.
Flujo principal	1. El actor selecciona la RNA. 2. El actor suministra el nuevo nombre de la RNA. 3. El sistema cambia el nombre de la RNA seleccionada. 2a: El actor suministra el nombre de una RNA existente. El sistema cancela la operación y regresa al módulo principal.

	2b: El actor suministra un nombre no válido. El sistema cancela la operación y regresa al módulo principal.
Precondición	Debe existir por lo menos una RNA creada.

Clonar RNA	
Actor	Usuario
Propósitos	Clonar una RNA.
Resumen	Por medio de este caso de uso el actor puede crear una RNA exactamente igual a la seleccionada.
Flujo principal	<ol style="list-style-type: none"> 1. El actor selecciona la RNA. 2. El actor suministra el nombre de la nueva RNA. 3. El sistema crea una RNA exactamente igual a la seleccionada. 4. El sistema pone a disposición del actor la RNA clonada. <p>2a: El actor suministra el nombre de una RNA existente. El sistema cancela la operación y regresa al módulo principal.</p> <p>2b: El actor suministra un nombre no válido. El sistema cancela la operación y regresa al módulo principal.</p>
Precondición	Debe existir por lo menos una RNA creada.

Inicializar RNA	
Actor	Usuario
Propósitos	Inicializar una RNA.
Resumen	Por medio de este caso de uso el actor puede inicializar los pesos y/o centros de la RNA seleccionada.
Flujo principal	<ol style="list-style-type: none"> 1. El actor selecciona la RNA. 2. El sistema espera la confirmación por parte del actor. 3. El sistema inicializa la RNA seleccionada. <p>2a: El actor cancela la operación. El sistema regresa al módulo principal.</p>
Precondición	Debe existir por lo menos una RNA creada.

Eliminar RNA	
Actor	Usuario
Propósitos	Eliminar una RNA.
Resumen	Por medio de este caso de uso el actor puede eliminar la RNA seleccionada.
Flujo principal	<ol style="list-style-type: none"> 1. El actor selecciona la red. 2. El sistema espera la confirmación por parte del actor. 3. El sistema elimina la red de la lista. <p>2a: El actor cancela la operación.</p>

	El sistema regresa al módulo principal.
Precondición	Debe existir por lo menos una RNA creada.

Generar Reporte	
Actor	Usuario
Propósitos	Producir un reporte, en base a opciones seleccionadas por el actor.
Resumen	Por medio de este caso de uso el actor puede generar un reporte de acuerdo a las opciones seleccionadas por él.
Flujo principal	<ol style="list-style-type: none"> 1. El actor selecciona la RNA. 2. Entre las opciones disponibles, el actor escoge el contenido del reporte. 3. El actor suministra el nombre del reporte. 4. El sistema genera el reporte. <p>2a: El actor cancela la operación. El sistema regresa al módulo principal.</p> <p>3a: El actor cancela la operación. El sistema regresa al paso 2 del presente caso de uso.</p>
Precondición	Debe existir por lo menos una RNA creada.

Generar Gráficas	
Actor	Usuario
Propósitos	Producir una serie de gráficas en base a datos simulados.
Resumen	Por medio de este caso de uso el actor puede generar gráficas predefinidas producto de los datos simulados.
Flujo principal	<ol style="list-style-type: none"> 1. El actor selecciona la RNA. 2. El actor realiza una simulación exitosa de la RNA. 3. El sistema genera las gráficas de acuerdo a los datos simulados.
Precondición	Existencia de datos simulados, la RNA debe constar de 3 entradas y 4 salidas

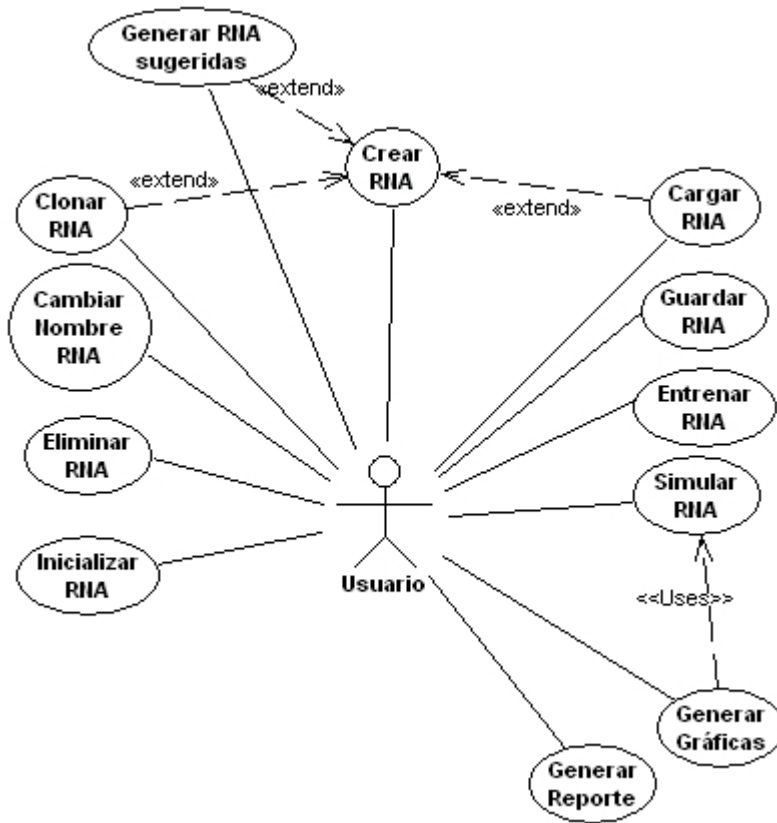


Figura 18. Diagrama de casos de uso

4. METODOLOGÍA

4.1. PLANTEAMIENTO DE LA METODOLOGÍA

Antes que cualquier RNA realice función alguna dentro de la aplicación para la cual fue construida, es vital tener la red adecuada, que varía según el tipo. Muchas de las personas que se inician en este campo recurren a una consecución y entrenamiento de las arquitecturas por ensayo y error, exponiéndose así a una posible equivocación. Es preferible tratar de ajustarse a un método, que designe los principales puntos a seguir para la escogencia de una red adecuada.

La metodología debe cubrir y especificar el tipo y el número de los ensayos, la cantidad de entradas, las variables de entrada del modelo, la cantidad de salidas, la interpretación de esas salidas, la cantidad de capas y las neuronas necesarias en cada una de estas, el criterio para definir una red como suficiente, ya sea por una tolerancia del error, por un número de iteraciones o por ciertos requisitos que durante el proceso se cumplen.

Por distintas experiencias ocurridas durante el ciclo de análisis, diseño y desarrollo del software, además de la guía que ofrecen nuestros tutores junto con la diferente literatura consultada, se ha llegado a una convergencia de pensamiento en cuanto a la metodología adecuada, una metodología que es intuitiva y que permite un hallazgo en varias etapas.

Teniendo ya en Neuralyzer v1.0 un aplicativo flexible que nos permite generar distintas arquitecturas dentro de las redes de tipo backpropagation y de función de base radial, disponemos a detallar el proceso para la consecución de una red adecuada, no solo para la determinación del patrón de flujo, sino que es útil para todas aquellas aplicaciones de clasificación/predicción en general. La metodología consta de los siguientes puntos (ver Figura 19)

- Adquisición de los datos, proceso de normalización
- Definir el número y el rango de entradas
- Definir el número y rango de las salidas
- Realizar normalización de las entradas/salidas de ser necesario
- Prueba de las diferentes arquitecturas
- Prueba para cada arquitectura con las redes sugeridas.
- Realizar una afinación en base a los resultados.

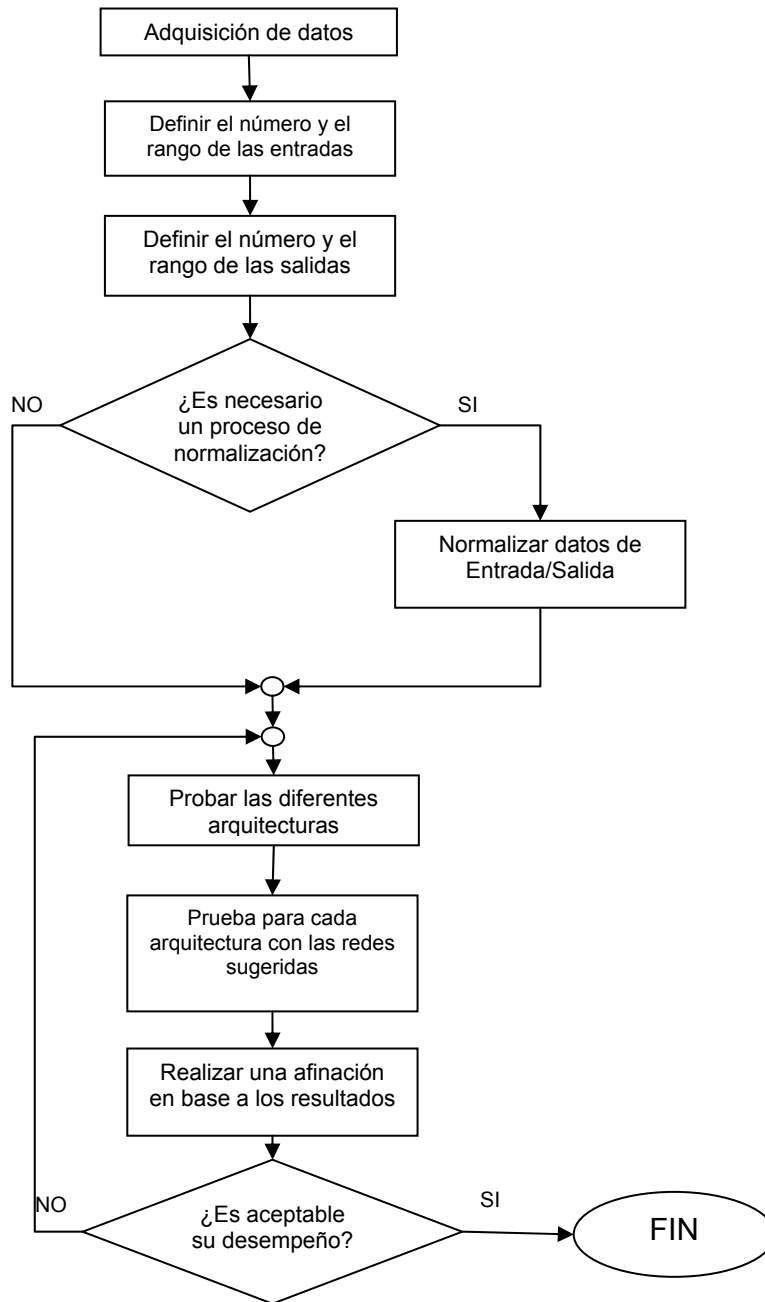


Figura 19. Diagrama de flujo para la consecución de una arquitectura de red adecuada.

4.1.1. Adquisición De Los Datos, Proceso De Normalización

Es muy frecuente que no se tenga a disposición todo el conjunto de datos que se quiere someter a estudio, sino sólo un subconjunto de estos. Como primera medida, se debe asegurar que éste es representativo, y que no presente sesgos relevantes que puedan perjudicar el entrenamiento. Por ejemplo, si el problema es de clasificación, en el conjunto de datos deben estar representadas todas las categorías, si es de predicción, se deben incluir valores continuos de todo el rango.

Hay que tener en cuenta en este punto que la RNA requiere alcanzar un grado de generalización, por lo tanto no debe aprender de memoria todos los casos, sino que teniendo algunos ejemplos de cada uno, sea capaz de determinar correctamente otro que no haya visto antes en base a los que le fueron mostrados durante su entrenamiento. Entendiendo por generalización la capacidad de la red de almacenar las características que le son comunes a todos los patrones que fueron usados en la etapa de entrenamiento.

Aplicando lo aconsejado por el método de validación cruzada¹⁹ (crossvalidation), el conjunto de datos que se escoja debe ser dividido en dos partes, una parte denominada *conjunto de entrenamiento* y otra llamada *conjunto de test*, es común que el conjunto de test sea aproximadamente el 10% del conjunto total. Como su nombre lo dice, el conjunto de entrenamiento es con el que la red supervisada realiza el aprendizaje, y el conjunto de test es con el que se simula la red para ver el grado de generalización, entre más bajo sea el error en este punto mejor ha generalizado la red. La mejor red no es la que tenga el más bajo error durante el entrenamiento, por esto hay que tener en cuenta en qué punto el error de validación pueda empezar a crecer, separándose del error de entrenamiento, a partir de ese punto se produce un sobre ajuste y la red aprende de memoria (ver Figura 21).

Unos de los usos más comunes dentro del procesamiento de los datos son:

- *Escalamiento*: se transforma el contenido de las variables dentro de un rango de 0 a 1.
- *Análisis de variables nominales*: Transformación de un valor categórico a un valor numérico.

¹⁹ Introducido por T. M. Cover. *Learning in pattern recognition*. In Satoshi Watanabe, editor, *Methodologies of Pattern Recognition*, paginas 111-132. Academic press, New York, 1969).

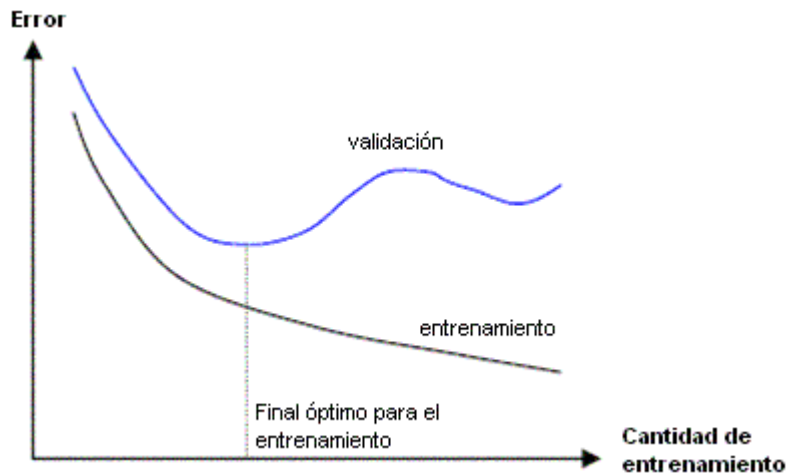


Figura 20. Error en el entrenamiento y error durante la validación

4.1.2. Definir El Número Y El Rango De Entradas/Salidas

El procesamiento (ver Figura 21) tanto de los datos de entrada como los de salida es importante para evitar traumatismos en los pasos de construcción de la arquitectura adecuada, ahorrando horas de trabajo y costos computacionales, así como mejoras en la calidad de las interpretaciones de los mismos.

A continuación las principales recomendaciones a tener en cuenta para las variables de entrada/salida:

- Realizar una definición previa de las variables, (continuas y discretas).
- Hay que evitar el uso de valores continuos para representar conceptos simbólicos, por ejemplo la representación de los animales.
- No representar los meses del año del 1 al 12, categorizar de otra manera.
- No confundir las entradas continuas con las entradas discretas, estado civil es discreto (1 o 0), mientras que la temperatura es continua (0, 10, 15.5, 30,40.2...).
- No mezclar escalas (kilogramos con toneladas, metros con kilómetros, años con meses...).
- Evitar las variables con altas variaciones (máximos y mínimos), si es necesario normalizarlas.
- Usar como patrones de entrada los diferentes periodos en que puedan afectar la salida (si es por meses, el promedio de cada mes y no los datos de cada mes).

- Entre mayor sea el número de entradas, más casos de entrenamiento requiere, lo que puede conducir a arquitecturas complejas, altos costos computacionales y difícil interpretación de resultados.

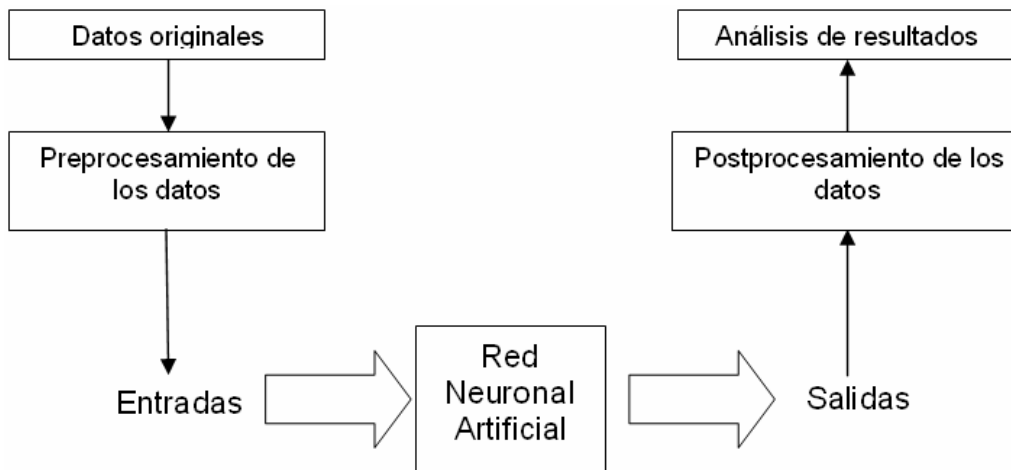


Figura 21. Proceso de los datos para la entrada/salida en una red neuronal.

4.1.3. Prueba De Las Diferentes Arquitecturas

Neuralyzer v1.0 otorga dos opciones de RNA para experimentar, PMC y de función de base radial, ambas son paralelas, es decir, lo que se implementa en backpropagation, se implementa en base radial, y viceversa. Aprovechando esta situación, es posible construir y probar modelos simultáneamente en ambos tipos de redes. Sometiéndolas a los posteriores análisis para observar cuál se comporta mejor.

Tanto el PMC como la de función de base radial presentan sus ventajas y desventajas, las principales son ilustradas en la Tabla 6. Por esta razón depende de la experiencia del usuario, así como la cantidad de datos disponibles y la calidad de los mismos.

CRITERIO	PMC con Backpropagation	BASE RADIAL
Tamaño	Menor o igual que la de función de base radial	Igual o mayor a la backpropagation
Costo computacional	Tiene menor costo computacional que la de base radial	Requiere una mayor cantidad de cálculos, al ser de mayor tamaño
Capas	Desde dos capas en adelante(aunque se aconseja que no sea mayor a 4)	Siempre 3, una capa de entrada, una oculta y una de salida

Aprendizaje	Supervisado	Hibrido (no supervisado en la capa oculta y supervisado en la capa de salida)
Entrenamiento	Hay que cuidar que no se sobre-ajuste la red	No hay problemas de sobre-ajuste

Tabla 6. Comparación del PMC con la de función de base radial

4.1.4. Prueba Para Cada Arquitectura Con Las Redes Sugeridas

4.1.4.1 Para PMC Con Algoritmo Backpropagation

Al igual que se ha dicho que la red con el error más bajo durante el entrenamiento no siempre es la que mejor se desempeña, así mismo se puede decir, con los PMC, a que la red más grande no es la que mejor aprende. La determinación de las neuronas adecuadas y de las capas adecuadas debe estar de acuerdo a previos estudios del desempeño que han tenido cada una de las arquitecturas, por esta razón, es recomendable, en el caso de los PMC, que se construyan diversos prototipos de redes, con algunos criterios de guía para su construcción:

- Asumir que el número de neuronas en la capa oculta sean menos de la mitad de la suma del número de entradas más el de las salidas.
- Con tres capas las redes backpropagation aproximan la mayoría de las funciones, con cuatro se estima que las aproxima todas, por lo tanto no es aconsejable que utilice más de cuatro capas.
- Ya sabe que el número de neuronas en la capa de entrada es igual a las entradas, y que el número de neuronas en la capa de salida es igual a las salidas, por lo tanto puede tener en cuenta la regla $N > W/E$, donde N es la cantidad de ejemplos de entrenamiento, W la cantidad de nodos ocultos y E el error deseado.
- La tasa de aprendizaje varia comúnmente entre 0.01 y 10, pero la más usada es 0.1

4.1.4.2 Para Base Radial

Para la red de función de base radial los criterios varían. Este tipo de red no sufre de sobreentrenamiento, pero tiene mayor costo computacional, requiere mayor número de neuronas que el PMC para realizar la misma labor, sin embargo su aprendizaje es más rápido.

Se presenta la “maldición de la dimensionalidad” que indica que el tamaño de la red aumenta exponencialmente con respecto a los casos que debe resolver. Cuando sea

posible se recomienda colocar tantas neuronas en la capa oculta como ejemplos de entrenamiento hayan, sin embargo, debido a que la cantidad de ejemplos puede llegar a ser considerable se debe tener cuidado al construir una red de tamaño excesivo, por que su entrenamiento puede llegar a ser inviable.

4.1.5. Realizar Una Afinación En Base A Los Resultados

Teniendo ya preseleccionadas un número razonable de redes, usualmente 10 redes entre uno u otro tipo, y teniendo ya claro cuáles requisitos mínimos debe cumplir la red o redes ganadoras, se comienza el proceso de afinación, que consiste en realizar variaciones relativamente pequeñas alrededor de los parámetros de cada red, número de neuronas, tasa de aprendizaje, número de iteraciones, con el fin de encontrar una que se ajuste aún mejor que las que ya existían. Este proceso es iterativo, y termina cuando se cumplan los requisitos propuestos para la red.

4.2. APLICACIÓN DE LA METODOLOGÍA

La determinación del patrón de flujo con ayuda de una red neuronal, sirve de caso de estudio para poner en práctica la metodología que permita descubrir que arquitectura es la que más se adapta a este fin.

4.2.1. Adquisición De Datos

El total del conjunto de datos que se poseen para realizar el estudio provienen de casos de estudio hipotéticos obtenidos de la literatura. Los datos poseen la información de las variables de la Tabla 7:

VARIABLE	NOMBRE	UNIDADES
qosc	Caudal de aceite	BOPD
qwsd	Caudal de agua	BWPD
qgsc	Caudal de gas	SCFD
T	Temperatura en cabeza	°F
P	Presión promedio del fluido en el segmento de tubería	Psia
Sal	Salinidad del agua	Ppm
Gg	Gravedad específica del gas libre	Adimensional
Tsep	Temperatura	°F

	en el separador	
Gsep	Gravedad especifica del gas en el separador	Adimensional
Psep	Presión en el separador	Psia
API	Gravedad API del aceite a 60°F	API

Tabla 7. Variables pertenecientes al conjunto de datos

A estos datos se les realiza un tratamiento para llegar a definir un patrón de flujo consistente, con el fin de reunir ejemplos para el entrenamiento, prueba y verificación, esta determinación del patrón de flujo se realizó con el método de Beggs & Brill, ya descrito, que propone cuatro patrones de flujo, distribuido, intermitente, segregado y transición. Para esto, el método se apoya en las velocidades superficiales de las fases denotadas como V_{so} , velocidad superficial del aceite, V_{sg} , velocidad superficial del gas y V_{sw} , velocidad superficial del agua. Puesto que estas variables son obtenidas después de una compleja sucesión de ecuaciones (ver Tabla 8), en las que se tienen en cuenta todos los parámetros que están contenidos en los datos iniciales, son elegidas para ser las variables de entrada a la red.

VARIABLE	MÉTODO DE CALCULO	AUTOR
Viscosidad Gas	Directo, correlación	Lee, Gonzáles y Eakin
Viscosidad Aceite	Directo, correlación	Andrade
Viscosidad Agua	Directo, correlación	McCain
Z gas	Directo, correlación	Standing
Densidad gas	Directo	Ecuación de estado
Densidad aceite	Directo, balance	Standing
Densidad agua	Directo, correlación	Beggs
Factor volumétrico del gas	Directo, correlación	Ecuación de estado
Factor volumétrico del aceite	Directo, correlación	Vasquez-Beggs, Standing
Velocidad superficial del liquido	Directo, ecuación	
Velocidad superficial del gas	Directo, ecuación	
Velocidad superficial de la mezcla	Directo, ecuación	
Numero de froude	Directo, correlación	

Tabla 8. Variables del patrón de flujo[20]

4.2.2. Definición De Entradas/Salidas

Teniendo como variables de entrada de la red las velocidades superficiales, se especifica el rango que van a manejar estas velocidades, que según los datos obtenidos tienen un valor máximo de 29 y un valor mínimo de 0, siendo un rango manejable, por no presentar valores extremos ni escala muy grande, se puede prescindir de la normalización.

Se procede a realizar un estudio de la salida de la red. La determinación del patrón de flujo en una tubería, es una cualificación que ilustra una distribución de las fases dentro de esta, por lo tanto la salida está en función del grado de pertenencia de la entrada a cada uno de los grupos predeterminados por el usuario. Dichos grupos, tomando como base el estudio de Beggs & Brill, son segregado, transición, intermitente y distribuido, que para efectos de representarlos en la salida de la red, pueden ser caracterizados de la manera que se ilustra en la Tabla 9.

PATRÓN DE FLUJO	REPRESENTACIÓN EN LA SALIDA			
	Salida 1	Salida 2	Salida 3	Salida 4
<i>Segregado</i>	1	0	0	0
<i>Transición</i>	0	1	0	0
<i>Intermitente</i>	0	0	1	0
<i>Distribuido</i>	0	0	0	1

Tabla 9. Representación de las salidas de la red neuronal

En total son 1500 datos en los cuales hay ejemplares de cada uno de los patrones propuestos por Beggs & Brill. Para la elección del conjunto de datos con los que se probará y entrenará la red se agruparon los datos de acuerdo a cada una de las clasificaciones, y se les ordenó de menor a mayor, según los valores, tomando una muestra aleatoria de los elementos a lo largo del cuerpo de datos. De este muestreo se recogieron en total 192 datos, cerca del 12.8% del total, de los cuales se asigna el 30% a testeo de la red y el otro 70% a entrenamiento.

4.2.3. Prueba De Las Diferentes Arquitecturas/Afinación De Redes

Una vez reunidos los datos de entrenamiento y prueba, se disponen los requisitos a superar por parte de la red o redes para que sean tenidas en cuenta como adecuadas, en esta oportunidad, el único requisito que se impone es que el error de generalización, que es medido con los datos de test, debe ser menor o igual al 5%.

4.2.3.1 Para PMC Con Algoritmo Backpropagation

Se procede a generar una serie de redes auto sugeridas, inicialmente bajo el modelo backpropagation. Se realizan 100 iteraciones con una tasa de 0.02 y un momento de 0.8, con el fin de observar cuales son las que tienen un descenso más pronunciado en

el error, se escogen las tres que tengan el error más bajo. A continuación se inicia un proceso iterativo, en el que tres ganadoras sufren pequeñas variaciones en el número de neuronas, sumando o restando 1 ó 2 neuronas a la capa oculta, aumentando o disminuyendo la tasa de aprendizaje en un factor de 10 y subiendo y bajando el momento en un factor de 10, en cada ciclo se escogen las mejores y se continúa el proceso. Una vez terminado este ciclo, se continúa el proceso, inicializando y entrenando completamente las redes.

Después de este proceso de búsqueda de la PMC más adecuada, se llega a una arquitectura, mostrada en la Figura 22, con 3 neuronas en la capa de entrada, 4 en la capa de salida y una capa oculta con solo 4 neuronas, para un error de entrenamiento de 2.82% y un error de generalización de 1.75% satisfaciendo el criterio de búsqueda.




Figura 22. Arquitectura final PMC para determinar el patrón de flujo

4.2.3.2 Para Base radial

A priori se sabe que la red de función de base radial de mejor comportamiento es la que tiene tantas neuronas en la capa oculta como casos de entrenamiento, por lo tanto se inicia la búsqueda con 3 neuronas en la capa de entrada, 135 neuronas en la capa oculta y 4 neuronas en la capa de salida.

En un proceso iterativo, hasta que se cumpla el criterio propuesto, se inicia con 10 redes idénticas, una tasa de aprendizaje con variaciones alrededor de 0.02, y escogiendo siempre las de mayor pendiente descendiente de error. Después de este proceso se obtiene una red con un error de entrenamiento de 1.23% y un error de generalización de 3.5% satisfaciendo el criterio de búsqueda. La arquitectura final se muestra en la

Figura 23.




Figura 23. Arquitectura final Base Radial para determinar el patrón de flujo

5. COMPARACIÓN Y GRÁFICOS

Para la realización de la comparación y los gráficos de la herramienta Neuralyzer v 1.0 se tomaron 10 pozos hipotéticos, con características individuales que se pueden apreciar en la Tabla 10, todas las tuberías de transporte, en este caso, son de 3 pulgadas.

Nombre	Gg	Gsep	Tsep	Psep	Sal	API	T	P
Pozo1	0.7858	0.7858	150	150	28000	20.5	99.5	75
Pozo2						13.8	93	77
Pozo3						19.8	113.2	150
Pozo4						21	97.6	133
Pozo5						23.4	103.4	111
Pozo6						21.4	97.6	89
Pozo7			21.8	123.4		113		
Pozo8			20.5	106.4		60		
Pozo9			21	118.1		60		
Pozo10			21	96.6		61		

Tabla 10. Propiedades de los pozos, según los parámetros requeridos en la Tabla 7

Para realizar el análisis de resultados, sólo se utilizará una red de las desarrolladas en el capítulo anterior, la que presentó mejor comportamiento de acuerdo a los porcentajes de error, que en este caso, es el PMC. Para realizar el comparativo con HYSYS 3.2, se realiza un modelo simple de tubería.




Figura 24. Diagrama del modelo realizado en HYSYS

5.1. POZO 1

Este pozo cuenta con 524 registros.



Figura 25. Porcentajes de presencia de los patrones en Pozo1




Figura 26. Historial de producción de Pozo1, y su relación con el patrón de flujo




Figura 27. Grafico de Velocidades de Pozo1, y su relación con el patrón de flujo

 TEAM LND Calgary, Alberta CANADA	Case Name: C:\Archivos de programa\Hyprotech\HYSYS 3.2\Cases\mixer.hsc			
	Unit Set: Field			
	Date/Time: Tue Jan 30 14:51:01 2007			
Pipe Segment: Tubería				
PROFILES				
Data				
Distance (ft)	Elevation (ft)		Increments	
0.0000	0.0000		5	
3.281e-007	0.0000			
Pipe Table				
Length (ft)	0.0000	6.562e-008	1.312e-007	1.969e-007
Elevation (ft)	0.0000	0.0000	0.0000	0.0000
Pressure (psia)	61.00	61.00	61.00	61.00
Temperature (F)	96.28	97.02	97.77	98.51
Heat Transferred (Btu/hr-ft)	---	-2.605e+010	-2.605e+010	-2.605e+010
Flow Regime	Transition	Transition	Transition	Transition
Liquid HoldUp	0.4638	0.4634	0.4631	0.4627
Friction Gradient (inH2O/ft)	6.550e-003	6.556e-003	6.562e-003	6.568e-003
Static Gradient (inH2O/ft)	0.0000	0.0000	0.0000	0.0000
Accel. Gradient (inH2O/ft)	2.958e-007	2.965e-007	2.973e-007	2.981e-007
Liq. Reynolds	8867	8911	8955	8999
Vap. Reynolds	5829	5825	5822	5818
Liquid Velocity (ft/s)	0.2057	0.2058	0.2058	0.2059
Vapour Velocity (ft/s)	1.023	1.025	1.026	1.028
Hyprotech Ltd.	HYSYS v3.2 (Build 5029)			Page 1 of 2
Licensed to: TEAM LND				

Figura 28. Reporte HYSYS de Simulación de Pozo1

Como se puede observar el resultado en ambas herramientas dio como resultado el patrón de flujo transición.

5.2. POZO2

Este pozo cuenta con 524 registros.




Figura 29. Porcentajes de presencia de los patrones en Pozo2




Figura 30. Historial de producción de Pozo2, y su relación con el patrón de flujo




Figura 31. Grafico de Velocidades de Pozo2, y su relación con el patrón de flujo

 TEAM LND Calgary, Alberta CANADA	Case Name:	C:\Archivos de programa\Hyprotech\HYSYS 3.2\Cases\mixer.hsc		
	Unit Set:	Field		
	Date/Time:	Tue Jan 30 18:32:52 2007		
Pipe Segment: Tubería				
PROFILES				
Data				
Distance (ft)	Elevation (ft)		Increments	
0.0000	0.0000		5	
3.281e-007	0.0000			
Pipe Table				
Length (ft)	0.0000	6.562e-008	1.312e-007	1.969e-007
Elevation (ft)	0.0000	0.0000	0.0000	0.0000
Pressure (psia)	77.00	77.00	77.00	77.00
Temperature (F)	82.67	96.14	109.6	123.1
Heat Transferred (Btu/hr-ft)	---	-3.299e+011	-3.312e+011	-3.331e+011
Flow Regime	Segregated	Segregated	Segregated	Segregated
Liquid HoldUp	0.4011	0.3955	0.3898	0.3838
Friction Gradient (inH2O/ft)	4.595e-003	4.673e-003	4.762e-003	4.863e-003
Static Gradient (inH2O/ft)	0.0000	0.0000	0.0000	0.0000
Accel. Gradient (inH2O/ft)	1.208e-007	1.264e-007	1.327e-007	1.397e-007
Liq. Reynolds	5604	6138	6691	7261
Vap. Reynolds	7930	7822	7736	7676
Liquid Velocity (ft/s)	0.1392	0.1401	0.1409	0.1418
Vapour Velocity (ft/s)	1.058	1.089	1.121	1.156
Hyprotech Ltd.	HYSYS v3.2 (Build 5029)			Page 1 of 2

Figura 32. Reporte HYSYS de Simulación de Pozo2

Como se puede observar el resultado en ambas herramientas dio como resultado el patrón de flujo segregado.

5.3. POZO3

Este pozo cuenta con 279 registros.



Figura 33. Porcentajes de presencia de los patrones en Pozo3




Figura 34. Historial de producción de Pozo3, y su relación con el patrón de flujo




Figura 35. Grafico de Velocidades de Pozo3, y su relación con el patrón de flujo

 TEAM LND Calgary, Alberta CANADA	Case Name: C:\Archivos de programa\Hyprotech\HYSYS 3.2\Cases\mixer.hsc			
	Unit Set: Field			
	Date/Time: Tue Jan 30 18:48:17 2007			
Pipe Segment: Tubería				
PROFILES				
Data				
Distance (ft)	Elevation (ft)		Increments	
0.0000	0.0000		5	
3.281e-007	0.0000			
Pipe Table				
Length (ft)	0.0000	6.562e-008	1.312e-007	1.969e-007
Elevation (ft)	0.0000	0.0000	0.0000	0.0000
Pressure (psia)	150.0	150.0	150.0	150.0
Temperature (F)	113.0	120.4	127.8	135.2
Heat Transferred (Btu/hr-ft)	---	-1.599e+011	-1.602e+011	-1.605e+011
Flow Regime	Transition	Transition	Transition	Transition
Liquid HoldUp	0.7808	0.7761	0.7713	0.7665
Friction Gradient (inH2O/ft)	1.495e-003	1.498e-003	1.502e-003	1.508e-003
Static Gradient (inH2O/ft)	0.0000	0.0000	0.0000	0.0000
Accel. Gradient (inH2O/ft)	4.648e-009	4.730e-009	4.818e-009	4.913e-009
Liq. Reynolds	6194	6555	6927	7311
Vap. Reynolds	3679	3655	3634	3615
Liquid Velocity (ft/s)	0.1269	0.1273	0.1277	0.1282
Vapour Velocity (ft/s)	0.2777	0.2820	0.2864	0.2909
Hyprotech Ltd.		HYSYS v3.2 (Build 5029)		Page 1 of 2
Licensed to: TEAM LND				

Figura 36. Reporte HYSYS de Simulación de Pozo3

Como se puede observar el resultado en ambas herramientas dio como resultado el patrón de flujo transición.

5.4. POZO4

Este pozo cuenta con 278 registros.



Figura 37. Porcentajes de presencia de los patrones en Pozo4




Figura 38. Historial de producción de Pozo4, y su relación con el patrón de flujo




Figura 39. Grafico de Velocidades de Pozo4, y su relación con el patrón de flujo

 TEAM LND Calgary, Alberta CANADA	Case Name: C:\Archivos de programa\Hyprotech\HYSYS 3.2\Cases\mixer hsc			
	Unit Set: Field			
	Date/Time: Tue Jan 30 18:59:54 2007			
Pipe Segment: Tubería				
PROFILES				
Data				
Distance (ft)	Elevation (ft)		Increments	
0.0000	0.0000		5	
3.281e-007	0.0000			
Pipe Table				
Length (ft)	0.0000	6.562e-008	1.312e-007	1.969e-007
Elevation (ft)	0.0000	0.0000	0.0000	0.0000
Pressure (psia)	133.0	133.0	133.0	133.0
Temperature (F)	97.08	107.7	118.2	128.8
Heat Transferred (Btu/hr-ft)	---	-7.316e+010	-7.355e+010	-7.404e+010
Flow Regime	Segregated	Segregated	Segregated	Segregated
Liquid HoldUp	0.4162	0.4116	0.4069	0.4022
Friction Gradient (inH2O/ft)	5.811e-004	5.851e-004	5.901e-004	5.961e-004
Static Gradient (inH2O/ft)	0.0000	0.0000	0.0000	0.0000
Accel. Gradient (inH2O/ft)	1.008e-009	1.037e-009	1.069e-009	1.105e-009
Liq. Reynolds	1537	1686	1843	2009
Vap. Reynolds	4998	4945	4899	4862
Liquid Velocity (ft/s)	3.906e-002	3.924e-002	3.942e-002	3.960e-002
Vapour Velocity (ft/s)	0.4051	0.4140	0.4232	0.4329
Hyprotech Ltd.	HYSYS v3.2 (Build 5029)			Page 1 of 2
Licensed to: TEAM LND				

Figura 40. Reporte HYSYS de Simulación de Pozo4

Como se puede observar el resultado en ambas herramientas dio como resultado el patrón de flujo segregado.

5.5. POZO5

Este pozo cuenta con 254 registros.



Figura 41. Porcentajes de presencia de los patrones en Pozo5




Figura 42. Historial de producción de Pozo5, y su relación con el patrón de flujo

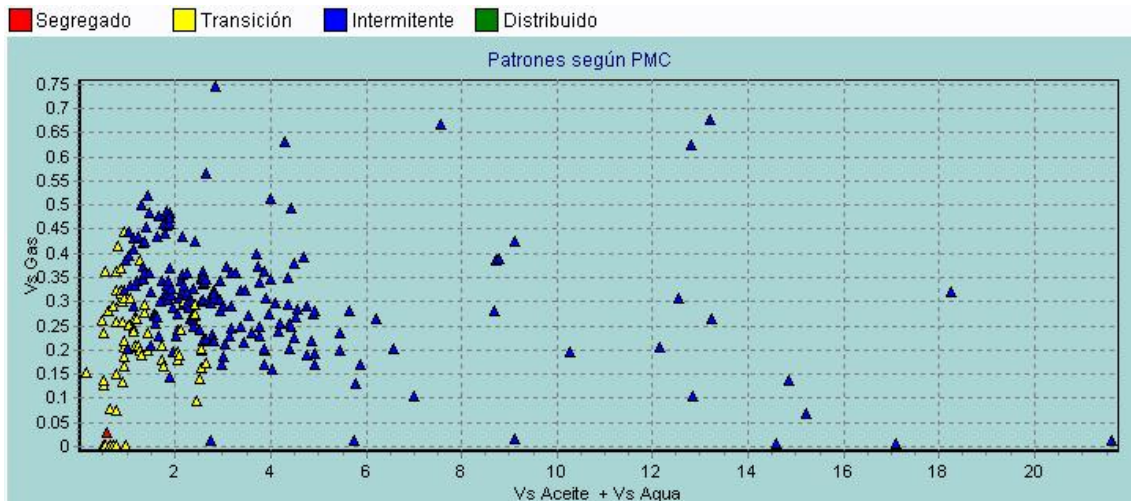


Figura 43. Grafico de Velocidades de Pozo5, y su relación con el patrón de flujo


 TEAM LND Calgary, Alberta CANADA	Case Name: C:\Archivos de programa\Hyprotech\HYSYS 3.2\Cases\mixer.hsc			
	Unit Set: Field			
	Date/Time: Tue Jan 30 19:08:51 2007			
Pipe Segment: Tubería				
PROFILES				
Data				
Distance (ft)	Elevation (ft)		Increments	
0.0000	0.0000		5	
3.281e-007	0.0000			
Pipe Table				
Length (ft)	0.0000	6.562e-008	1.312e-007	1.969e-007
Elevation (ft)	0.0000	0.0000	0.0000	0.0000
Pressure (psia)	111.0	111.0	111.0	111.0
Temperature (F)	103.0	112.4	112.8	131.2
Heat Transferred (Btu/hr-ft)	---	-6.753e+011	-6.774e+011	-6.800e+011
Flow Regime	Transition	Transition	Transition	Transition
Liquid HoldUp	0.3561	0.3522	0.3484	0.3444
Friction Gradient (inH2O/ft)	2.978e-002	3.020e-002	3.064e-002	3.112e-002
Static Gradient (inH2O/ft)	0.0000	0.0000	0.0000	0.0000
Accel. Gradient (inH2O/ft)	3.313e-006	3.426e-006	3.547e-006	3.677e-006
Liq. Reynolds	1.833e+004	1.935e+004	2.038e+004	2.143e+004
Vap. Reynolds	2.241e+004	2.222e+004	2.205e+004	2.192e+004
Liquid Velocity (ft/s)	0.4248	0.4266	0.4285	0.4304
Vapour Velocity (ft/s)	2.214	2.258	2.304	2.352
Hyprotech Ltd.	HYSYS v3.2 (Build 5029)			Page 1 of 2

Figura 44. Reporte HYSYS de Simulación de Pozo5

En esta oportunidad, y causado probablemente por las tasas cercanas a límites entre transición e intermitente, el resultado de simulación de HYSYS (transición) difiere del resultado arrojado por la red (intermitente).

5.6. POZO6

Este pozo cuenta con 234 registros.




Figura 45. Porcentajes de presencia de los patrones en Pozo6




Figura 46. Historial de producción de Pozo6, y su relación con el patrón de flujo

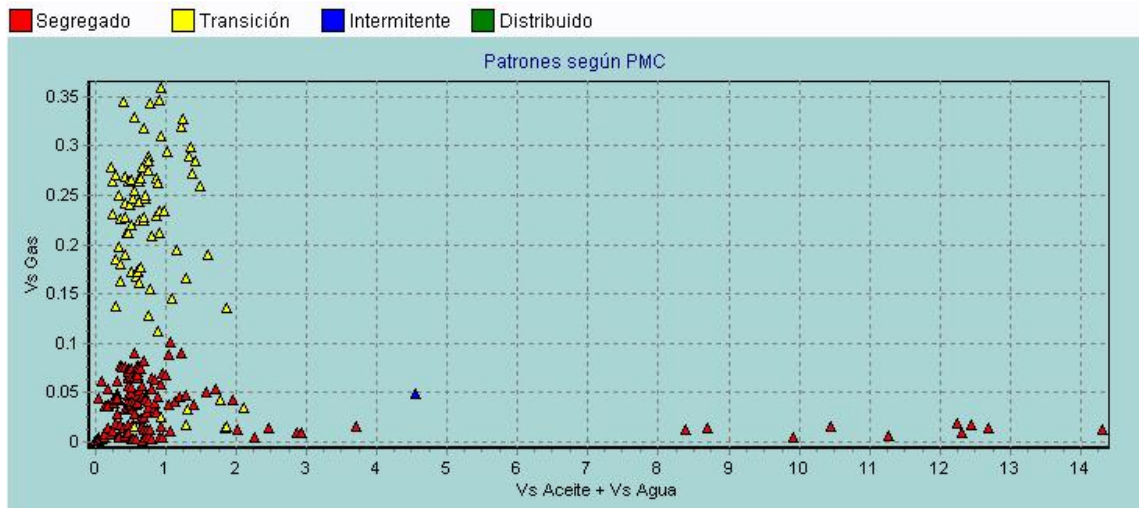


Figura 47. Grafico de Velocidades de Pozo6, y su relación con el patrón de flujo

 TEAM LND Calgary, Alberta CANADA	Case Name: C:\Archivos de programa\Hyprotech\HYSYS 3.2\Cases\mixer.hsc			
	Unit Set: Field			
	Date/Time: Tue Jan 30 19:31:07 2007			
Pipe Segment: Tubería				
PROFILES				
Data				
Distance (ft)	Elevation (ft)		Increments	
0.0000	0.0000		5	
3.281e-007	0.0000			
Pipe Table				
Length (ft)	0.0000	6.562e-008	1.312e-007	1.969e-007
Elevation (ft)	0.0000	0.0000	0.0000	0.0000
Pressure (psia)	89.00	89.00	89.00	89.00
Temperature (F)	96.79	107.4	118.1	128.7
Heat Transferred (Btu/hr-ft)	---	-1.027e+011	-1.036e+011	-1.047e+011
Flow Regime	Segregated	Segregated	Segregated	Segregated
Liquid HoldUp	0.2862	0.2828	0.2792	0.2755
Friction Gradient (inH2O/ft)	1.645e-003	1.668e-003	1.695e-003	1.725e-003
Static Gradient (inH2O/ft)	0.0000	0.0000	0.0000	0.0000
Accel. Gradient (inH2O/ft)	1.379e-008	1.431e-008	1.488e-008	1.552e-008
Liq. Reynolds	2237	2444	2663	2891
Vap. Reynolds	7802	7730	7672	7631
Liquid Velocity (ft/s)	5.403e-002	5.428e-002	5.452e-002	5.476e-002
Vapour Velocity (ft/s)	0.9420	0.9637	0.9866	1.011
Hyprotech Ltd.		HYSYS v3.2 (Build 5029)		Page 1 of 2
Licensed to: TEAM LND				

Figura 48. Reporte HYSYS de Simulación de Pozo6

Como se puede observar el resultado en ambas herramientas dio como resultado el patrón de flujo segregado.

5.7. POZO7

Este pozo cuenta con 238 registros.




Figura 49. Porcentajes de presencia de los patrones en Pozo7




Figura 50. Historial de producción de Pozo7, y su relación con el patrón de flujo




Figura 51. Grafico de Velocidades de Pozo7, y su relación con el patrón de flujo


 TEAM LND Calgary, Alberta CANADA		Case Name: C:\Archivos de programa\Hyprotech\HYSYS 3.2\Cases\mixer.hsc		
		Unit Set: Field		
		Date/Time: Tue Jan 30 19:48:12 2007		
Pipe Segment: Tubería				
PROFILES				
Data				
Distance (ft)	Elevation (ft)		Increments	
0.0000	0.0000		5	
3.281e-007	0.0000			
Pipe Table				
Length (ft)	0.0000	6.562e-008	1.312e-007	1.969e-007
Elevation (ft)	0.0000	0.0000	0.0000	0.0000
Pressure (psia)	113.0	113.0	113.0	113.0
Temperature (F)	122.8	128.2	133.7	139.1
Heat Transferred (Btu/hr-ft)	---	-1.230e+011	-1.234e+011	-1.238e+011
Flow Regime	Segregated	Segregated	Segregated	Segregated
Liquid HoldUp	0.4451	0.4426	0.4400	0.4374
Friction Gradient (inH2O/ft)	3.463e-003	3.492e-003	3.521e-003	3.552e-003
Static Gradient (inH2O/ft)	0.0000	0.0000	0.0000	0.0000
Accel. Gradient (inH2O/ft)	4.529e-008	4.620e-008	4.715e-008	4.815e-008
Liq. Reynolds	5731	5858	5985	6112
Vap. Reynolds	8314	8283	8257	8235
Liquid Velocity (ft/s)	0.1331	0.1335	0.1338	0.1342
Vapour Velocity (ft/s)	0.8558	0.8660	0.8765	0.8874
Hyprotech Ltd		HYSYS v3.2 (Build 5029)		Page 1 of 2
Licensed to: TEAM LND				

Figura 52. Reporte HYSYS de Simulación de Pozo7

Como se puede observar el resultado en ambas herramientas dio como resultado el patrón de flujo segregado.

5.8. POZO8

Este pozo tiene 241 registros.



Figura 53. Porcentajes de presencia de los patrones en Pozo8




Figura 54. Historial de producción de Pozo8, y su relación con el patrón de flujo




Figura 55. Grafico de Velocidades de Pozo8, y su relación con el patrón de flujo

 TEAM LND Calgary, Alberta CANADA	Case Name:	C:\Archivos de programa\Hyprotech\HYSYS 3.2\Cases\mixer.hsc		
	Unit Set:	Field		
	Date/Time:	Tue Jan 30 19:59:09 2007		
Pipe Segment: Tubería				
PROFILES				
Data				
Distance (ft)	Elevation (ft)		Increments	
0.0000	0.0000		5	
3.281e-007	0.0000			
Pipe Table				
Length (ft)	0.0000	6.562e-008	1.312e-007	1.969e-007
Elevation (ft)	0.0000	0.0000	0.0000	0.0000
Pressure (psia)	60.00	60.00	60.00	60.00
Temperature (F)	106.2	114.9	123.7	132.5
Heat Transferred (Btu/hr-ft)	---	-4.292e+011	-4.301e+011	-4.313e+011
Flow Regime	Transition	Transition	Transition	Transition
Liquid HoldUp	0.5351	0.5300	0.5248	0.5192
Friction Gradient (inH2O/ft)	8.763e-003	8.871e-003	8.988e-003	9.115e-003
Static Gradient (inH2O/ft)	0.0000	0.0000	0.0000	0.0000
Accel. Gradient (inH2O/ft)	4.890e-007	5.052e-007	5.228e-007	5.423e-007
Liq. Reynolds	1.115e+004	1.146e+004	1.180e+004	1.213e+004
Vap. Reynolds	5021	4995	4977	4971
Liquid Velocity (ft/s)	0.2898	0.2911	0.2925	0.2938
Vapour Velocity (ft/s)	0.9234	0.9423	0.9625	0.9844
Hyprotech Ltd.	HYSYS v3.2 (Build 5029)			Page 1 of 2
Licensed to: TEAM LND				

Figura 56. Reporte HYSYS de Simulación de Pozo8

Como se puede observar el resultado en ambas herramientas dio como resultado el patrón de flujo transición.

5.9. POZO9

Este pozo cuenta con 234 registros.



Figura 57. Porcentajes de presencia de los patrones en Pozo9

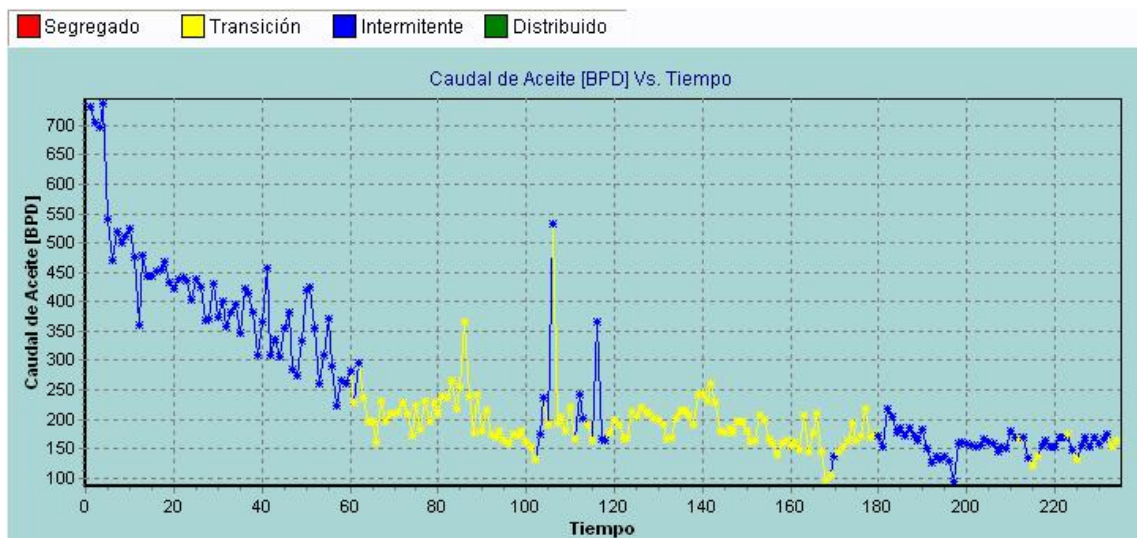


Figura 58. Historial de producción de Pozo9, y su relación con el patrón de flujo




Figura 59. Grafico de Velocidades de Pozo9, y su relación con el patrón de flujo

 HYPROTECH <small>LIFECYCLE INNOVATION</small>	TEAM LND Calgary, Alberta CANADA	Case Name: C:\Archivos de programa\Hyprotech\HYSYS 3.2\Cases\mixer.hsc Unit Set: Field Date/Time: Tue Jan 30 20:10:23 2007		
	Pipe Segment: Tubería			
	PROFILES			
Data				
Distance (ft)	Elevation (ft)	Increments		
0.0000	0.0000	5		
3.281e-007	0.0000			
Pipe Table				
Length (ft)	0.0000	6.562e-008	1.312e-007	1.969e-007
Elevation (ft)	0.0000	0.0000	0.0000	0.0000
Pressure (psia)	60.00	60.00	60.00	60.00
Temperature (F)	117.9	124.3	130.7	137.1
Heat Transferred (Btu/hr-ft)	---	-8.002e+011	-8.012e+011	-8.025e+011
Flow Regime	Intermittent	Intermittent	Intermittent	Intermittent
Liquid HoldUp	0.5057	0.5032	0.5007	0.4979
Friction Gradient (inH2O/ft)	3.848e-002	3.880e-002	3.915e-002	3.953e-002
Static Gradient (inH2O/ft)	0.0000	0.0000	0.0000	0.0000
Accel. Gradient (inH2O/ft)	7.570e-006	7.757e-006	7.961e-006	8.183e-006
Liq. Reynolds	3.820e+004	4.000e+004	4.174e+004	4.351e+004
Vap. Reynolds	6510	6500	6497	6503
Liquid Velocity (ft/s)	0.7398	0.7420	0.7442	0.7465
Vapour Velocity (ft/s)	1.237	1.257	1.279	1.302
Hyprotech Ltd.	HYSYS v3.2 (Build 5029)		Page 1 of 2	
Licensed to: TEAM LND				

Figura 60. Reporte HYSYS de Simulación de Pozo9

Como se puede observar el resultado en ambas herramientas dio como resultado el patrón de flujo segregado.

5.10. POZO10

Este pozo cuenta con 232 registros.



Figura 61. Porcentajes de presencia de los patrones en Pozo10




Figura 62. Historial de producción de Pozo10, y su relación con el patrón de flujo




Figura 63. Grafico de Velocidades de Pozo10, y su relación con el patrón de flujo

 TEAM LND Calgary, Alberta CANADA	Case Name: C:\Archivos de programa\Hyprotech\HYSYS 3.2\Cases\mixer.hsc			
	Unit Set: Field			
	Date/Time: Tue Jan 30 20:16:16 2007			
Pipe Segment: Tubería				
PROFILES				
Data				
Distance (ft)	Elevation (ft)		Increments	
0.0000	0.0000		5	
3.281e-007	0.0000			
Pipe Table				
Length (ft)	0.0000	6.562e-008	1.312e-007	1.969e-007
Elevation (ft)	0.0000	0.0000	0.0000	0.0000
Pressure (psia)	61.00	61.00	61.00	61.00
Temperature (F)	96.33	97.07	97.80	98.53
Heat Transferred (Btu/hr-ft)	---	-4.790e+010	-4.790e+010	-4.791e+010
Flow Regime	Transition	Transition	Transition	Transition
Liquid HoldUp	0.4661	0.4657	0.4653	0.4649
Friction Gradient (inH2O/ft)	1.337e-002	1.340e-002	1.343e-002	1.346e-002
Static Gradient (inH2O/ft)	0.0000	0.0000	0.0000	0.0000
Accel. Gradient (inH2O/ft)	1.450e-006	1.456e-006	1.462e-006	1.468e-006
Liq. Reynolds	1.592e+004	1.598e+004	1.605e+004	1.612e+004
Vap. Reynolds	7597	7593	7588	7584
Liquid Velocity (ft/s)	0.3868	0.3870	0.3871	0.3873
Vapour Velocity (ft/s)	1.334	1.336	1.338	1.341
Hyprotech Ltd.		HYSYS v3.2 (Build 5029)		Page 1 of 2
Licensed to: TEAM LND				

Figura 64. Reporte HYSYS de Simulación de Pozo10

Como se puede observar el resultado en ambas herramientas dio como resultado el patrón de flujo transición.

Nombre de la facilidad	HYSYS	PMC
Pozo1	Transición	Transición
Pozo2	Segregado	Segregado
Pozo3	Transición	Transición
Pozo4	Segregado	Segregado
Pozo5	Transición	Intermitente
Pozo6	Segregado	Segregado
Pozo7	Segregado	Segregado
Pozo8	Transición	Transición
Pozo9	Intermitente	Intermitente
Pozo10	Transición	Transición

Tabla 11. Comparación de resultados de Hysys Vs PMC

Como resultado final, de los 10 pozos, sólo en el pozo 5 se presentó una diferencia, pero la misma fue por lo cercano de las tasas a los límites entre transición e intermitente. A pesar de eso, se puede concluir que la arquitectura de RNA de tipo PMC con algoritmo backpropagation cumple con exactitud el cometido de la determinación del patrón de flujo, con menos de 200 registros de entrenamiento la RNA realizó una generalización correcta por encima del 90%.

6. CONCLUSIONES

- El software representa un adelanto en el estado del arte del flujo multifásico, porque además de utilizar tecnologías emergentes, aprovecha los datos de producción disponibles, para lograr mayor exactitud, y facilitar el análisis global de la tubería bajo estudio.
- La metodología desarrollada, inspirada en algoritmos genéticos, facilitó la búsqueda de la arquitectura de RNA apropiada, evitando un proceso de prueba y error con su consiguiente desgaste.
- Aunque las arquitecturas desarrolladas cumplieron los requisitos propuestos en la metodología, la red PMC con algoritmo backpropagation superó la de base radial, en cuanto a volumen y capacidad de generalización.
- Comparado con Hysys 3.2, Neuralyzer v1.0 mostró mayor versatilidad y facilidad de uso, ahorrando tiempo y dinero.
- La herramienta desarrollada queda con la facultad de migrar hacia otro tipo de problemas, tanto del petróleo como de cualquier otro campo del conocimiento al que le sea útil un modelamiento de aproximación basado en un conjunto de datos.
- Pese a que los registros disponibles para este trabajo son hipotéticos, se logra un modelo efectivo para la determinación del patrón de flujo. Se puede asegurar que, con datos reales de campo y un conjunto más grande de entrenamiento, el sistema es factible, con resultados satisfactorios.

7. RECOMENDACIONES

- Implementar una búsqueda inteligente de arquitecturas de RNA.
- Implementar más tipos de RNA.
- Ampliación del estudio hacia el comportamiento del patrón de flujo en tuberías inclinadas y verticales.
- Realizar un módulo visual en el que se facilite la construcción de un campo petrolero completo, para modelar el flujo en el total de las tuberías del sistema de facilidades.
- Explorar otras aplicaciones de las RNA en el petróleo. Estas tecnologías, con un pre-procesamiento y un post-procesamiento adecuado, pueden modelar procesos con relativa facilidad, comparados con las herramientas analíticas disponibles.

8. ANEXO 1: MANUAL DE USUARIO

8.1. INTRODUCCIÓN

Desde aquí se le orientará para que maneje el aplicativo arrancando desde cero. Para esto es necesario que usted tenga fundamentos en redes neuronales artificiales, y conozca las ventajas y desventajas de trabajar con uno u otro tipo de red.

Una de las utilidades de este software es permitirle manipular múltiples arquitecturas prototipo antes de llegar a la que se acerque a la generalización que quiera conseguir, quizá le ayude el [¿Qué puede hacer?](#).

La última finalidad de este producto, es permitirle una mejor, cómoda y más fácil herramienta para encontrar la arquitectura de red que más se ajuste a las necesidades de su modelo, para esto siga las [recomendaciones](#).

8.1.1. ¿Qué Puede Hacer?

Neuralyzer en su primera versión trata de ser lo más útil posible para el usuario, con varios extras en su ejecutable, el usuario puede permitirse un análisis documentado de sus datos y de las redes creadas para su estudio.

Con Neuralyzer V.1 puede:

- [Crear una red neuronal](#) de PMC con algoritmo backpropagation o de función de base radial.
- [Autogenerar](#) una serie de redes sugeridas.
- Cargar datos para el entrenamiento de la red desde un archivo de texto con dos opciones avanzadas, [normalización](#) y escogencia de [entradas/salidas](#), pudiendo [reservar](#) de ese conjunto de datos un porcentaje para realizar pruebas durante la ejecución, así como la oportunidad de [asignar un nombre](#) a las variables.
- Realizar el [entrenamiento](#) de cualquier red neuronal ya creada, con parámetros cambiantes como los ciclos de entrenamiento, la tasa de aprendizaje y el momentum, pudiendo detener este entrenamiento en cualquier momento.
- Entrenar así mismo la red con las velocidades superficiales de las fases, pero incluyendo solo los datos de los [caudales diarios](#) y llenando un [formulario](#) para que Neuralyzer calcule estas velocidades por usted.

- [Simular](#) cualquier red neuronal ya creada, cargando los datos de prueba desde un archivo de texto, que le permiten mayor flexibilidad al usuario, [normalizándolos](#) si lo necesita, [exportar](#) estos datos a excel para que pueda trabajarlos más cómodamente.
- Acciones como [guardar](#) , [cargar](#), [clonar](#), [Cambiar el nombre](#), [inicializar](#), mostrar los [detalles](#) y [borrar](#) están activas para cada red.
- Generación de [reportes](#) en los que se pueden incluir datos de simulación, [graficas en 2D](#), generalidades y especificaciones de la red neuronal, están disponibles para los usuarios.

8.1.2. Recomendaciones

Para un óptimo desarrollo del programa, es necesario que tenga en cuenta las siguientes recomendaciones antes de empezar a trabajar:

- Debido a la naturaleza de las RNA, el sistema requiere de un buen desempeño del computador durante su ejecución, por lo tanto, trate en lo posible de no utilizar programas que puedan obstaculizarlo, especialmente en el uso de la unidad de procesamiento.
- Para las PMC, el aplicativo trae habilitadas hasta seis capas, sin embargo por experiencia se sabe que para casi todos los modelamientos, una red con máximo cuatro capas es más que suficiente.
- Entre más neuronas hayan en una arquitectura, más demorará el sistema en cada ciclo de entrenamiento, lo mismo pasa cuando los datos de entrenamiento son excesivos, por tanto se recomienda ser consecuentes con estas variables y estudiar bien los modelos a proponer para evitar que el entrenamiento, simulación y generación de reportes sean tediosos.
- Cuando tenga arquitecturas que le han dado resultado, no olvide guardarlas, estas le servirán más adelante como guías para la afinación del modelo.
- Tenga en cuenta que cada computador tiene definido su [operador separador decimal](#), por lo tanto asegúrese de seleccionar el correcto para sus datos antes de empezar a trabajar.

8.2. DESDE CERO

En este tutorial se muestran todas las posibilidades que como principiante en el uso de *Neuralyzer* debe conocer. En los siguientes pasos, aprenderá a manejar el software de una manera grafica, sencilla y práctica.

A continuación se listan las opciones principales del sistema:

- [Crear](#)
- [Salvar](#)
- [Cargar](#)
- [Entrenar](#)
- [Simular](#)

8.2.1. ¿Cómo Crear?

Para crear una RNA, hay que tener primero en claro:

- ¿Cuántas entradas y cuantas salidas va tener la red?
- ¿Cuál va a ser el rango que van a manejar?
- ¿Hay que normalizar las entradas o no?
- ¿Qué tipo de modelo se quiere realizar?, ejemplo: predictivo, clasificador ...
- Después de contestadas estas dudas, hay dos opciones para la generación de la red, por medio del [autogenerar](#), o por el [formulario de creación de red](#).



Figura 65. Opciones para la creación de redes

8.2.1.1 Creando Una Red Neuronal

Después de tener una buena idea de lo que va entrar a la red y cuál es la salida, se ejecuta el comando *crear red* en el menú *red neuronal*. Inmediatamente luego de llenar

un sencillo formulario, el sistema le permite ver un diagrama previo de la arquitectura de la red en fabricación.

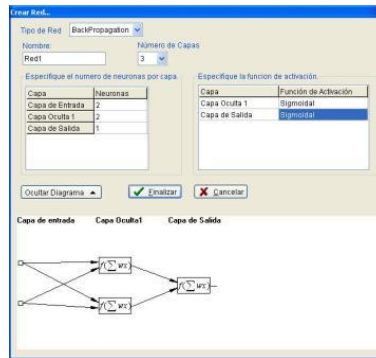


Figura 66. Detalles de la red

8.2.1.2 Autogenerando Redes

Seleccionando la opción *autogenerar* en el menú *red neuronal* aparece la ventana que se muestra en la ilustración, esta permite la generación en serie de redes sugeridas para iniciar un estudio que introduzca a la solución de la arquitectura óptima para el problema.



Figura 67. Caja de diálogo para autogeneración de redes

8.2.2. ¿Cómo Salvar?

Para salvar las redes ya creadas esta la opción *Guardar* en el menú *Red neuronal* allí va tener varias opciones de salvado, entre las que cuentan:

- Como archivo .m de Matlab®
- Como código fuente para Delphi® y Kylix® dentro de un .pas
- Como archivo .rna para ser utilizado por Neuralyzer.
- Como Macro de Microsoft Excel®

Seleccionando la opción *Guardar red* del menú *red neuronal* se llega a la conocida ventana de guardar archivo como, en la parte inferior se encuentran las opciones anteriormente nombradas. Solamente se selecciona la adecuada y se oprime en guardar, el archivo así guardado queda listo para ser utilizado con su respectivo software.

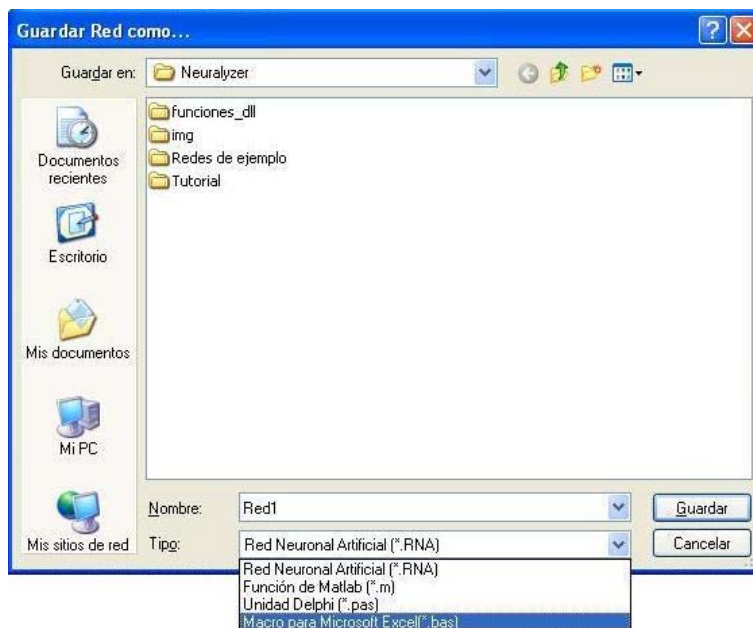


Figura 68. Salvando una red

8.2.3. ¿Cómo Cargar?

En la opción *cargar red* del menú *red neuronal*, se encuentra el diálogo de cargar red neuronal, aquí el sistema carga redes salvadas con el formato .rna

8.2.4. Entrenamiento

El entrenamiento es el proceso de más cuidado en la construcción de un modelo basado en redes neuronales, el rango de las entradas, las entradas irrelevantes, un conjunto de entrenamiento parcializado o mal escogido, en fin, múltiples variables que hay que tener en cuenta si no se quiere perder valioso tiempo en analizar datos fallidos y en construir, escoger y entrenar nuevos prototipos de red. Es por esto que antes de poner a entrenar cualquier red, es necesario analizar si el conjunto de entrenamiento realmente aporta a un generalización o si simplemente son datos sesgados, muy extremos, demasiado pocos o en determinados casos demasiados datos.

Una ayuda que quizá le pueda servir es el subconjunto de test, que no es sino un porcentaje que usted asigna al cargar los datos y que permite conocer el estado de la generalización por medio del error que se obtiene al evaluar el conjunto de test en cada iteración. Así mismo la [normalización](#) es un concepto que se puede aplicar con mucho éxito en los datos de entrada de la red neuronal.




Figura 69. Opción de reserva para realizar test.

Hay que tener en cuenta los diferentes parámetros ubicados en la parte superior y que de ellos depende también la duración y la calidad del entrenamiento. Es por esto que el usuario debe comprender el efecto que cada parámetro, iteraciones, tolerancia de error, momentum y tasa de aprendizaje, producen en el entrenamiento de la red.

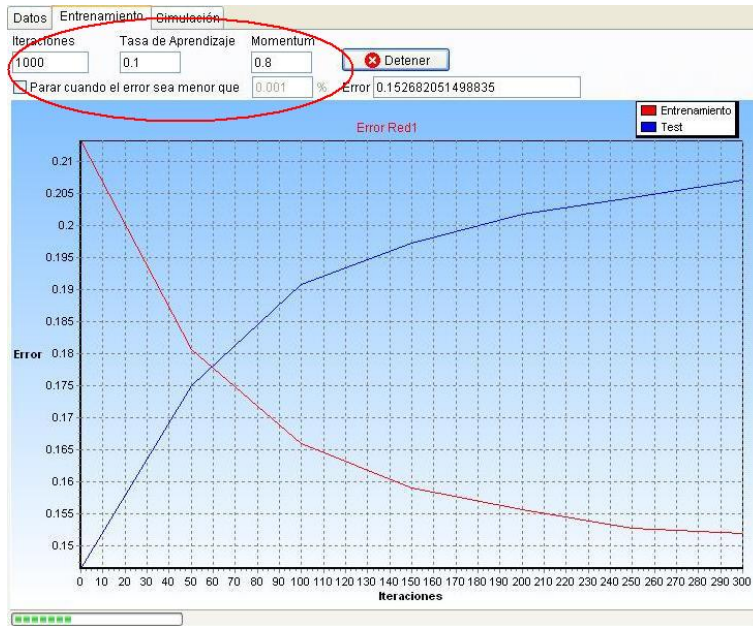


Figura 70. Parámetros de entrenamiento

Hay que tener en cuenta que el entrenamiento se puede detener en cualquier momento, ya sea por su extensa duración, por que consume más recursos de los debidos, o simplemente porque se considera que alcanzo un estado ideal de entrenamiento, el botón *Detener* se activa una vez comienza el entrenamiento y se desactiva cuando éste termina.



Figura 71. Botón detener entrenamiento

8.2.5. Simulación

En simulación, se cargan los datos de test desde archivo, y paso siguiente, se selecciona la red a simular, en este punto se activa el botón *Simulación*, inmediatamente las casillas de salida se rellenan con los datos obtenidos por la simulación de la red seleccionada, no olvide que también puede [normalizar](#) las entradas antes de realizar la simulación.




Figura 72. Empezar la simulación de los datos

8.3. AVANZADAS

Estas funciones no son vitales para el manejo, la generación y experimentación con redes en el *Neuralyzer*, sin embargo, facilitan en buena medida la experimentación con las redes. Estas funciones son puestas a su consideración en los siguientes apartes:

- [Edición.](#)
- [Normalización.](#)
- [Entradas/Salidas](#)
- [Convertir Caudales](#)
- [Exportar a Excel](#)
- [Reportes](#)
- [Gráficas en 2D](#)
- [Separador decimal](#)

8.3.1. Normalización

Se tiene este módulo experimental de normalización de entradas y salidas, con el fin de experimentar temporalmente si tiene éxito en la convergencia de la red o si simplemente no aporta mucho a la red, por tanto se puede ingresar el conjunto sin normalizar.

Esta normalización aplica solamente mientras los datos están cargados en el sistema y de ninguna manera afectan el archivo desde donde fueron cargados. Para que la normalización sea permanente, se debe editar directamente el archivo que contiene los datos.

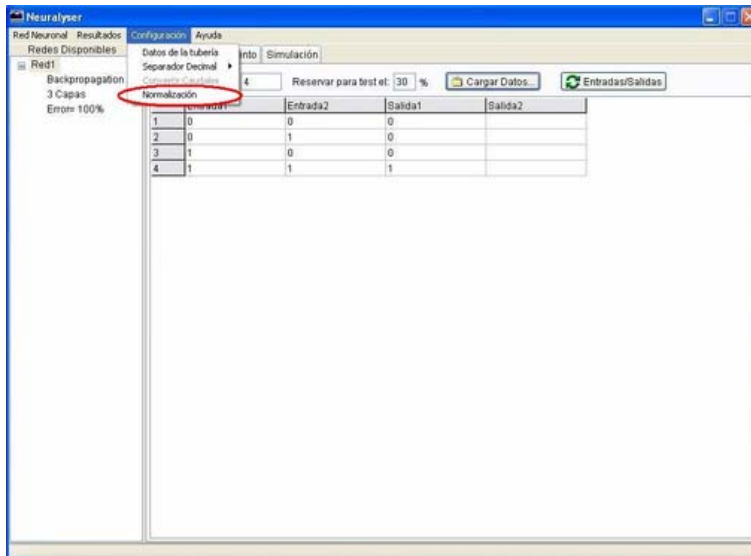


Figura 73. Opción para la normalización de datos

Al presionar el botón *normalización* que se habilita cuando una red es cargada o creada, y hay datos válidos cargados, ya sea en simulación o en entrenamiento, aparece una ventana que ofrece la opción de realizarla de dos maneras diferentes.




Figura 74. Normalización producto

En la primera, se realiza el producto de la entrada y/o salida por un número natural, la segunda realiza la normalización con el criterio Max-Min que cumple con la siguiente formula:

$$nuevo_valor = \frac{(valor_actual - min_actual)}{(max_actual - min_actual)} * [(nuevo_max - nuevo_min) + nuevo_min]$$




Figura 75. Normalización Max-Min

8.3.2. Edición

Al oprimir el botón derecho del ratón sobre alguna red neuronal, en la lista de redes en el frame izquierdo de la ventana principal, aparece un menú, accesible también por medio de la opción *edición* en el menú *Red neuronal*, desde este menú se pueden realizar acciones como mostrar los [detalles](#) de la red, [Cambiar el nombre](#), [Inicializar](#), [clonar](#), y [borrar](#) la red seleccionada.




Figura 76. Opciones para edición de redes

8.3.2.1 Detalles

Los detalles de cada una de las redes son mostrados acá, el cambio de red para visualizar se realiza por medio de un combo box situado en el margen superior izquierdo de la ventana de diálogo, resaltado en la ilustración.

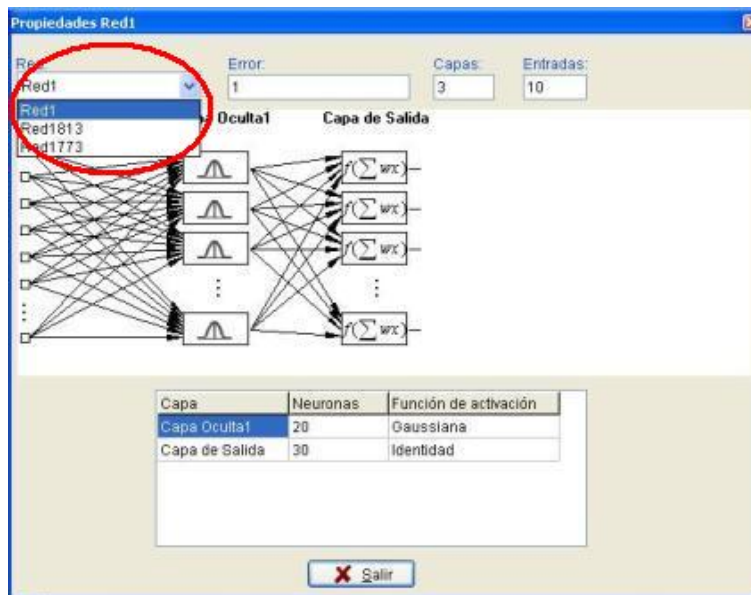


Figura 77. Caja de diálogo para los detalles de la red

8.3.2.2 Cambiar nombre

El nombre de la red puede ser cambiado, para efectos de mejor comprensión y orden, el sistema por defecto asigna un número consecutivo a cada red generada manualmente y un número aleatorio a cada red autogenerada.




Figura 78. Cambio de nombre de la red

8.3.2.3 Inicializar

La inicialización es muy útil para tener una nueva oportunidad de entrenar redes, tanto backpropagation como de función de base radial. Se utiliza principalmente para aquellas redes que han quedado atrapadas en un mínimo local, o simplemente han quedado mal entrenadas, y se desea aplicar un nuevo entrenamiento. Aplicar la inicialización es equivalente a borrar y crear una nueva red con las mismas características.

8.3.2.4 Clonar

Si determinada red es favorita para realizar varios experimentos, se le puede clonar mediante esta instrucción, de modo que queda una replica exacta y en las condiciones en las que se encontraba justo antes de clonarla. El formulario que aparece en el sistema sólo exige el nuevo nombre de la red.




Figura 79. Clonación de una red

8.3.2.5 Borrar

Para liberar espacio y para eliminar aquellas redes que definitivamente no sirven, o son desechadas por su pobre desempeño, existe la opción de borrar la red, pidiendo antes una confirmación de la acción para evitar el borrado por accidente.

8.3.3 Entradas/Salidas

Un conjunto de entrenamiento no necesariamente está sujeto a que las salidas sean siempre las últimas de la fila, aquí es posible escoger que columnas son entradas y que columnas son salidas, para esto oprima el botón localizado en la pestaña de carga de datos, que se habilita cuando hay una red.



Figura 80. Botón para activar la caja de diálogo de entradas/salidas

Después de seleccionar la opción, aparece una caja de diálogo que permite la elección de las entradas y las salidas.

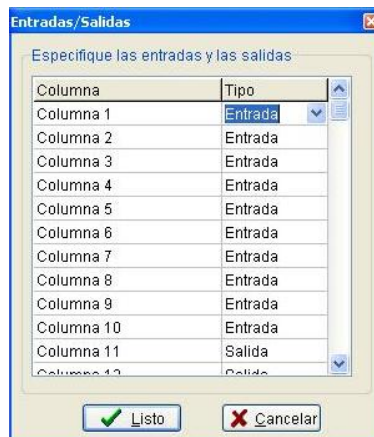


Figura 81. Caja de diálogo de entradas salidas

Así mismo es posible asignar nombres a las variables, para permitir una mayor comprensión de las entradas y las salidas de la red, esta opción esta disponible haciendo click sobre la caja de texto donde se encuentre la variable escogida.

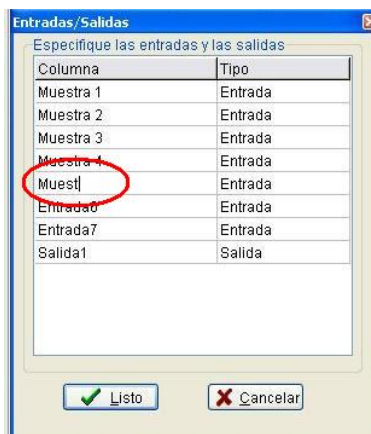


Figura 82. Edición del caption de las entradas y/o salidas

8.3.4. Convertir Caudales

Dentro de Neuralyser v 1.0 es posible introducir los datos de los caudales diarios producidos por un pozo, y llenando un sencillo [formulario](#) con los principales datos del mismo, se calculan las velocidades superficiales para alimentar la red que se va a entrenar con los mismos.

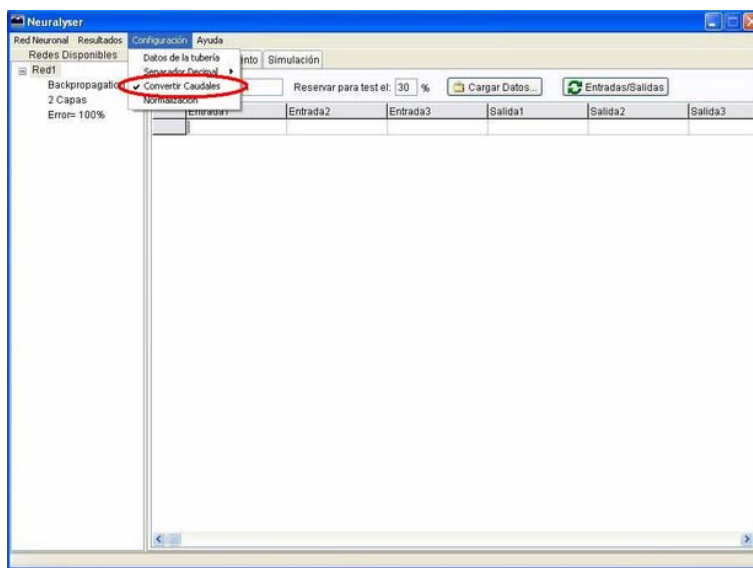


Figura 83. Opción de convertir caudales

8.3.5. Datos De La Facilidad

Con los datos de este formulario se realizan una serie de cálculos, junto con los [caudales diarios](#) del pozo para dar como resultado las velocidades superficiales.

Figura 84. Formulario de obtención de datos de tubería

8.3.6. Exportar Datos A Excel

Con los datos de simulación es necesario muchas veces seguir un trabajo de interpretación, en el que se le realizan operaciones, es por esto que esta opción se activa cada vez que se realiza una simulación, para permitir un cómodo trabajo en Excel.




Figura 85. Botón para exportar a Excel los datos de simulación

8.3.7. Reportes

Los reportes son de mucha utilidad para la documentación y seguimiento del proceso de creación y afinación de la red neuronal. Dentro del menú *Resultados* seleccione la opción *Reportes*

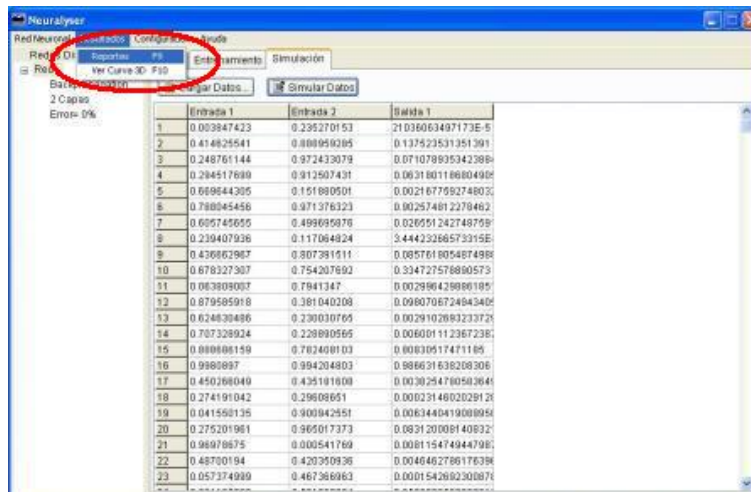


Figura 86. Opción para la generación de reportes

Aparece entonces una ventana que le pide que datos quiere que entren en el reporte. Después, solo acciona aceptar y el reporte es generado.

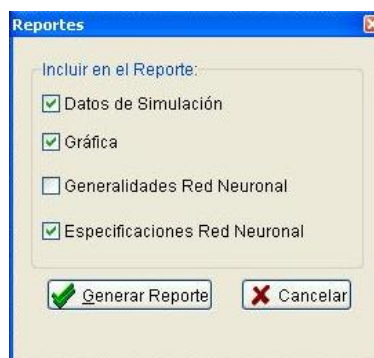


Figura 87. Caja de diálogo para la elaboración del reporte

8.3.8. Gráficas En 2D

Las gráficas son de mucha utilidad a la hora de realizar los análisis, es por esto que existe la opción de verlas en Neuralzyer v1.0

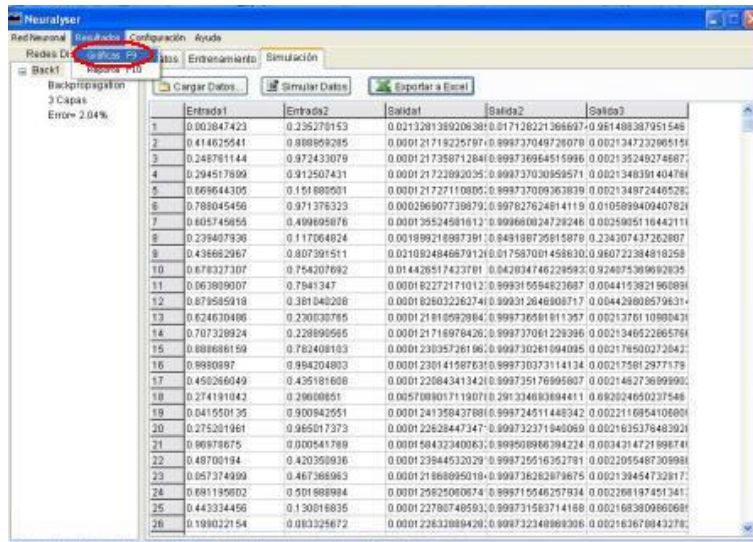


Figura 88. Opción para ver las graficas generadas

Una serie de gráficas le ilustran mejor lo que esta sucediendo con el pozo.

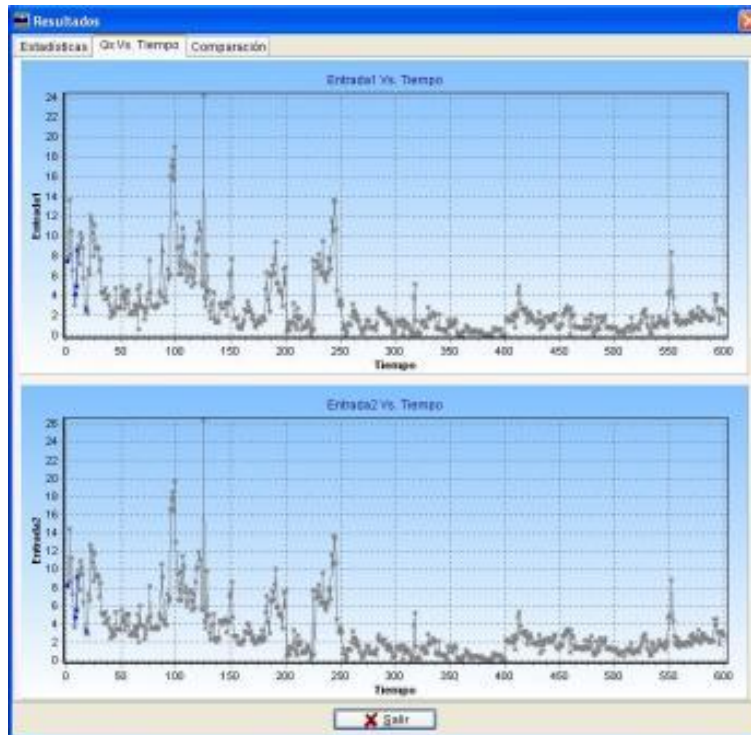


Figura 89. Gráficas generadas de acuerdo a los datos suministrados

8.3.9. *Separador Decimal*

Cada computador puede tener su separador decimal en coma (,) o en punto (.) lo que hace difícil la exportación/importación de los datos, afortunadamente en la opción *Separador decimal* del menú *configuración* se puede seleccionar el operador de separación decimal.

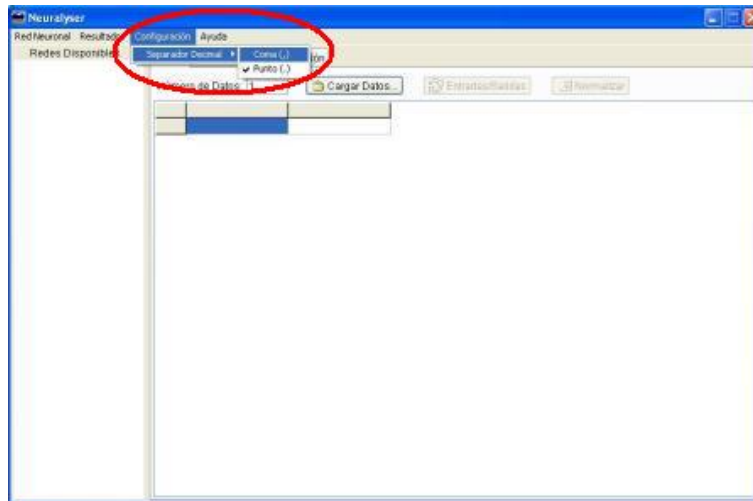


Figura 90. Menú operador decimal

9. ANEXO 2. ANÁLISIS DE LOS ALGORITMOS IMPLEMENTADOS EN NEURALYZER

Para efectos de medición de la eficiencia de los algoritmos de entrenamiento para las redes neuronales artificiales implementadas en Neuralyzer V1.0, tipo perceptrón multicapa con algoritmo de aprendizaje backpropagation y red de función de base radial, se proponen como parámetros de medición:

- Numero de iteraciones
- Error de generalización (definido como la evaluación de un conjunto de datos entrada/salida que la red nunca ha visto y se califica como el promedio de las diferencias entre la salida deseada y la salida obtenida)

$$E = \frac{1}{2n} \sum (Y_i - D_i)^2$$

n = número de datos

Donde: $Y_i =$ Salida *i* obtenida
 $D_i =$ Salida *i* deseada

- Tiempo de ejecución durante el entrenamiento
- Características de la red:
 - Para PMC:
 - Número de capas (incluyendo la de entrada y la de salida)
 - Neuronas en la capa oculta
 - Para redes de función de base radial:
 - Número de neuronas en la capa oculta

Para la comparación se va a utilizar el software MATLAB® 6.5, instalado junto con Neuralyzer en un equipo Pentium 4 de 2.8GHz y 512MB de RAM.

Con los casos propuestos se trata de cubrir en su mayoría los usos que se le dan a las redes de tipo clasificador. Los casos de evaluación van a ser los siguientes:

- Compuerta AND de 3 entradas
- Compuerta XOR de 3 entradas
- Sumador Binario
- Interpolación de la ecuación $Y=3X/4+2$
- Clasificador de números pares
- Determinación del patrón de flujo Multifásico

Compuerta AND

No existen para la red datos no vistos, es decir la evaluación se hace en este caso a partir del error de entrenamiento arrojado por el sistema. El conjunto con el que se entrena la red es el siguiente:

Entrada 1	Entrada 2	Entrada 3	Salida
0	0	0	0

0	0	1	0
0	1	0	0
0	1	1	0
1	0	0	0
1	0	1	0
1	1	0	0
1	1	1	1

Compuerta XOR de 3 entradas

No existen para la red datos no vistos, es decir la evaluación se hace en este caso a partir del error de entrenamiento arrojado por el sistema. El conjunto con el que se entrena la red es el siguiente:

Entrada 1	Entrada 2	Entrada 3	Salida
0	0	0	0
0	0	1	1
0	1	0	1
0	1	1	0
1	0	0	1
1	0	1	0
1	1	0	0
1	1	1	1

Sumador Binario

Este caso funciona de la siguiente manera:

No existen para la red datos no vistos, es decir la evaluación se hace en este caso a partir del error de entrenamiento arrojado por el sistema. Dos registros de 2 bits cada uno, la salida es un registro de 3 bits con la suma de los registros de entrada.

Los datos totales son:

Registro 1		Registro 2		Salida		
Bit 1	Bit 2	Bit 1	Bit 2	Bit 1	Bit 2	Bit 3
0	0	0	0	0	0	0
0	0	0	1	0	0	1
0	0	1	0	0	1	0
0	0	1	1	0	1	1
0	1	0	0	0	0	1
0	1	0	1	0	1	0
0	1	1	0	0	1	1
0	1	1	1	1	0	0
1	0	0	0	0	1	0
1	0	0	1	0	1	1
1	0	1	0	1	0	0

1	0	1	1	1	0	1
1	1	0	0	0	1	1
1	1	0	1	1	0	0
1	1	1	0	1	0	1
1	1	1	1	1	1	0

Interpolación de la ecuación $Y=3X/4+2$

Hay una entrada de números reales, y la salida es un valor continuo que aproxima la función $Y=3X/4+2$

Se colocan los siguientes datos de entrenamiento:

Entrada	Salida
1	2.75
3	4.25
5	5.75
7	7.25
9	8.75

Los datos de test son los siguientes:

Entrada	Salida
2	3.5
8	8
10	9.5

Clasificador de números pares

Las entradas de este caso son números binarios de 4 bits, una salida que aproxima a uno los valores pares y a cero los valores impares.

Los datos de entrenamiento son:

Número				Salida
Bit 1	Bit 2	Bit 3	Bit 4	Par/Impar
0	0	0	1	0
0	0	1	0	1
0	0	1	1	0
0	1	0	0	1
0	1	0	1	0
1	0	1	0	1
1	0	1	1	0
1	1	0	0	1
1	1	0	1	0

1	1	1	0	1
1	1	1	1	0

Los datos de test son los siguientes:

Número				Salida
Bit 1	Bit 2	Bit 3	Bit 4	Par/Impar
0	1	1	0	1
0	1	1	1	0
1	0	0	0	1
1	0	0	1	0

Determinación del patrón de flujo Multifásico

La determinación del flujo multifásico, por su complejidad, requiere de los siguientes datos de entrenamiento.

Vs Aceite	Vs Gas	Vs Agua	Segregado	Transición	Intermitente	Distribuido
0.137716822	0.522874709	2.694659501	0	0	0	1
0.142020473	0.23238876	2.217644747	0	0	0	1
0.146324123	0.40668033	2.792589682	0	0	0	1
0.150627774	0.34858314	2.640955853	0	0	0	1
0.176449678	0.23238876	1.961762661	0	0	0	1
0.180753329	0.23238876	1.968080737	0	0	0	1
0.197967931	0.23238876	1.983875928	0	0	0	1
0.241004438	0.697166279	2.552502786	0	0	0	1
0.30468017	28.05934304	0.104560467	0	0	0	1
0.344292055	0.23238876	1.86383248	0	0	0	1
0.348679759	28.39695691	0.011248685	0	0	0	1
1.269741074	0	1.698061951	0	0	0	1
0.085654435	0.867033321	0.046366646	1	0	0	0
0.09725332	1.57666851	0.001412143	1	0	0	0
0.019386294	0.404862118	0.016883986	1	0	0	0
0.006417419	0.368356752	0.002812171	1	0	0	0
0.124070098	2.913367042	0.019685199	1	0	0	0
0.057078277	1.002208752	0.002800152	1	0	0	0
0.051860863	0.513522714	0.011127	1	0	0	0
0.005482401	0.079720504	0.015380295	1	0	0	0
0.072730747	1.372966077	0.009842599	1	0	0	0
0.00469896	0.050347552	0.009776649	1	0	0	0
0.022155765	0	0.042209966	1	0	0	0
0.003426177	0.545909869	0.019670698	1	0	0	0
0.047005624	0.370596718	0.025340347	1	0	0	0
0.074390722	0.968632098	0.004208203	1	0	0	0
0.019876714	0.345305908	0.068765537	1	0	0	0
0.081613791	1.633149935	0.029525019	1	0	0	0

0.034557705	0.932814931	0.049148706	1	0	0	0
0.008947409	0.23784677	0	1	0	0	0
0.037195361	0.343708164	0.018235547	1	0	0	0
0.01559713	0.79094594	0.064645396	1	0	0	0
0.022438812	0.04905787	0.008418035	1	0	0	0
0.044849378	0.62366855	0.07025938	1	0	0	0
0.019509417	1.469482447	0.061535648	1	0	0	0
0.050736246	0.823242903	0.001400076	1	0	0	0
0.011887441	0.245079333	0.002808237	1	0	0	0
0.013733866	0.525936875	0.094336036	1	0	0	0
0.094161999	2.145769228	0.011255991	1	0	0	0
0.01147639	1.208634656	0.004226048	1	0	0	0
0.073070508	1.331941911	0.002802772	1	0	0	0
0.029815071	0.243745347	0.063152024	1	0	0	0
0.105713131	1.124863081	0.004208203	1	0	0	0
0.038895647	0.410818171	0.006954375	1	0	0	0
0.029365975	1.063986108	0.004194341	1	0	0	0
0.014959208	0.019623148	0.01683607	1	0	0	0
0.036466677	1.002208752	0.004200228	1	0	0	0
0.022473598	1.19531108	0.114048043	1	0	0	0
0.056774147	0	0.023918981	1	0	0	0
0.008739733	1.912497729	0.074624028	1	0	0	0
0.058757029	0.347434423	0.019709159	1	0	0	0
0.014301959	0.722639734	0.001412143	1	0	0	0
0.08039271	0.614622834	0.049097061	1	0	0	0
0.24935036	2.255436779	0.147607542	0	1	0	0
0.12100868	1.129749971	0.03616275	0	1	0	0
0.075512507	0.506660051	0.606781378	0	1	0	0
0.046905945	0.748409182	0.130009256	0	1	0	0
0.127395646	0.607293178	0.25748079	0	1	0	0
0.150260224	2.882796752	0.092674032	0	1	0	0
0.013328103	0.666692717	0.190036082	0	1	0	0
0.12792268	0.637764036	0.039149842	0	1	0	0
0.024711928	0.868330537	0.180411332	0	1	0	0
0.003654934	0	0.276845313	0	1	0	0
0.265544913	0.515526939	0.28985291	0	1	0	0
0.086073014	0.34858314	0.060021724	0	1	0	0
0.081448642	0.629344402	0.099163154	0	1	0	0
0.059443605	0.894661061	0.240109991	0	1	0	0
0.141242999	13.36044991	0.019697984	0	1	0	0
0.07340223	0.697395117	0.113849596	0	1	0	0
0.026058858	0.68604175	0.104641597	0	1	0	0
0.173377181	2.18694926	0.016849824	0	1	0	0
0.076160441	0	0.115373906	0	1	0	0
0.221910772	1.482139949	0.132384742	0	1	0	0
0.202271582	1.859110078	0.028431343	0	1	0	0
0.124557393	0.447823123	0.028053564	0	1	0	0
0.057894017	0.327711594	0.168814591	0	1	0	0
0.059543617	0.44534833	0.150548877	0	1	0	0

0.121922348	1.656313404	0.060438674	0	1	0	0
0.077726369	0.502232634	0.088328366	0	1	0	0
0.059929595	1.33874841	0.095744036	0	1	0	0
0.17438035	0.250780949	0.081355334	0	1	0	0
0.019509417	2.271018327	0.186005482	0	1	0	0
0.052252435	1.133267066	0.137743955	0	1	0	0
0.13508604	1.260429209	0.125204155	0	1	0	0
0.196520006	0.095586804	0.008426131	0	1	0	0
0.232548673	0.273105153	0.014043552	0	1	0	0
0.193711487	0.71748454	0.04194626	0	1	0	0
0.020832824	0.433499882	0.121952359	0	1	0	0
0.147492142	0.143672671	0.284217878	0	1	0	0
0.54182466	0.841907472	0.102395507	0	1	0	0
0.493397382	0.631803011	0.00317425	0	1	0	0
0.101381348	0.541173538	0.268418928	0	1	0	0
0.212343667	3.989584606	0	0	1	0	0
0.036858074	0.669954363	0.172415404	0	1	0	0
0.645547602	3.602025776	1.279410431	0	0	1	0
0.198223668	1.22437648	0.627085622	0	0	1	0
0.763235406	1.411703122	0.323875645	0	0	1	0
0.438311573	4.475241998	0.380402188	0	0	1	0
1.625473981	0.877733322	0.001402678	0	0	1	0
1.64415759	1.468859845	0.001402678	0	0	1	0
0.31847015	2.556276357	0.31590381	0	0	1	0
0.295998347	1.10919531	0.455669197	0	0	1	0
0.46723706	1.613374996	0.243958278	0	0	1	0
0.204373941	5.723857117	0.598085872	0	0	1	0
0.211937255	2.577634694	0.401334798	0	0	1	0
0.733391286	1.77234837	0.021063731	0	0	1	0
0.348568254	3.540116805	0.415365624	0	0	1	0
0.440328119	1.915882808	0.3014427	0	0	1	0
0.847819184	1.045749419	1.260456203	0	0	1	0
0.210878883	2.033401648	1.841719213	0	0	1	0
0.565789737	8.203828232	0.002800178	0	0	1	0
0.271129993	2.207693217	0.73289684	0	0	1	0
0.716205011	0.949385022	0.004208035	0	0	1	0
0.210643081	1.306532603	0.522802336	0	0	1	0
0.163538726	1.161943799	1.942808433	0	0	1	0
0.192478205	1.376531203	0.771035372	0	0	1	0
0.204163445	1.266650128	0.596994582	0	0	1	0
0.799186245	10.38800899	0.004212456	0	0	1	0
0.293941886	2.070634357	0.441937836	0	0	1	0
0.442774386	1.680598955	0.344906531	0	0	1	0
0.778483707	1.110601346	0.064523196	0	0	1	0
0.085260295	0.497726706	0.982868391	0	0	1	0
0.959091927	0.931472097	0.065925874	0	0	1	0
2.223349468	1.27181767	0.025248207	0	0	1	0
0.884357492	0.716516997	0.357682935	0	0	1	0
0.542310034	3.995333776	0.065495609	0	0	1	0

0.278334352	2.805375581	0.345438752	0	0	1	0
0.111894918	1.917207268	1.254138126	0	0	1	0
0.524750055	3.35609905	0.058557636	0	0	1	0
0.591099833	0.947704516	0.047613755	0	0	1	0
0.025821904	0.755263469	1.652176927	0	0	1	0
1.133472278	0.931472097	0.410984706	0	0	1	0
0.672609923	0.591126523	0.178140128	0	0	1	0
0.284837491	2.872170238	0.295091403	0	0	1	0
0.097886583	2.279970231	0.599790809	0	0	1	0
0.137716822	0.522874709	2.694659501	0	0	0	1
0.142020473	0.23238876	2.217644747	0	0	0	1
0.146324123	0.40668033	2.792589682	0	0	0	1
0.150627774	0.34858314	2.640955853	0	0	0	1
0.176449678	0.23238876	1.961762661	0	0	0	1
0.180753329	0.23238876	1.968080737	0	0	0	1
0.197967931	0.23238876	1.983875928	0	0	0	1
0.241004438	0.697166279	2.552502786	0	0	0	1
0.30468017	28.05934304	0.104560467	0	0	0	1
0.344292055	0.23238876	1.86383248	0	0	0	1
0.348679759	28.39695691	0.011248685	0	0	0	1
1.269741074	0	1.698061951	0	0	0	1
0.085654435	0.867033321	0.046366646	1	0	0	0
0.09725332	1.57666851	0.001412143	1	0	0	0
0.019386294	0.404862118	0.016883986	1	0	0	0
0.006417419	0.368356752	0.002812171	1	0	0	0
0.124070098	2.913367042	0.019685199	1	0	0	0
0.057078277	1.002208752	0.002800152	1	0	0	0
0.051860863	0.513522714	0.0111127	1	0	0	0
0.005482401	0.079720504	0.015380295	1	0	0	0
0.072730747	1.372966077	0.009842599	1	0	0	0
0.00469896	0.050347552	0.009776649	1	0	0	0
0.022155765	0	0.042209966	1	0	0	0
0.003426177	0.545909869	0.019670698	1	0	0	0
0.047005624	0.370596718	0.025340347	1	0	0	0
0.074390722	0.968632098	0.004208203	1	0	0	0
0.019876714	0.345305908	0.068765537	1	0	0	0
0.081613791	1.633149935	0.029525019	1	0	0	0
0.034557705	0.932814931	0.049148706	1	0	0	0
0.008947409	0.23784677	0	1	0	0	0
0.037195361	0.343708164	0.018235547	1	0	0	0
0.01559713	0.79094594	0.064645396	1	0	0	0
0.022438812	0.04905787	0.008418035	1	0	0	0
0.044849378	0.62366855	0.07025938	1	0	0	0
0.019509417	1.469482447	0.061535648	1	0	0	0
0.050736246	0.823242903	0.001400076	1	0	0	0
0.011887441	0.245079333	0.002808237	1	0	0	0
0.013733866	0.525936875	0.094336036	1	0	0	0
0.094161999	2.145769228	0.011255991	1	0	0	0
0.01147639	1.208634656	0.004226048	1	0	0	0

0.073070508	1.331941911	0.002802772	1	0	0	0
0.029815071	0.243745347	0.063152024	1	0	0	0
0.105713131	1.124863081	0.004208203	1	0	0	0
0.038895647	0.410818171	0.006954375	1	0	0	0
0.029365975	1.063986108	0.004194341	1	0	0	0
0.014959208	0.019623148	0.01683607	1	0	0	0
0.036466677	1.002208752	0.004200228	1	0	0	0
0.022473598	1.19531108	0.114048043	1	0	0	0
0.056774147	0	0.023918981	1	0	0	0
0.008739733	1.912497729	0.074624028	1	0	0	0
0.058757029	0.347434423	0.019709159	1	0	0	0
0.014301959	0.722639734	0.001412143	1	0	0	0
0.08039271	0.614622834	0.049097061	1	0	0	0
0.24935036	2.255436779	0.147607542	0	1	0	0
0.12100868	1.129749971	0.03616275	0	1	0	0
0.075512507	0.506660051	0.606781378	0	1	0	0
0.046905945	0.748409182	0.130009256	0	1	0	0
0.127395646	0.607293178	0.25748079	0	1	0	0

Los datos de test de la red son los siguientes:

Vs Aceite	Vs Gas	Vs Agua	Segregado	Transición	Intermitente	Distribuido
0.008739733	0.717186648	0.059136022	1	0	0	0
0.051688561	0.402780417	0.055866566	1	0	0	0
0.066452877	2.924144397	0.016729675	1	0	0	0
0.102281146	1.917151466	0.031990125	1	0	0	0
0.033790414	0.243745347	0.058941889	1	0	0	0
0.088094276	0.874893507	0.002805469	1	0	0	0
0.007491199	2.199372388	0.084480032	1	0	0	0
0.06851777	0.437446754	0	1	0	0	0
0.095932967	1.734066642	0.032316147	1	0	0	0
0.006342031	0.03579317	0.011200608	1	0	0	0
0.1113096	0.467178582	0.00842027	1	0	0	0
0.011098554	0.536897546	0.018200988	1	0	0	0
0.104817842	2.846393087	0.019685199	1	0	0	0
0.103024491	0.245079333	0	1	0	0	0
0.051512246	0.802077816	0.025274136	1	0	0	0
0.042905877	0.492708909	0.004236428	1	0	0	0
0.003426177	0.610134559	0.022480798	1	0	0	0
0.019496413	0.208143668	0.008432008	1	0	0	0
0.065807873	0.277947539	0.032379332	1	0	0	0
0.21118193	0.203536284	0.291218319	0	1	0	0
0.07925814	1.540805161	0.089865728	0	1	0	0
0.290200027	1.381223633	0.014033783	0	1	0	0
0.520778015	0.58717608	0.080048246	0	1	0	0
0.161944051	1.426733092	0.10266974	0	1	0	0
0.374278901	0.840299477	0.264989164	0	1	0	0
0.15059484	0.526148474	0.056081502	0	1	0	0

0.125654665	2.70240608	0.042166517	0	1	0	0
0.102375097	1.988135691	0.071611752	0	1	0	0
0.15011535	3.373165977	0.056102048	0	1	0	0
0.191472344	0.428772128	0.042155628	0	1	0	0
0.077791294	0.239643933	0.198895124	0	1	0	0
0.071002084	1.391694984	0.115140464	0	1	0	0
0.042455613	0.050417168	0.16178065	0	1	0	0
0.238133856	0.839024763	0.122692189	0	1	0	0
0.07021436	0.933237573	0.104560467	0	1	0	0
0.139945086	0.410272441	0.197022702	0	1	0	0
0.248578107	1.155193828	0.168306145	0	1	0	0
0.258920727	1.830084759	0.257616415	0	1	0	0
1.046282103	0.859820397	0.234247255	0	0	1	0
1.064965712	0.877733322	0.343656153	0	0	1	0
0.479482828	4.98540331	0.002800178	0	0	1	0
0.584697485	2.770957296	0.023689901	0	0	1	0
0.657238486	5.9279226	0.58161533	0	0	1	0
0.162997622	5.412777926	0.589721035	0	0	1	0
0.435435584	4.033437491	0.250968573	0	0	1	0
0.154931425	0.929555039	1.434203298	0	0	1	0
0.048899287	1.05766925	1.293761513	0	0	1	0
0.37367218	0.304519724	0.681701593	0	0	1	0
0.148228254	0	0.764768234	0	0	1	0
0.137921065	1.182100926	0.687310804	0	0	1	0
0.084006467	0.311079191	0.906190715	0	0	1	0
0.559474589	0.813360659	1.023528345	0	0	1	0
0.081769363	2.091498838	1.525815403	0	0	1	0
0.261497015	1.570646159	0.521496438	0	0	1	0

Comparación de resultados

Compuerta AND

Tipo de RNA Parámetro	PMC con algoritmo Backpropagation	Feed-Forward Backpropagation	Base Radial	Radial Basis (Fewer neurons)
Iteraciones	1000			--
Error de entrenamiento	0.39%	18.04%	0.02%	0.00%
Tiempo de	0.32	2.63 segundos	0.25	0.00

ejecución durante el entrenamiento	segundos		segundos	segundos
Número de capas	2	2	3	3
Neuronas en la capa oculta	--	--	8	8

Compuerta XOR

Tipo de RNA Parámetro	PMC con algoritmo Backpropagation	Feed-Forward Backpropagation	Base Radial	Radial Basis (Fewer neurons)
Iteraciones	1000			--
Error de entrenamiento	12.92%	30.80%	1.13%	0.00%
Tiempo de ejecución durante el entrenamiento	0.22 Segundos	3.53 segundos	0.15 segundos	0.00 segundos
Número de capas	3	3	3	3
Neuronas en la capa oculta	3	3	8	8

Sumador Binario

Tipo de RNA Parámetro	PMC con algoritmo Backpropagation	Feed-Forward Backpropagation	Base Radial	Radial Basis (Fewer neurons)
Iteraciones	1000			--
Error de entrenamiento	4.93%	46.39%	0.82%	0.00%
Tiempo de ejecución durante el entrenamiento	0.28 segundos	3.62 segundos	0.18 segundos	0.00 segundos
Número de capas	3	3	3	3
Neuronas en la capa oculta	4	4	16	16

Interpolación de la ecuación $Y=3X/4+2$

Tipo de RNA

Parámetro	PMC con algoritmo Backpropagation	Feed-Forward Backpropagation	Base Radial	Radial Basis (Fewer neurons)
Iteraciones	1000			--
Error de test	1.3%	30.26%	195.30%	10.14%
Tiempo de ejecución durante el entrenamiento	0.34 segundos	4.53 segundos	0.15 segundos	0.00 segundos
Número de capas	3	3	3	3
Neuronas en la capa oculta	5	5	5	5

Clasificador de números pares

Parámetro	PMC con algoritmo Backpropagation	Feed-Forward Backpropagation	Base Radial	Radial Basis (Fewer neurons)
Iteraciones	1000			--
Error de test	0.01%	20.98%	0.00%	2.55%
Tiempo de ejecución durante el entrenamiento	0.28 segundos	4.63 segundos	0.19 segundos	0.00 segundos
Número de capas	3	3	3	3
Neuronas en la capa oculta	4	4	11	11

Determinación del patrón de flujo Multifásico

Parámetro	PMC con algoritmo Backpropagation	Feed-Forward Backpropagation	Base Radial	Radial Basis (Fewer neurons)
Iteraciones	1000			120
Error de test ²⁰	1.9%	47.74%	42.12%	81.46%
Tiempo de ejecución durante el	1.04 segundos	5.50 segundos	3.88 segundos	1.97 segundos

²⁰ El cálculo del porcentaje de error de test es en este caso, el porcentaje de los desaciertos sobre el total de los registros evaluados.

entrenamiento				
Número de capas	3	3	3	3
Neuronas en la capa oculta	4	4	135	135

Conclusiones

- Las redes implementadas en Neuralyzer mostraron buenos resultados en comparación con las redes hechas en MATLAB® en cuanto a tiempo de entrenamiento y porcentajes de error.
- Las redes de Neuralyzer demuestran su capacidad para afrontar las diferentes problemáticas propuestas actualmente para las redes de tipo Clasificación/Predicción.

BIBLIOGRAFÍA

En orden de aparición:

1. Miguel Garre et al. Comparación de diferentes algoritmos de clustering en la estimación de coste en el desarrollo de software. Universidad de Alcalá. Madrid.
2. Mohaghegh S. "Neural Network: What it can do for Petroleum Engineers", paper SPE 29219. JPT (Enero/95).
3. Osman, E.A.: "Artificial Neural Networks Models for Identifying Flow Regimes and Predicting Liquid Holdup in Horizontal Multiphase Flow", paper SPE 68219, marzo 2001.
4. Lobo C. Eduardo A. Romero R. Yeison R. Determinación del patrón de flujo multifásico predominante del sistema de facilidades de superficie del campo gala utilizando una aplicación numérica desarrollada en el software Microsoft Excel. Tesis de Grado. P14802.UIS.
5. Amaya A. Carlos, Pallares Henry. Influencia de los modificadores de tensión superficial en los patrones de flujo en flujo bifásico gas-liquido en tubería horizontal. Tesis de grado. P06796. 1996.UIS
6. Brill J. P. Arirachakaran S. J. State of the art in multiphase flow. Paper. SPE. 232835. Mayo de 1992.
7. Mohaghegh, S.D.: "*Virtual Intelligence Applications in Petroleum Engineering: Part 1—Artificial Neural Networks,*" paper SPE 58046,
8. Dukler, Wicks & Cleveland, A.I.Ch.E. Journal, 10, 44. 1974
9. Beggs H.D. and Brill, J.P.: "A Study of Two Phase Pressure Drop In Inclined Pipes" JPT, May 1973 (Cap. 3).
10. Rueda L. Alexander, García J. Diego M. Estudio generalizado de las aplicaciones de las redes neuronales en la industria del petróleo. Tesis de Grado. P10110. UIS.
11. Miguel F. Pérez I., Mike A. Roza A., Roberto Ulloa J. Estudio de yacimientos de petróleo usando redes neuronales artificiales. Universidad Industrial de Santander. Facultad de Ingenierías Físico-Químicas. Escuela de Ingeniería de Petróleos. Bucaramanga 2002.
12. Sandoval M. Jorge E. Aplicaciones de redes neuronales para predecir la composición de fluidos en yacimientos de gas condensado a partir de datos de producción. Tesis de Grado. YP09096. UIS. 1999.
13. Henry Guerrero R, Javier Medina C. Desarrollo de un Sistema de Diagnostico por Computador del Flujo Multifásico en Tuberías Verticales. Universidad Industrial de Santander. Bucaramanga 1990.
14. Ady Z. Alfaro G, José A. Camacho A. Evaluación Crítica de Flujo Multifásico utilizando Modelos Mecanísticos. Universidad Industrial de Santander. Facultad de Ingenierías Físico-Químicas. Escuela de Ingeniería de Petróleos. Bucaramanga 2001.
15. Alcalá C. Jaime R. Predicción de patrones de flujo bifásicos gas-líquido viscosos en tuberías horizontales y levemente inclinadas. Tesis de Grado. ST-0128 Universidad Simón Bolívar. 1999.
16. Economides, J.M. and Hill, A.D: "Petroleum Production Systems", Hall PTR Prentice, New Jersey, 1994 (Cap. 7 y 10).

17. Bharath Rao. Multiphase flow models: Range of applicability. www.ctes.com. 1998.
18. A.M. Ribeiro, V. Ferreira, J.B.L.M. Campos. On the comparison of new pressure drop and hold-up data for horizontal air–water flow in a square cross-section channel against existing correlations and models. *International Journal of Multiphase Flow* 32 (2006) 1029–1036. 2006.
19. Rey-Fabret *et al.* Neural Networks Tools for Improving Tacite Hydrodynamic Simulation of Multiphase Flow Behavior in Pipelines. *Oil & Gas Science and Technology – Rev. IFP*, Vol. 56 (2001), No. 5, pp. 471-478. 2001
20. Baker, O.: “Design of Pipelines for the simultaneous Flow of Oil and Gas”, *Oil and Gas J.* 1953.
21. Mandhane, J.M.: “A Flow Pattern Map for Gas-Liquid Flow in Horizontal Pipes”, *Int. J. Multiphase Flow*, 1974.
22. Taitel, Y.: “Advances in Two Phase Flow Modeling”, paper SPE 27959, May 1995.
23. Baker, O., *Oil and Gas Journal*, 53(12), 185. 1954
24. Hughmark, G. A. And B.S. Pressburg, *A.I.Ch.E. Journal*, 7, 677, 1961
25. Lockhart, R. W. & R. C. Martinelli, *Chem. Eng. Progress*, 45, 39. 1949
26. <http://www.gc.ssr.upm.es/inves/neural/ann2/anntutorial.html> Revisado el 12 de agosto del 2006.
27. <http://ingenieria.udea.edu.co/investigacion/mecatronica/mectronics/redes.htm> Revisado el 12 de Agosto del 2006.
28. <http://www.tecnociencia.org/n/205/redes-neuronales-artificiales/> Revisado el 20 de agosto del 2006.
29. <http://www.gc.ssr.upm.es/inves/neural/ann2/concepts/taxonomy.htm> Revisado el 20 de agosto del 2006.
30. GRECH, Pablo, *Introducción a la Ingeniería. Un enfoque a través del diseño.*- Editorial Prentice Hall, Bogotá, 2001.
31. Dawson, Martín G. *El proyecto de fin de carrera en ingeniería informática: una guía para el estudiante.* Editorial Prentice Hall. Madrid. 2002.