

Caracterización hidrodinámica de flujos multifase empleando técnicas de inteligencia artificial

Carlos Mauricio Ruiz Diaz

Trabajo de Grado para Optar el Título de Magister en Ingeniería Mecánica

Director

Octavio Andrés González Estrada

PhD en Ingeniería Mecánica y de Materiales

Codirector

German González Silva

PhD en Ingeniería Química

Marlon Mauricio Hernández Cely

PhD en Ingeniería Mecánica

Universidad Industrial de Santander

Facultad de Ingenierías Fisicomecánicas

Escuela de Ingeniería Mecánica

Maestría en Ingeniería Mecánica

Bucaramanga

2021

### **Dedicatoria**

*Dedico este trabajo a mis padres, Mauricio Ruiz y Margarita Diaz, por su apoyo y fiel comprensión en mi formación como Magister en Ingeniería Mecánica.*

*También dedico este trabajo a mi hermana Yohanna Ruiz, por la motivación y el apoyo que me brindó en cada momento de dificultad presentado durante mi formación.*

### **Agradecimientos**

En primer lugar, agradezco a Dios por bendecirme siempre y brindarme la oportunidad de formarme como un profesional integral.

Agradezco a Octavio Andrés González Estrada, PhD., director de mi proyecto de investigación, por confiar en mí, por brindarme su acompañamiento profesional y por apoyarme incondicionalmente en mi formación como Magister.

Agradezco a Germán González Silva, PhD., codirector de mi proyecto de investigación, por brindarme su apoyo enfocado para aumentar mi potencial como investigador.

Agradezco a Marlon Mauricio Hernández Cely, PhD., codirector de mi proyecto de investigación por abrirme las puertas en la investigación, por creer en mí, por brindarme su amistad y por brindarme su apoyo incondicional en el ámbito profesional y personal.

Agradezco a Oscar Mauricio Hernández Rodríguez, PhD. Por disponibilizar todo el material experimental, técnico y profesional del Laboratorio LEMI de la EESC/USP para llevar a cabo mi investigación.

Asimismo, agradezco a todas las personas que directa o indirectamente orientaron mi camino a la formación como Magister con su apoyo permanente.

**Tabla de Contenido**

	<b>Pág.</b>
Introducción .....	15
1. Objetivos .....	35
1.1. Objetivo General .....	35
1.2. Objetivos Específicos.....	35
2. Alcance.....	36
3. Metodología .....	37
3.1. Aparato experimental.....	37
3.1.1. Propuesta esquemática para banco experimental en la Universidad Industrial de Santander .....	42
3.2. Matriz experimental .....	44
3.3. Análisis de las bases de datos .....	50
3.4. Aplicación de inteligencia artificial .....	51
4. Resultados .....	60
5. Conclusiones .....	86
6. Recomendaciones .....	89
Referencias Bibliográficas .....	90

**Lista de Tablas**

	<b>Pág.</b>
Tabla 1 Equipos de la bancada experimental instalada en LEMI-USP .....	41
Tabla 2. Instrumentos de medida instalados en LEMI-USP .....	42
Tabla 3 Información general de la base de datos experimental para flujo bifásico de aceite y agua en tubería horizontal .....	45
Tabla 4 Información general de la base de datos de la literatura para flujo bifásico de aceite y agua en tubería horizontal .....	46
Tabla 5 Información general de la base de datos para flujo bifásico de aceite y agua en tubería vertical.....	48
Tabla 6 Funciones de entrenamiento para las RNA.....	53
Tabla 7 Resultados de la variación en el número de neuronas en la capa oculta (# N.C.O.) usando la función de activación LogSig en tubería horizontal .....	60
Tabla 8 Resultados de la variación en el número de neuronas en la capa oculta usando la función de activación TanSig en tubería horizontal.....	63
Tabla 9 Resultados de MSE, R <sup>2</sup> y MAPE para diferentes números de neuronas en las dos capas ocultas de la red neuronal artificial para tubería horizontal.....	67
Tabla 10 Resultados de los modelos RNA implementados para tubería vertical de la literatura	72
Tabla 11 Resultados de los modelos ANFIS implementados para tubería vertical.....	74
Tabla 12 Resultados de los modelos RNA implementados para la velocidad superficial del aceite para tubería vertical de la literatura .....	76

Tabla 13 Resultados de los modelos RNA implementados para la velocidad superficial del agua para tubería vertical de la literatura .....	78
Tabla 14 Resultados de los modelos RNA implementados para tubería horizontal de la literatura .....	83

### Lista de Figuras

	<b>Pág.</b>
Figura 1 Patrones de flujo bifásico en tubería horizontal. Fuente: Elaboración propia.....	23
Figura 2 Patrones de flujo bifásico en tubería vertical. Fuente: Elaboración propia.....	25
Figura 3 Carta de flujo en tubería levemente inclinada para flujo bifásico líquido-líquido de aceite y agua. Modificada de [38].....	26
Figura 4 Carta de flujo en tubería horizontal para flujo bifásico líquido-líquido de aceite y agua. Modificada de [39].....	27
Figura 5 Estructura general de una RNA. Elaboración propia .....	30
Figura 6 Estructura general de modelo ANFIS. Elaboración propia .....	34
Figura 7 Vista esquemática del circuito experimental instalado en LEMI. Modificado de [67].	38
Figura 8 Curvas de calibración para los sensores de a) 3 KPa b) 10 KPa y c) 40 KPa. Fuente. Elaboración propia .....	39
Figura 9 Curvas de calibración para el sensor de temperatura. Fuente. Elaboración propia .....	41
Figura 10 Vista esquemática del circuito experimental diseñado para la Universidad Industrial de Santander. Elaboración propia .....	44
Figura 11 Número de datos por autor obtenidos de la literatura para tubería horizontal .....	47
Figura 12 Número de datos por autor obtenidos de la literatura para tubería vertical.....	49
Figura 13 Funciones de activación: (a) LogSig, (b) TanSig. Elaboración propia .....	55
Figura 14.....	57
Figura 15 Estructura particular del modelo ANFIS desarrollado. Elaboración propia.....	58
Figura 16. Comparación entre el MSE y el $R^2$ contenidos en la Tabla 7 para tubería horizontal	62

Figura 17 Comparación entre el MSE y el  $R^2$  contenidos en la Tabla 8 para tubería horizontal 63

Figura 18 Variación del MSE en cada iteración realizada en la RNA de configuración [3-1-15] para tubería horizontal ..... 65

Figura 19 Desempeño de la RNA entrenada con los datos experimentales obtenidos en LEMI en términos del coeficiente de correlación para tubería horizontal ..... 66

Figura 20 Comparación entre el MSE y el  $R^2$  contenidos en la Tabla 9 para tubería horizontal 68

Figura 21 Rendimiento en la fase de validación del modelo de RNA [3-2-15] para tubería horizontal ..... 69

Figura 22 Desempeño de la RNA [3-2-15] en términos del coeficiente de correlación (R) ..... 70

Figura 23 Una comparación entre  $\epsilon_{exp}$  y  $\epsilon_{pred}$  para la RNA con 12 neuronas en la capa oculta para tubería vertical de la literatura ..... 72

Figura 24 Comparación entre el MSE y el  $R^2$  contenidos en la Tabla 10 para tubería vertical de la literatura ..... 73

Figura 25 Comparación entre el MSE y el  $R^2$  contenidos en la Tabla 11 para tubería vertical de la literatura ..... 75

Figura 26 Comparación entre el MSE y el  $R^2$  contenidos en la Tabla 12 para tubería vertical de la literatura ..... 77

Figura 27 Comparación entre  $J_{oExp}$  y  $J_{oPred}$  para la RNA con 12 neuronas en la capa oculta para cada dato incluido para tubería vertical de la literatura ..... 78

Figura 28 Comparación entre el MSE y el  $R^2$  contenidos en la Tabla 13 para tubería vertical de la literatura ..... 79

Figura 29 Comparación entre  $J_{oExp}$  y  $J_{oPred}$  para la RNA con 10 neuronas en la capa oculta para tubería vertical de la literatura ..... 80

Figura 30 Mapa de flujo estructurado con valores generados por el modelo predictivo para [81]. Fuente. Elaboración propia .....	81
Figura 31 Mapa de flujo estructurado por [81]. Modificado .....	82
Figura 32 Comparación entre el MSE y el $R^2$ contenidos en la Tabla 14 para tubería horizontal de la literatura .....	84
Figura 33 Una comparación entre $\varepsilon_{\text{exp}}$ y $\varepsilon_{\text{pred}}$ para la RNA con 15 neuronas en la capa oculta para tubería horizontal de la literatura .....	85

### **Lista de Apéndices**

“Los apéndices están adjuntos y puede visualizarlos en la base de datos de la biblioteca UIS”

Apéndice A. Base de datos experimental intervalo frio.

Apéndice B. Base de datos experimental intervalo caliente.

Apéndice C. Base de datos experimental inicial en tubería horizontal.

Apéndice D. Base de datos en la horizontal de la literatura.

Apéndice E. Base de datos en la vertical de la literatura.

Apéndice F. Plantilla de cálculos para los parámetros estadísticos.

Apéndice G. Código para graficar patrones de flujo en tubería vertical.

Apéndice H. Código del modelo de RNA diseñado.

**Glosario**

$A$	área de sección transversal de la tubería
$D$	diámetro de a tubería
$A_w$	área de la sección transversal ocupada por el agua
$A_o$	área de la sección transversal ocupada por el aceite
$Q_w$	caudal de inyección de agua
$Q_o$	caudal de inyección de aceite
$C_w$	fracción volumétrica de inyección de agua
$C_o$	fracción volumétrica de inyección de aceite
$J_w$	velocidad superficial de inyección de agua
$J_o$	velocidad superficial de inyección de agua
$J$	Velocidad de la mezcla bifásica
$\mu_o$	viscosidad del aceite
$\mu_w$	viscosidad del agua
$\varepsilon_w$	holdup de agua
$\varepsilon_o$	holdup de agua
$V_w$	velocidad in situ de agua
$V_o$	velocidad in situ de aceite
$\Delta P$	Caída de presión en la línea
$S_i$	regresión logística
$i$ y $j$	nodos de la red neuronal

$w_{ij}$	peso sináptico
$b_j$	sesgo
$x_i$	entradas de los modelos
$f_1$ y $f_2$	reglas fundamentales
$\mu_{A_i}(x)$	función de membresía
$A_i$	nivel lingüístico
$O_i^n$	función nodal
$a_i, b_i$ y $c_i$	parámetros base
RNA	red neuronal artificial
$\theta$	Inclinación de la tubería
$\bar{T}$	temperatura promedio

## Resumen

**Título:** Caracterización hidrodinámica de flujos multifase empleando técnicas de inteligencia artificial \*

**Autor:** Carlos Mauricio Ruiz Díaz \*\*

**Palabras Clave:** Redes Neuronales Artificiales, Flujo bifásico líquido-líquido, ANFIS, Mapas de flujo

**Descripción:** Dada la importancia del control de procesos en la industria petroquímica, existe la necesidad de caracterizar los fluidos en el interior de las tuberías. En este trabajo se desarrolla una metodología para la identificación de patrones de flujo, cálculo de velocidades superficiales y cálculo de la fracción volumétrica de flujos bifásicos en tuberías verticales y horizontales con diámetros entre 0.01 y 0.1 [m], a partir de la implementación de técnicas de inteligencia artificial, para una combinación líquida de dos fases compuesta por aceite con viscosidad en el rango de 792 a 1823 [Kg/m<sup>3</sup>] y agua a temperatura ambiente. Los modelos predictivos generados en la estructuración de la metodología fueron entrenados con el 70% de los datos basados en parámetros de viscosidad, diámetro de la tubería, número de Reynolds, fracciones volumétricas y velocidades superficiales de los fluidos de trabajo almacenados en bases de datos para tubería horizontal y vertical. La información restante, equivalente al 30% del total, se utilizó para desarrollar la validación automática de los modelos. Los patrones de flujo identificados por el sistema inteligente para el flujo bifásico de aceite y agua son: agitado (CHURN), disperso (D), dispersión muy fina (VFD), flujo de transición (TF), intermitente (S), estratificado (ST) y anular (A), y en conjunto con los valores de velocidades superficiales y fracciones volumétricas generados por los modelos predictivos, alcanzaron un mayor nivel de aproximación con los valores experimentales al implementar estructuras de redes neuronales, dado que los modelos ANFIS presentaban valores superiores a los generados por las RNA, siendo estos 0.00016, 0.99798 y 0.1988 %, correspondientes al MSE, R<sup>2</sup> Y MAPE respectivamente.

---

\* Proyecto de Grado

\*\* Facultad de Ingenierías Fisicomecánicas. Escuela de Ingeniería Mecánica. Maestría en Ingeniería Mecánica. Director: Octavio Andrés González Estrada, PhD en Ingeniería Mecánica y de Materiales. Codirectores: Germán González Silva, PhD en Ingeniería Química, Marlon Mauricio Hernández Cely, PhD en Ingeniería Mecánica.

### Abstract

**Title:** Hydrodynamic characterization of multiphase flows using intelligence techniques \*

**Author:** Carlos Mauricio Ruiz Diaz \*\*

**Key Words:** Artificial Neural Networks, Liquid-liquid two-phase flow, ANFIS, Flow maps

**Description:** Given the importance of process control in the petrochemical industry, there is a need to characterize the fluids inside the pipes. In this work, a methodology is developed for the identification of flow patterns, calculation of the superficial velocities and the volume fraction of two-phase flows in vertical and horizontal pipes with diameters between 0.01 and 0.1 [m], from the implementation of artificial intelligence techniques, for a two-phase liquid combination composed of oil with viscosity in the range of 792 to 1823 [Kg/m<sup>3</sup>] and water at room temperature. The predictive models generated in the structuring of the methodology were trained with 70% of the data based on viscosity parameters, pipe diameter, Reynolds number, volume fractions and surface speeds of the working fluids stored in databases for horizontal and vertical pipes. The remaining information, equivalent to 30% of the total, was used to develop the automatic validation of the models. The flow patterns identified by the intelligent system for two-phase oil and water flow are: agitated (CHURN), dispersed (D), very fine dispersion (VFD), transition flow (TF), intermittent (S), stratified (ST) and annular (A), and in conjunction with the values of superficial velocities and volumetric fractions generated by the predictive models, reached a higher level of approximation with the experimental values when implementing neural network structures, given that the ANFIS models presented higher values than those generated by the ANNs, being these 0.00016, 0.99798 and 0.1988 %, corresponding to MSE, R<sup>2</sup> and MAPE respectively.

---

\* Degree project

\*\* Faculty of Physicomechanical Engineering. School of Mechanical Engineering. Master's Degree in Mechanical Engineering. Director: Octavio Andrés González Estrada, PhD in Mechanical and Materials Engineering. Co-directors: Germán González Silva, PhD in Chemical Engineering, Marlon Mauricio Hernández Cely, PhD in Mechanical Engineering.

### **Introducción**

En la industria petroquímica, de alimentos, energía, entre otros, los fluidos multifase están presentes de manera directa, por ello, se deben realizar estudios y descripciones de los fenómenos que se presentan a diario en esta temática, debido a que los flujos multifase se pueden encontrar ya sea en forma líquido-líquido (aceite-agua), gas-líquido (gas-agua o gas-aceite) o flujos trifásicos [1]. Los principales objetivos de la industria son mejorar la eficiencia de los procesos, disminuir costos, tiempos de producción y transporte de productos, así como también, aumentar la seguridad de las operaciones. De ahí la necesidad de investigar más a fondo el comportamiento fenomenológico [2] e hidrodinámico de los flujos multifase [3]–[5], con el fin de generar modelos que simplifiquen los procesos industriales.

Debido a la presencia de variables físicas y químicas en el proceso, es de vital importancia identificar los parámetros experimentales que demandan gran atención debido al grado de intervención que tienen en el experimento. Entre ellos se encuentran la viscosidad y la densidad de los fluidos, el número de Reynolds, el ángulo de inclinación de la tubería, los gradientes de presión y temperaturas en la línea. Todos estos parámetros se utilizan en este trabajo para la generación de los modelos capaces de obtener valores predictivos para la fracción volumétrica de cada fase y de sus velocidades superficiales, que a su vez permite la identificación de patrones de flujo para cada inclinación de la tubería. Por este motivo, es de gran interés crear un sistema automático inteligente que permita brindar información de los parámetros mencionados anteriormente. Para modelar el sistema inteligente, se contará con bases de datos para tubería vertical y horizontal obtenidas de la literatura, y a su vez con mediciones experimentales con rangos de errores mínimos en las velocidades superficiales de los fluidos, temperaturas y

gradientes de presión, obtenidas con instrumentación avanzada, lo cual hace de este trabajo una aplicación óptima de la inteligencia artificial en procesos de flujo multifase.

El desarrollo de la Industria 4.0 en los últimos años ha llevado a la industria petrolera a centrar su interés en el desarrollo de tecnologías que permiten obtener sistemas actualizados para la medición precisa de flujo multifásico, definiéndose este como un flujo concurrente de sustancias en determinados estados o fases (sólido, líquido, gas), los cuales generan una capa de separación con mixtura entre las fases [1], o patrones característicos [2]–[5] derivados de los parámetros hidrodinámicos iniciales del flujo en la vertical [6], [7] y en la horizontal [8], [9]. Las fases son identificadas mediante la aplicación de distintas metodologías tales como la impedancia eléctrica [10], variación de presión [11], ecos ultrasónicos [12] y análisis de imágenes ópticas [13].

Existen técnicas desarrolladas para determinar la fracción volumétrica de flujos multifase [14] con implementación de técnicas no intrusivas con el fin de no modificar temporalmente la condición real del flujo al entrar en contacto con medidores sobrepuestos en las líneas de flujo y a su vez, técnicas intrusivas [15] que modifican el flujo natural dentro de la tubería. El estudio de una técnica que cuenta con un sensor basado en la permitividad eléctrica del fluido tomando como base las tomografías de los patrones generados en el interior de la tubería con flujo bifásico de aceite y agua, fue desarrollado por [16]. Para medir el gradiente de presión y determinar la fracción volumétrica de los fluidos, [17] y [18] aplicaron una técnica de inteligencia artificial para identificar el régimen de flujo utilizando un transductor de presión diferencial de flujo multifásico. Otras técnicas como VFM (caudalímetro virtual basado en datos), desarrollada por [19], consiste en el uso de medidores de flujo virtuales basados en datos capaces de determinar las tasas de flujo

aplicando de manera directa una técnica de aprendizaje automático como lo son las redes neuronales artificiales [20], [21].

Las aplicaciones de las técnicas de computación fueron estudiadas por [22] para la medición de flujo multifásico [23] y definir el estado de los avances desarrollados en medidores de flujo multifase. De manera particular, [24] aplica una metodología basada en el reconocimiento de patrones de distribuciones de altura de pulso de una red neuronal artificial (RNA) proponiendo un enfoque para la predicción independiente de la fracción volumétrica en flujos multifásicos al igual que [25] innovando con el reconocimiento de patrones de PHD por medio de la red neuronal. Cuatro modelos RBF (red neuronal de base radial) fueron desarrollados por [23], en los cuales se identifica de manera acertada cada régimen de flujo trifásico y [26] introduce una red híbrida en la que emplea un algoritmo de optimización (GWO) para entrenar la red neuronal y obtener valores de error medio, así como la determinación de las velocidades de los fluidos [27].

Se han propuesto modelos de dinámica computacional, CFD, para describir flujos multifásicos [28], entre otras herramientas útiles en la determinación eficiente de la fracción volumétrica del flujo multifásico como lo muestra [29], el cual desarrolla un modelo CFD-DEM de captura en la interfaz con un modelo a escala de partículas para el flujo de gas-líquido-sólido con lo cual se busca detallar todas las características del fluido [30] y la formación de gotas en la extracción de solventes [31] y flujos burbujeantes [32] y [33].

Los modelos metaheurísticos se han utilizado para optimizar la localización de pozos de producción [34]. El trabajo en [35] centra su estudio en establecer un procedimiento moderno basado en el análisis de datos derivado de machine learning para trabajar con sistemas dinámicos aplicando modelos de POD [36] en la combinación de regresiones.

En este trabajo, con el objetivo caracterizar flujos bifásicos de aceite y agua a través de un ducto con distintas inclinaciones previamente montado y calibrado en el laboratorio LEMI (Laboratorio de Escoamentos Multifásicos Industriais - EESC-USP, Brasil), por el cual fluyen sustancias en estado líquido y gaseoso, se generaron modelos predictivos a partir de datos experimentales, complementados por dos bases de datos estructuradas de la literatura para tubería vertical y horizontal, con distintos rangos de viscosidades y diámetros de tubería, las cuales amplificaron la capacidad de aprendizaje de los modelos inteligentes, entregando automáticamente resultados de fracciones volumétricas y velocidades superficiales de los fluidos de trabajo con una precisión elevada. Estos datos servirán para implementar modelos en plataformas industriales mejorando su eficiencia en el monitoreo en tiempo real del proceso de transporte de hidrocarburos, bajo los conceptos desarrollados a continuación.

### **Fundamentos teóricos para flujos bifásicos**

En esta sección son presentados los fundamentos teórico-prácticos que permiten caracterizar el flujo bifásico líquido-líquido compuesto por agua y aceite, además de los patrones de flujo existentes en la literatura.

#### ***Flujo bifásico de aceite y agua***

Una fase simple de la materia se puede presentar como un gas, un sólido o un líquido. Un flujo multifásico se desarrolla cuando de manera práctica interactúan simultáneamente dichas fases. De forma simplificada, un flujo multifásico es aquel formado por dos fases, denominado flujo bifásico, el cual es caracterizado a partir de la identificación de su estructura morfológica, la viscosidad de la mezcla, caídas de presión en la línea, inversiones de fase y fracciones volumétricas.

Los flujos bifásicos pueden ser caracterizados a partir de la definición de los conceptos fundamentales que lo describen, tales como las fracciones volumétricas, las velocidades superficiales de inyección y las velocidades in situ de los fluidos, considerando un flujo simultáneo a través de una tubería con sección transversal  $A$ . De manera específica, en el presente trabajo se utiliza una nomenclatura única para los fluidos enunciados, dado que todos los parámetros escritos con el sobrescrito  $w$  hacen referencia a la fase de agua y la letra  $o$  a la fase de aceite.

### ***Fracciones volumétricas de inyección***

Los caudales de inyección  $Q_w$  y  $Q_o$  de las fases de agua y aceite permiten determinar una característica importante en los flujos multifásicos, denominada fracción volumétrica  $C$  de inyección de las fases, así:

$$C_w = \frac{Q_w}{Q_w + Q_o}, \quad C_o = \frac{Q_o}{Q_w + Q_o} \quad (1)$$

### ***Velocidades superficiales de inyección***

Las velocidades superficiales de la fase de agua  $J_w$  y aceite  $J_o$ , basadas en los caudales de inyección y en el área de sección transversal de la tubería son definidas en la Ecuación (2) y permiten mediante la suma de sus magnitudes, obtener la velocidad de la mezcla  $J$ , definida en la Ecuación (3) como sigue:

$$J_w = \frac{Q_w}{A}, \quad J_o = \frac{Q_o}{A} \quad (2)$$

$$J = J_w + J_o \quad (3)$$

Combinando las Ecuaciones (1) y (2) se obtiene la relación de velocidades superficiales con las fracciones volumétricas de inyección.

$$\frac{J_w}{J_o} = \frac{C_w}{C_o} \quad (4)$$

### ***Holdup o fracción volumétrica in situ***

En un flujo bifásico se asume que cada una de las fases que lo integra ocupa una fracción de la sección transversal de la tubería de área  $A$ . De manera específica, se definen como  $A_w$  el área ocupada por el agua y  $A_o$  por el aceite, y permiten determinar la fracción volumétrica in situ o holdup de cada fase al interior de la tubería:

$$\varepsilon_w = \frac{A_w}{A}, \quad \varepsilon_o = \frac{A_o}{A} \quad (5)$$

### ***Velocidades in situ***

Por lo anterior, la velocidad superficial de cada fluido ( $J_w$  y  $J_o$ ) es diferente a la velocidad in situ de los mismos ( $V_w$  y  $V_o$ ), debido al deslizamiento ocurrido entre las fases de la mezcla multifásica. Dichas velocidades in situ se calculan a partir del caudal que fluye por el área específica ocupada por cada fase, menor a la sección transversal del tubo. Asimismo,

$$V_w = \frac{Q_w}{A_w}, \quad V_o = \frac{Q_o}{A_o} \quad (6)$$

La velocidad in situ o real también se puede expresar en términos de la velocidad superficial de la fase y su holdup como:

$$V_w = J_w \epsilon_w, \quad V_o = J_o \epsilon_o \quad (7)$$

### *Patrones de flujo bifásico en tubería horizontal*

Descritos los términos anteriores, es de gran importancia definir una característica fundamental en el estudio de los flujos bifásicos, correspondiente a los patrones de flujo que se presentan al combinar sustancias inmiscibles o en diferentes fases, que, a partir de condiciones específicas, presentan configuraciones geométricas especiales dentro de la tubería por la cual fluyen. La inclinación de la tubería es un parámetro fundamental en la formación de patrones de flujo, los cuales presentan comportamientos específicos para ángulos diferentes, estandarizando de manera general 3 categorías principales que son: flujo disperso (dispersiones, emulsiones), flujo de fases separadas (estratificado, anular) y flujo intermitente (pistonado). Por lo anterior, se definen los patrones de flujo de agua y aceite dentro de tuberías horizontales y verticales.

Según la literatura, para una relación de viscosidades moderada, los patrones de flujo observados en tuberías horizontales para flujo bifásico de aceite y agua, mostrados en la Figura 1, son los siguientes:

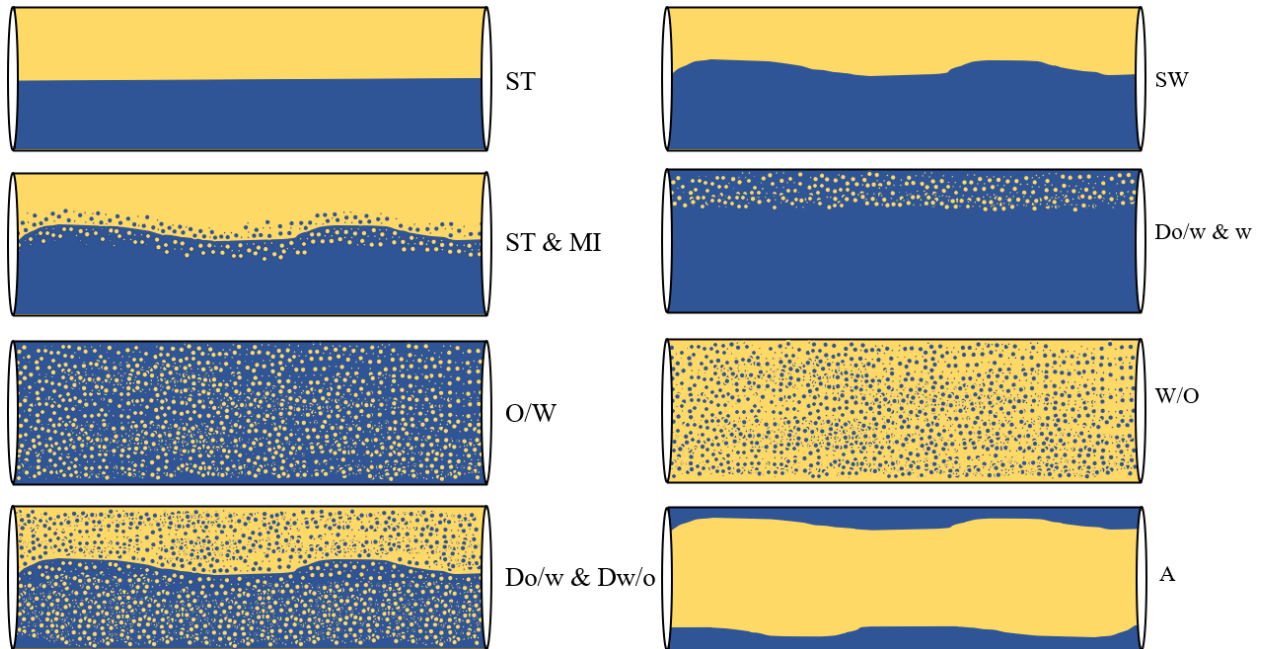
- **Estratificado (ST):** Se presenta para velocidades bajas de los fluidos, donde el flujo es dominado por la gravedad, por lo cual, la fase más densa se ubica en el fondo de la tubería y la menos densa en la parte superior. De manera específica, cuando se presentan ondas en la interfase de contacto entre los fluidos, el patrón de flujo se conoce como **Estratificado**

**ondulado (SW).** En algunas ocasiones se perciben gotas alargadas y de gran diámetro, este patrón de flujo se conoce como intermitente (**I**).

- **Estratificado con mezcla en la interfase (ST & MI):** Se presenta para velocidades superficiales mayores a las del patrón de flujo estratificado. Pueden observarse gotas de agua en la capa de aceite y gotas de aceite en la capa de agua.
- **Dispersión de aceite en agua sobre una capa de agua (Do/w & w):** Se presenta para velocidades superficiales altas de agua en un flujo dominado por ella, donde se percibe una dispersión de aceite en los vórtices acuosos que están en las proximidades de la interfase.
- **Dispersión homogénea de aceite en agua (o/w):** Se presenta para velocidades superficiales de agua extremadamente altas, donde se percibe una dispersión densa totalmente definida de la fase discontinua de aceite en la fase continua de agua.
- **Dispersión homogénea de agua en aceite (w/o):** Se presenta para velocidades superficiales de aceite extremadamente altas y es semejante al patrón de flujo o/w, pero en este caso, la fase de aceite es continua y la fase de agua es dispersa.
- **Dispersión de aceite en agua y dispersión de agua en aceite (Do/w & Dw/o):** Se presenta para velocidades superficiales altas de agua y de aceite, donde partiendo del patrón de flujo ST & MI, la región cercana al interfaz comienza a crecer y los dos tipos de dispersión comienzan a coexistir, ocupando la mayor parte de la sección transversal de la tubería.
- **Anular (A):** Se presenta cuando las fases líquidas poseen una alta razón de viscosidades, donde se puede percibir que una fase fluyendo en el núcleo del tubo (aceite), es circundada por una segunda fase fluyendo junto a las paredes del tubo (agua).

**Figura 1**

*Patrones de flujo bifásico en tubería horizontal. Fuente: Elaboración propia*



### *Patrones de flujo bifásico en tubería vertical*

En la Figura 2 se esquematizan los patrones de flujo observados en tuberías verticales para flujo bifásico de aceite y agua con alta razón de viscosidades. Según [37], los patrones más comunes para dicha inclinación son los siguientes:

- **Gotas dispersas (DD):** La simbología es proveniente del término inglés drope, referente al desarrollo de gotas de fluido no compresible se presenta para caudales bajos de aceite y altos de agua. También puede ser llamado dispersión de aceite en agua, donde las gotas de aceite pequeñas, y prácticamente esféricas, son arrastradas por el gran caudal de agua siguiendo la tendencia del perfil de velocidad esperado para el flujo monofásico de agua

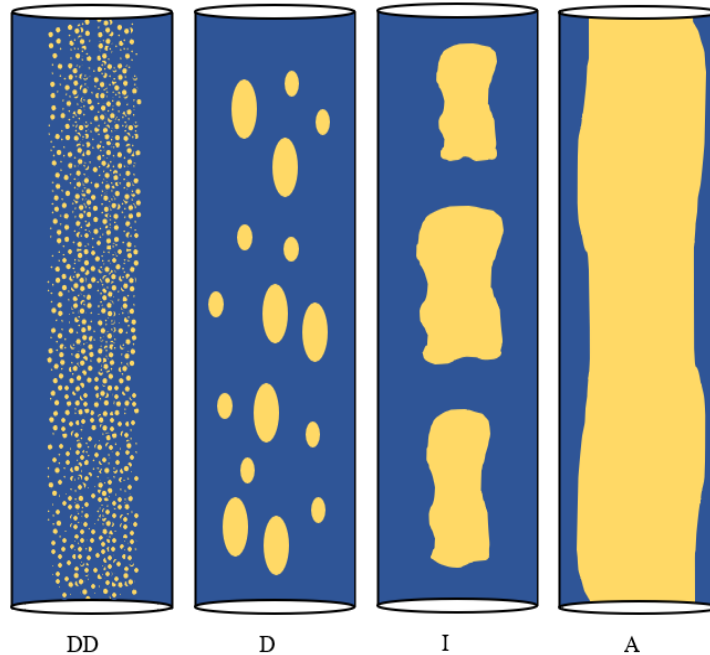
en una tubería (mayores velocidades en el centro del tubo y menores en las proximidades de la pared). Cuando la dispersión se percibe de manera homogénea y plenamente desarrollada, se dice que es una dispersión fina y se reconoce por las siglas VFD.

- **Gotas (D):** Se presenta para caudales elevados de aceite y bajos de agua en comparación con el patrón de gotas dispersas (DD). Las gotas poseen un diámetro mayor y se presentan en formas de esfera, tapón elíptico y tapón esférico.
- **Intermitente (I):** Aumentando el caudal de aceite, a partir del patrón de flujo de gotas (D), las gotas tienden a unirse en grandes gotas alargadas, separadas por grandes espacios de agua. Cuando el diámetro de la gota alargada se aproxima al diámetro de la tubería y presenta comportamiento de un pistón mecánico, se denomina **slug (S)**. Si la fase continua de agua se presenta con gotas dispersas, también se puede denominar **churn**, que también se puede determinar cuando existe coalescencia de los pistones de líquido secuenciales, lo cual genera ruptura en las interfases, flujo reverso e inestabilidades interfaciales prominentes generando un comportamiento turbulento del flujo.
- **Anular (A):** En este patrón, el aceite fluye en el núcleo del tubo circundado por una película de agua. Se presenta para mayores caudales de agua, en comparación con el patrón de flujo intermitente (I). La interfase presenta una estructura ondulatoria que depende de las velocidades de inyección de las fases. La película de agua puede presentar gotas dispersas y el núcleo de aceite puede presentar distorsiones o perturbaciones de alta frecuencia y se puede denominar **core flow**.

De manera general, cuando se presenta la variación de un estado de patrón de flujo a otro, se concreta un comportamiento intermedio denominado flujo de transición y se reconoce por las siglas TF.

**Figura 2**

*Patrones de flujo bifásico en tubería vertical. Fuente: Elaboración propia*

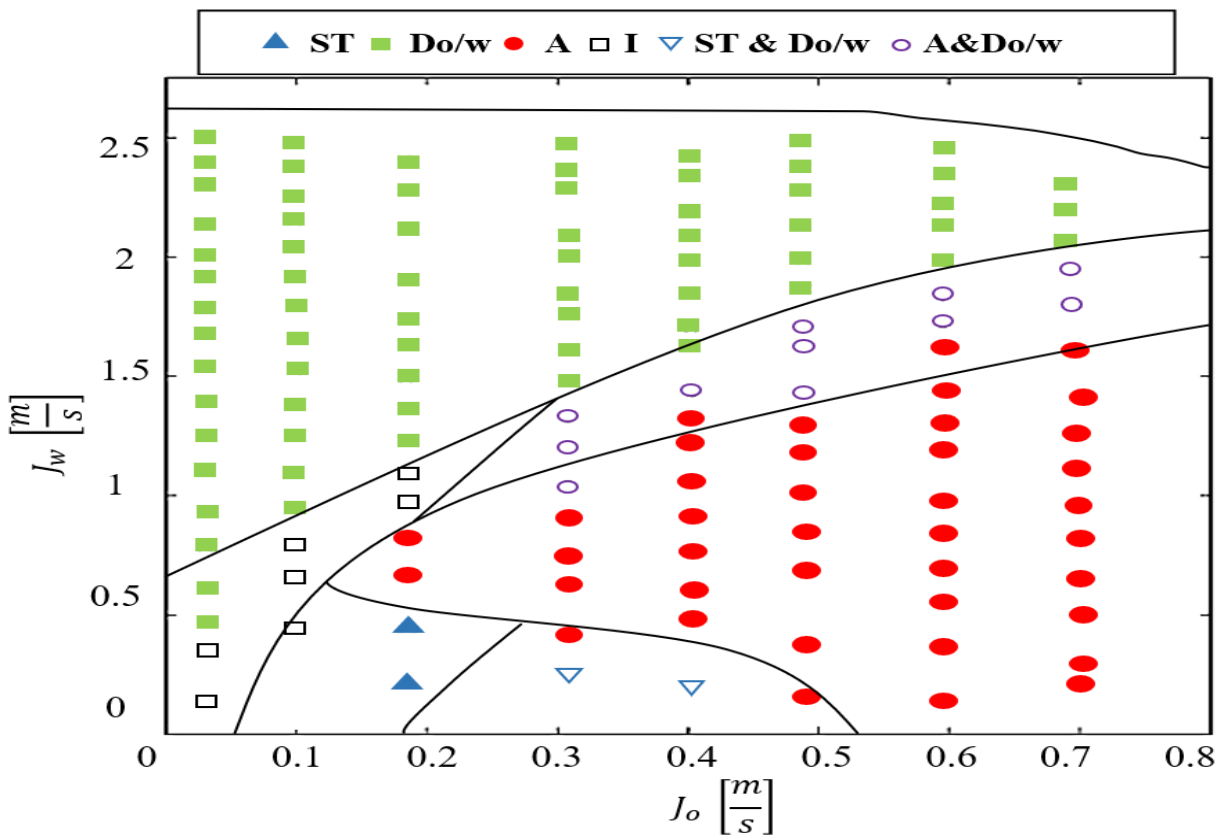
***Cartas de flujo o mapas de flujo***

Los mapas o cartas de flujo son herramientas utilizadas en la determinación de los patrones de flujo en función de las velocidades superficiales de las fases (o flujos volumétricos, fracciones volumétricas, velocidad total, caída de presión y combinaciones), donde se puede apreciar gráficamente que las fronteras de transición entre patrones de flujo están directamente relacionadas con la geometría de la tubería y las propiedades de los fluidos. Dichas herramientas son utilizadas en la generación de modelos mecanicistas que permitan identificar con mayor precisión la ubicación de las fronteras de transición entre fases y los patrones de flujo que se integran en ellas.

En las Figuras Figura 3 y Figura 4 se presentan ejemplificaciones de esquemas para mapas de flujo en tubería levemente inclinada y horizontal, respectivamente, tomando como parámetros las velocidades superficiales del aceite y del agua, donde se esquematizan los siguientes patrones de flujo: estratificado (ST), Dispersión de aceite en agua (Do/w), anular (A), intermitente (I), estratificado con dispersión de aceite en agua (ST & Do/w) y finalmente Anular con dispersión de aceite en agua.

**Figura 3**

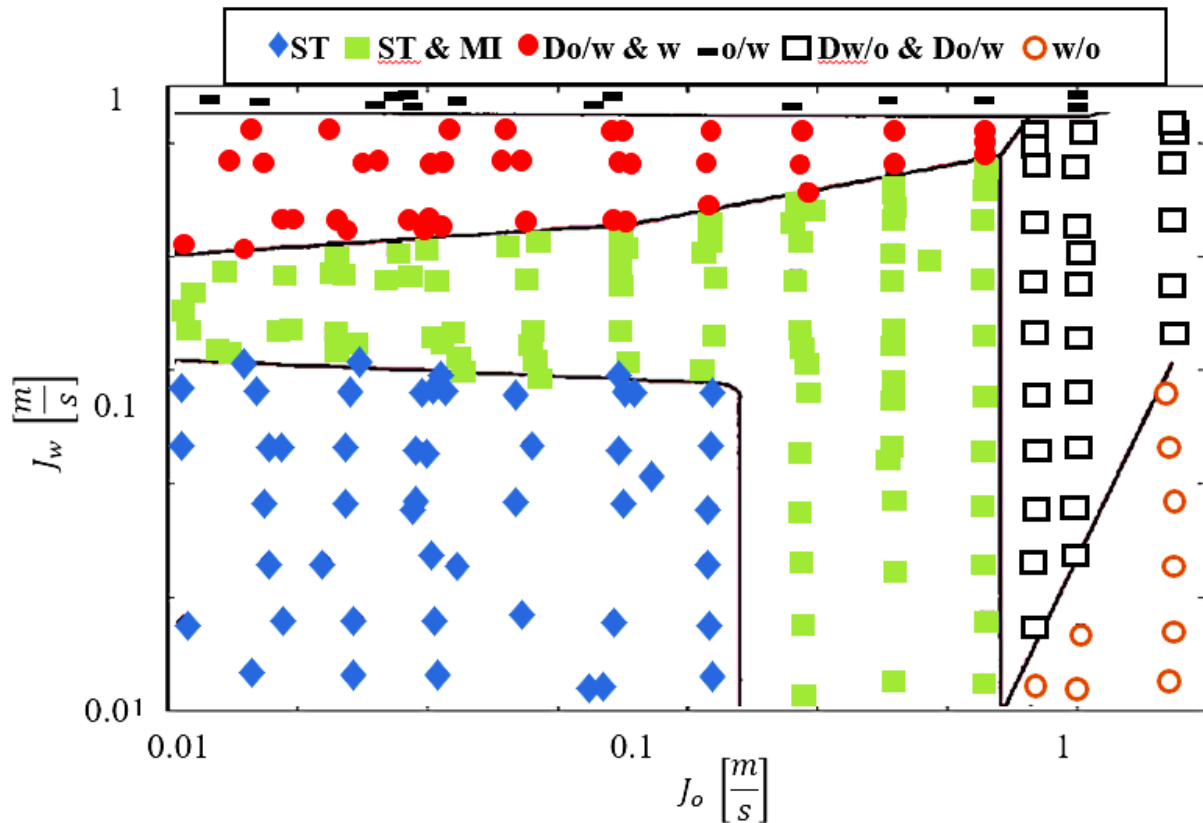
*Carta de flujo en tubería levemente inclinada para flujo bifásico líquido-líquido de aceite y agua. Modificada de [38]*



**Figura 4**

*Carta de flujo en tubería horizontal para flujo bifásico líquido-líquido de aceite y agua.*

*Modificada de [39]*



**Técnicas de inteligencia artificial**

A seguir se encuentran especificadas las principales técnicas de inteligencia artificial, machine learning y deep learning aplicadas en la caracterización de flujos multifásicos.

**Redes neuronales artificiales**

Los modelos de RNA son una rama de los métodos actuales de inteligencia artificial desarrollados para trabajar con una gran cantidad de datos [22], los cuales, mediante el análisis y

relacionamiento de la información logran entrenar redes artificiales como en [40] inspiradas en las redes neuronales biológicas. Las redes neuronales artificiales permiten desarrollar trabajos con desempeño elevado a partir de modelos no lineales para los que se tiene como mínimo una entrada, la cual se conecta de manera secuencial con nodos de la red que integran neuronas con sus respectivos pesos sinápticos y sesgos y, finalmente, una salida que representa la predicción del modelo, como puede ser visto en [2]. Asimismo, es una característica común en esta técnica tener implementadas capas ocultas, además de realizar la integración de funciones de propagación, activación, y transferencia. La función de los pesos sinápticos es realizar una modificación de la información que pasa de nodo a nodo, con el fin de disminuir la función error en cada interconexión de la red, que, al sumarse con los respectivos sesgos, permiten obtener el valor de la predicción final, o entrada al nodo siguiente en caso de poseer capas ocultas.

Las RNA son capaces de extraer patrones y se particularizan a partir de tres características fundamentales, las cuales son:

- Topología de la red: forward propagation [41], [42], o backpropagation [43], [44].
- Regla de aprendizaje: supervisado, no supervisado, forzado.
- Tipo de entrenamiento.

La aplicación de redes neuronales artificiales abarca un gran campo de la ciencia, dentro de la cual se incluyen funciones para el reconocimiento de patrones [45], memoria asociativa, realizar predicciones, aproximar funciones, modelar sistemas complejos [3], [4], así como procesar y clasificar imágenes [16].

De manera matemática, la expresión general para determinar el valor de la capa de salida en la red neuronal artificial se determina mediante la Ecuación (8) [46] y se conoce también como regresión logística:

$$S_i = \sum_{j=1}^m x_i w_{ij} + b_j \quad (8)$$

Donde  $S_i$  es la salida neta del nodo (neurona)  $j$  en la capa oculta o de salida,  $x_i$  son las entradas al nodo  $j$  (o salidas de la capa inmediatamente anterior),  $w_{ij}$  son los pesos que representan el grado de relación o conexión entre los nodos  $i$  y  $j$ ,  $i$  es la cantidad de nodos y  $b_j$  es el sesgo que esta relacionado con cada nodo  $j$ .

Los términos anteriormente descritos son procesados mediante una función de transferencia, la cual determina de manera precisa la salida que se está buscando. En recientes investigaciones, se han utilizado las funciones de activación tangente hiperbólica sigmoidea (TanSig) y logarítmica sigmoidea (LogSig) [47], siendo estas las funciones de activación más comunes en el tratamiento de datos con ecuaciones no lineales definidas por las Ecuaciones (9) y (10), respectivamente, debido al ajuste optimo que presentan con modelos linealizados de salida en los intervalos  $[0,1]$  y  $[-1,1]$ , lo cual, se relaciona directamente con el descenso de gradiente. Otras funciones de activación son la unidad lineal exponencial escalada (RELU) y función de base radial, entre otras.

$$\text{TanSig}(S_j) = f(S_j) = \frac{e^{S_j} - e^{-S_j}}{e^{S_j} + e^{-S_j}} \quad (9)$$

$$\text{LogSig}(S_j) = f(S_j) = \frac{1}{1 + e^{-S_j}} \quad (10)$$

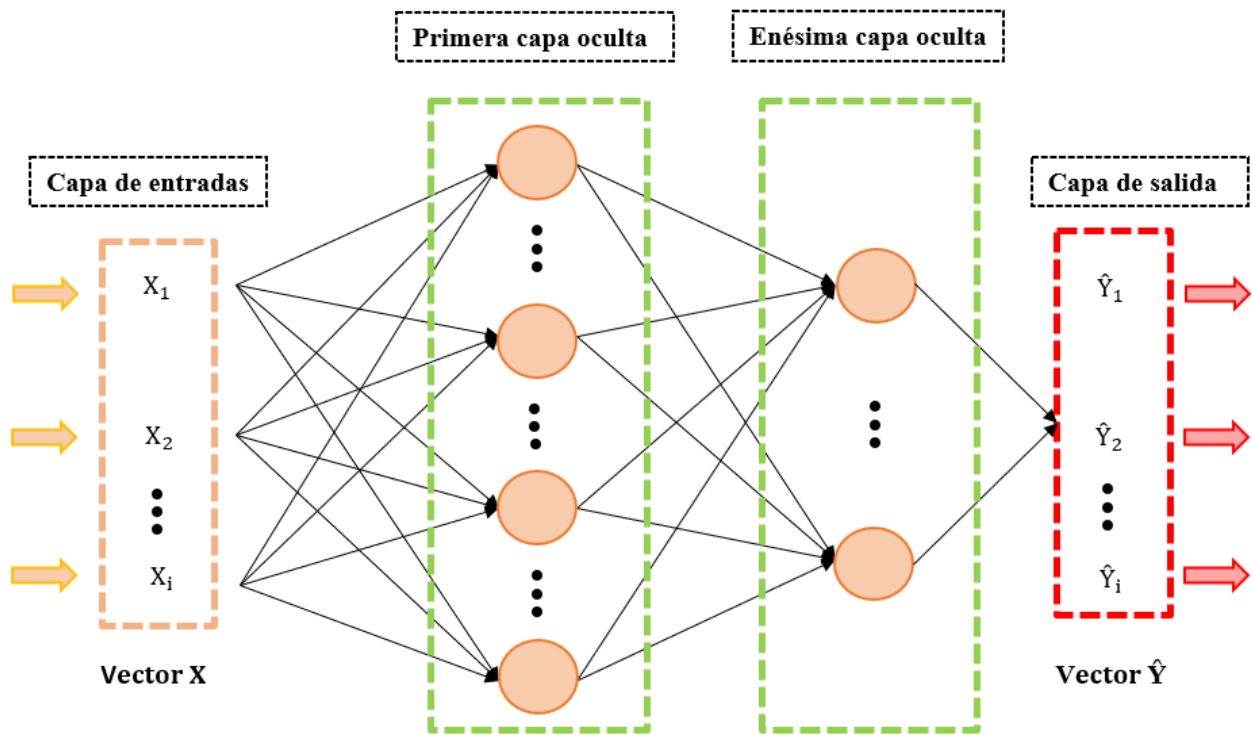
Para flujo bifásico se han realizado distintas adaptaciones de RNA, en las cuales se calculan la caída de presión en una tubería horizontal con flujo gas y aceite [48], la tasa de petróleo en

pozos de elevación de gas [49], caudales de los fluidos [50]. También se han modelado entornos y esquemas de control predictivo para la extracción de petróleo por gas, a partir de la aplicación de RNA para sistemas no lineales para la estabilización de pozos [51].

Para flujo de petróleo y agua se implementan modelos de RNA para medir los parámetros de flujo de alta presión y la impedancia de los sensores ubicados en la línea [52], determinar la fracción volumétrica de los fluidos en una tubería horizontal [53] y para predecir la permeabilidad relativa de del flujo bifásico de agua y aceite en la arenisca y el carbonato de las rocas de una yacimiento [54]. La estructura general de una RNA perceptrón multicapa se presenta en la Figura 5.

**Figura 5**

*Estructura general de una RNA. Elaboración propia*



***Adaptive neuro fuzzy inference system (ANFIS)***

En los sistemas de inferencia fuzzy (FIS) se aplica lógica difusa para proporcionar un modelo de aproximación que incluye reglas de cálculo y relaciones matemáticas propias [55], donde las variables numéricas son reemplazadas por variables lingüísticas. Por lo tanto, la generación de mapas de flujo e identificación de patrones de flujo en flujos multifásicos [56], es posible definiendo intervalos de aceptación de la respuesta del sistema [57]. Un sensor de capacitancia eléctrica fue implementado por [58] para generar imágenes que a partir de un sistema de inferencia difusa (FIS), determinó la distribución de fluidos dentro de una tubería.

Un modelo ANFIS es una aplicación de red neuronal artificial multicapa, la cual se basa en un sistema de inferencia fuzzy formado por 5 capas internas. La estructura general para un modelo ANFIS fue desarrollada por [59], al proponer una metodología para la evolución de modelos predictivos basados en modelamientos matemáticos particulares como el desarrollado por [60], para la derivación de reglas de control fuzzy en operadores humanos. El modelo general de dicha estructuración se esquematiza en la Figura 6.

El modelo parte de dos reglas fundamentales  $f_1$  y  $f_2$ , en las cuales se toman las entradas  $x_1$  y  $x_2$  como entradas, descritas en las Ecuaciones (11) y (12) con  $a_i, b_i$  y  $c_i$  como conjunto de parámetros base y  $p_i, q_i$  y  $r_i$  como conjunto de parámetros consecuentes.

$$\text{Regla 1: si } x_1 \text{ es } A_1 \text{ y } x_2 \text{ es } B_1, \text{ luego } f_1 = p_i x_1 + q_i x_2 + r_i \quad (11)$$

$$\text{Regla 2: si } x_1 \text{ es } A_2 \text{ y } x_2 \text{ es } B_2, \text{ luego } f_2 = p_i x_1 + q_i x_2 + r_i \quad (12)$$

En la primera capa, representada matemáticamente por la Ecuación (13), cada entrada ingresa a un nodo  $i$ , donde se establecen las funciones de membresía  $\mu_{A_i}(x)$  a partir de la aplicación de la Ecuación (14) para cada nivel lingüístico  $A_i$  y  $B_i$  en su respectiva función nodal  $O_i^1$ .

$$O_i^1 = \mu_{A_i}(x) \quad (13)$$

$$\mu_{A_i}(x) = \frac{1}{1 + \left| \frac{x - c_i}{a_i} \right|^{2b_i}} \quad (14)$$

En la segunda capa se desarrolla el producto entre las señales entrantes a cada nodo, generando las salidas  $w_i$  en cada uno de ellos.

$$O_i^2 = w_i = \mu_{A_i}(x_1) * \mu_{B_i}(x_2), i = 1,2. \quad (15)$$

En la tercera capa se realiza el cálculo de las salidas normalizadas  $\bar{w}_i$  de cada nodo, cómo se muestra en la Ecuación (16).

$$O_i^3 = \bar{w}_i = \frac{w_i}{w_1 + w_2}, i = 1,2. \quad (16)$$

En la cuarta capa se encuentra un nodo adaptativo  $O_i^4$ , junto con una función nodal en la cual se determina el grado de intervención de la  $i$ -ésima regla en la salida del modelo, Ecuación (15), donde  $\bar{w}_i$  es la salida de la capa 3, y  $\{p_i, q_i y r_i\}$  son los denominados parámetros consecuentes.

$$O_i^4 = \bar{w}_i f_i = \bar{w}_i (p_i x_1 + q_i x_2 + r_i), i = 1, 2. \quad (17)$$

En la quinta capa se encuentra un nodo fijo  $O_i^5$ , el cual calcula la salida global del modelo como la suma de todas las señales entrantes, Ecuación (16).

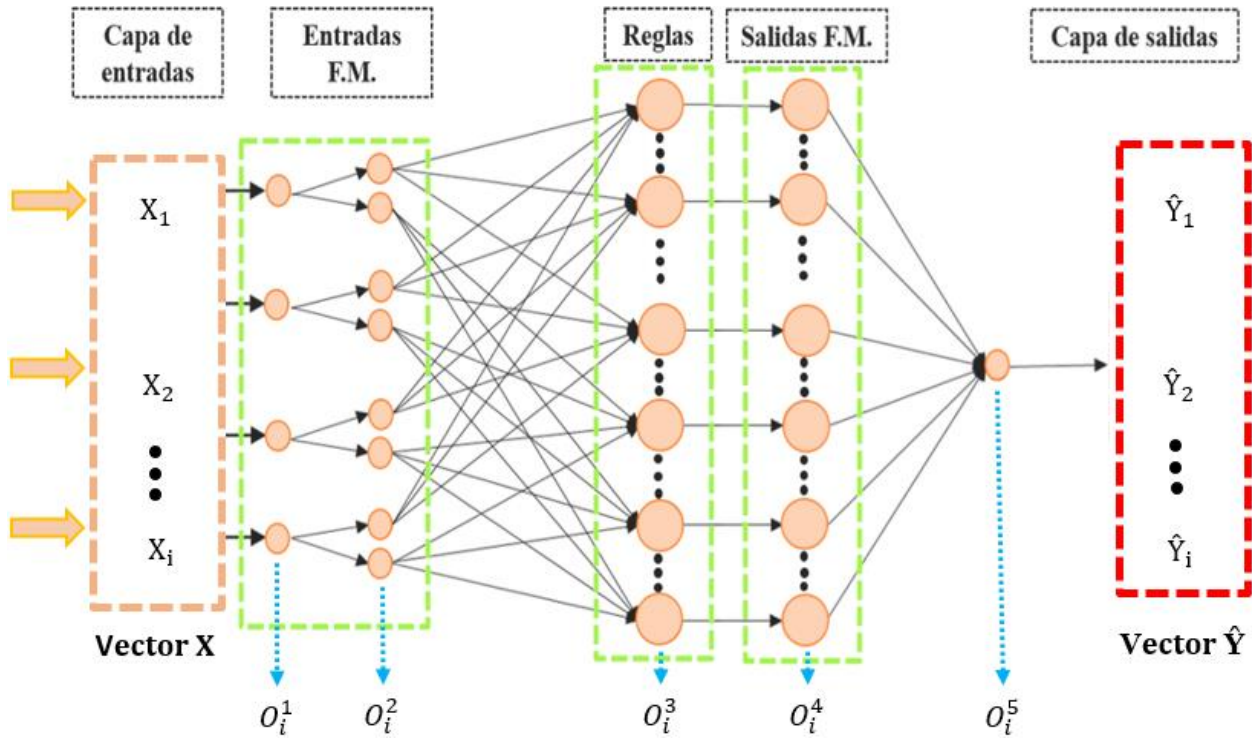
$$O_i^5 = \sum_{i=1}^2 \bar{w}_i f_i = \frac{w_1 f_1 + w_2 f_2}{w_1 + w_2} \quad (18)$$

Los modelos ANFIS han sido de gran utilidad en estudios industriales, al ser aplicados con el fin de obtener un modelo capaz de predecir caudales estacionales en centrales hidroeléctricas [61]. Para ello, se han diseñado sistemas de inferencia difusa basado en redes neuronales adaptativas (ANFIS) y se han comparado con modelos de RNA perceptrón multicapa [62]. Asimismo, un sistema difuso de clasificación, fue diseñado en [63] para monitorear las fugas en una tubería que transportaba petróleo, determinando así, los cambios operativos en la misma, a partir de las mediciones de sensores SCADA y determinar los regímenes de flujo y la fracción volumétrica del líquido en flujo bifásico en una tubería horizontal [64].

Para generar un modelo inteligente capaz de obtener predicciones de la caída de presión en tuberías verticales debida a la interacción del flujo multifásico que transporta, [65] implementó un modelo ANFIS, utilizando como parámetros fundamentales las características hidrodinámicas de los fluidos. Para generar una predicción del tamaño de las gotas (diámetro) de un flujo bifásico de microfluidos, [66] utilizó un sistema de inferencia difusa para estudiar el comportamiento de parámetros adimensionales considerados como entradas, tales como el número capilar, el número de Reynolds, la relación de flujos y la relación de viscosidad y el diámetro de las gotas la salida del modelo ANFIS.

**Figura 6**

*Estructura general de modelo ANFIS. Elaboración propia*



## **1. Objetivos**

### **1.1. Objetivo General**

Analizar las características hidrodinámicas y el comportamiento de los fenómenos presentes en flujos multifase, aplicando técnicas de inteligencia artificial que permitan optimizar el proceso de transporte de hidrocarburos.

### **1.2. Objetivos Específicos**

Montar, ajustar y calibrar la bancada experimental en el laboratorio LEMI- EESC/USP, haciendo uso de control computarizado en la misma para obtener una base de datos experimentales de flujo multifase y realizar pruebas preliminares.

Analizar y procesar los datos experimentales con el fin de seleccionar los parámetros principales para el entrenamiento de modelos basados en inteligencia artificial haciendo uso de software especializado como Matlab.

Clasificar los datos experimentales según el patrón de flujo que se evidencia en las pruebas experimentales, haciendo uso de las herramientas Excel y Matlab para realizar un mapa de patrones de flujo.

Proponer una metodología basada en inteligencia artificial para caracterizar la fenomenología de los fluidos multifase con la finalidad de implementar técnicas mejoradas de control y medición de flujo en tubería en la industria de hidrocarburos.

## 2. Alcance

Con la realización del trabajo se logrará la estructuración de un esquema de banco de laboratorio con escala industrial especializado en análisis de flujos multifase en tubos horizontales y en diversos ángulos de inclinación, contando con una variedad de ductos que extienden la capacidad experimental del laboratorio. Además, el esquema de la bancada experimental contará con dispositivos de alta tecnología instalados en la línea, los cuales determinarán con precisión las medidas que permitan hacer la ampliación a la industria de hidrocarburos real.

Adicionalmente, se estructurará una base de datos con gran variedad de puntos experimentales tomados con distintas sustancias, haciendo combinaciones entre ellas, lo cual amplía el nivel de estudio de los flujos multifase, siendo este un proceso complejo que aún se encuentra en exploración. Dicha base de datos será el punto de partida para la implementación de técnicas de inteligencia artificial con el fin de optimizar los procesos, generando modelos predictivos a partir de su aplicación a la temática de flujos multifase.

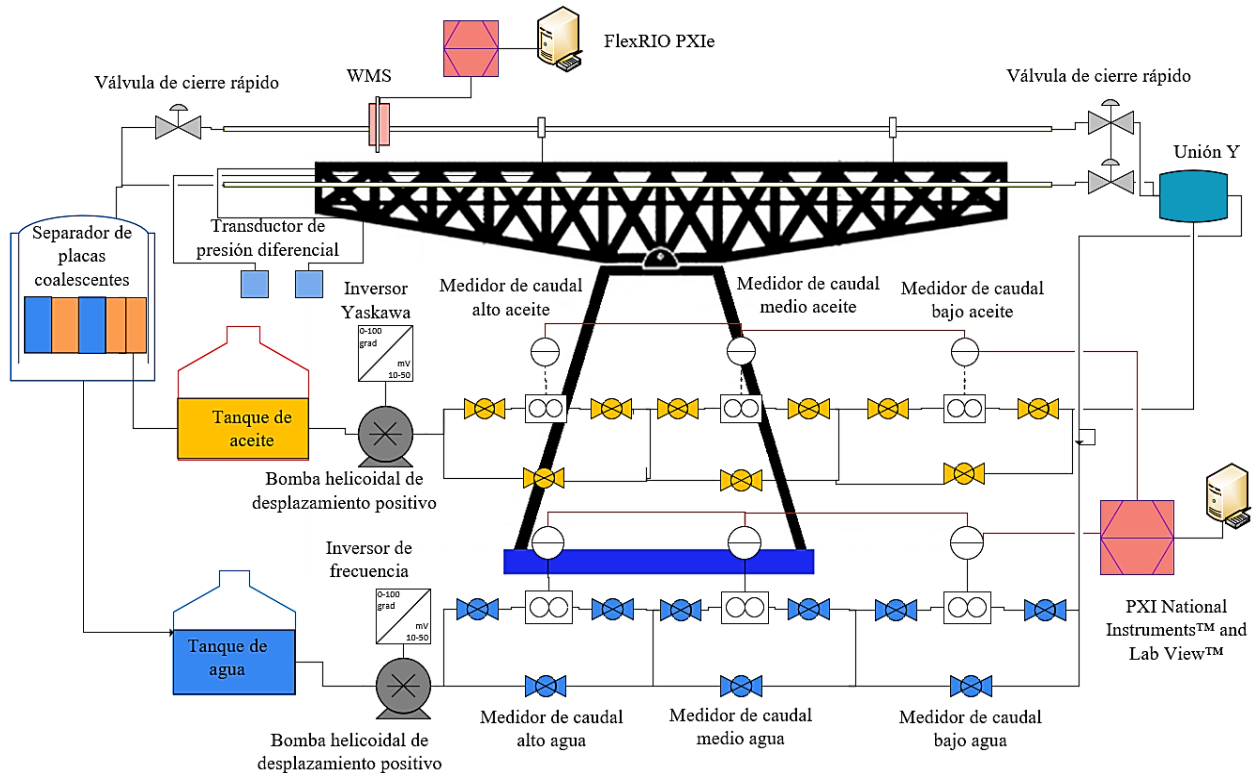
### 3. Metodología

#### 3.1. Aparato experimental

Se realizó el diseño de ingeniería para la selección de instrumentos a implementar en el banco experimental en las instalaciones del *Laboratorio de Escoamentos Multifásicos Industriais* (LEMI), del Departamento de Ingeniería Mecánica de la Escuela de Ingeniería de São Carlos (EESC) de la Universidad de São Paulo (USP), desarrollando el montaje de los recursos estructurales y técnicos adecuados para el estudio de problemas de elevación y transporte de fluidos de representativa aparición en la industria de petróleo. Asimismo, se llevó a cabo la adaptación, desarrollo, validación y documentación de calibración de instrumentos. El aparato experimental es presentado esquemáticamente en la Figura 7, el cual cuenta con instrumentación avanzada para la caracterización y análisis de flujo multifásico industrial, como sensores del tipo *wire mesh* (WMS) [16], cámaras de alta velocidad, densitómetros de rayos gama e instrumentos basados en laser usados para analizar la sección transversal del flujo, patrones de flujo y perfiles de velocidad para flujos turbulentos monofásicos y flujos turbulentos multifásicos.

**Figura 7**

*Vista esquemática del circuito experimental instalado en LEMI. Modificado de [67]*



Las pruebas experimentales se realizaron con agua convencional de viscosidad 1 [cP], densidad específica de 997 [Kg/m<sup>3</sup>] a temperatura ambiente, en conjunto con aceite mineral LUBRAX turbina 100 con viscosidad de 180 [cP] y densidad específica de 880 [Kg/m<sup>3</sup>], en una tubería de vidrio de borosilicato con sección transversal circular con 1 y 2" de diámetro interno, 12 [m] de longitud total y 4.5 [mm] de espesor en su pared. Cada tubo de la línea de prueba tiene una longitud de 1.5 [m]. El sistema es alimentado a partir de dos bombas de desplazamiento positivo controladas cada una por un variador de frecuencia independiente y a su vez, todo el

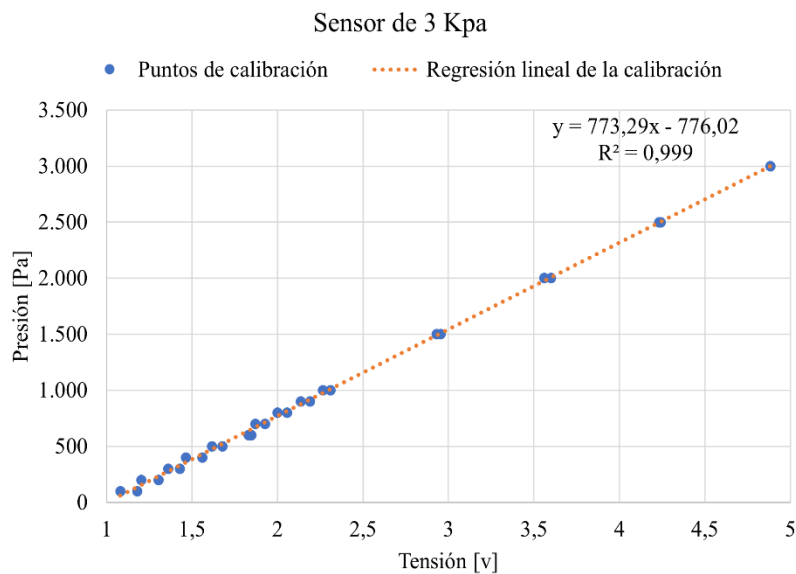
conjunto de procesos se desarrolla utilizando los equipos organizados en la Tabla 1, y cuantificados con los instrumentos de medición instalados como se muestra en la Tabla 2.

Adicionalmente, la bancada experimental mostrada en la Figura 7, cuenta con un sistema que permite modificar la inclinación de la tubería con una variación angular que inicia en la horizontal y alcanza una ubicación de  $\pm 5^\circ$ , la cual fue ajustada con apoyo del personal técnico propio del laboratorio LEMI, así como también las bombas, válvulas direccionales y componente electrónicos. Los sensores de presión y temperatura instalados en la línea fueron debidamente calibrados, tal como se muestra en las Figura 8 y Figura 9 respectivamente. De esa forma, el laboratorio adoptó las características necesarias para el desarrollo del trabajo de forma satisfactoria.

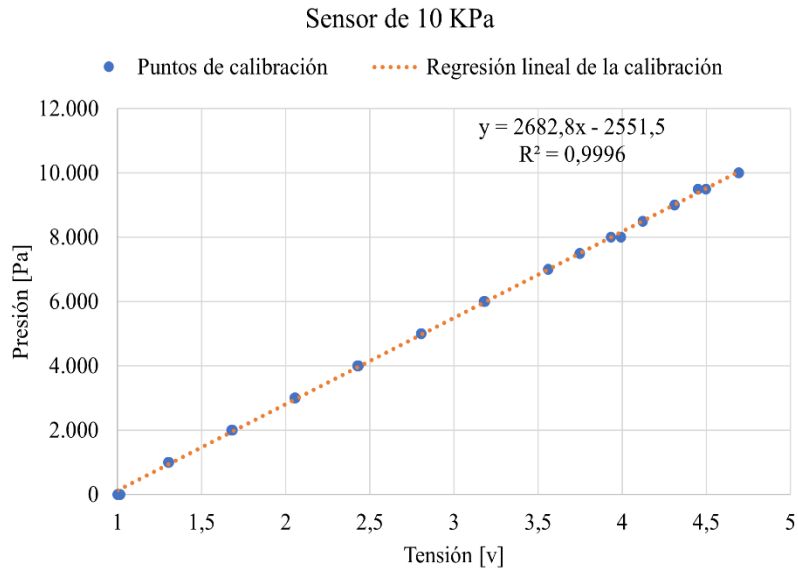
**Figura 8**

*Curvas de calibración para los sensores de a) 3 KPa b) 10 KPa y c) 40 KPa. Fuente.*

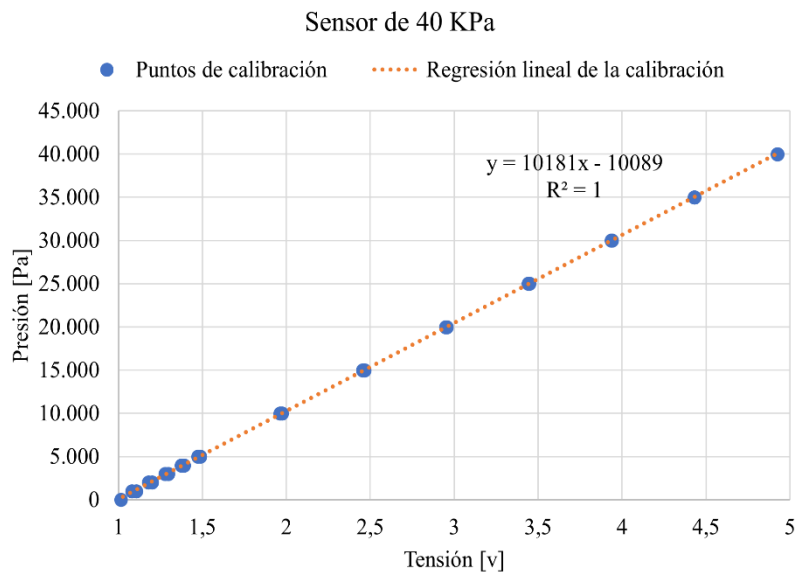
*Elaboración propia*



a)



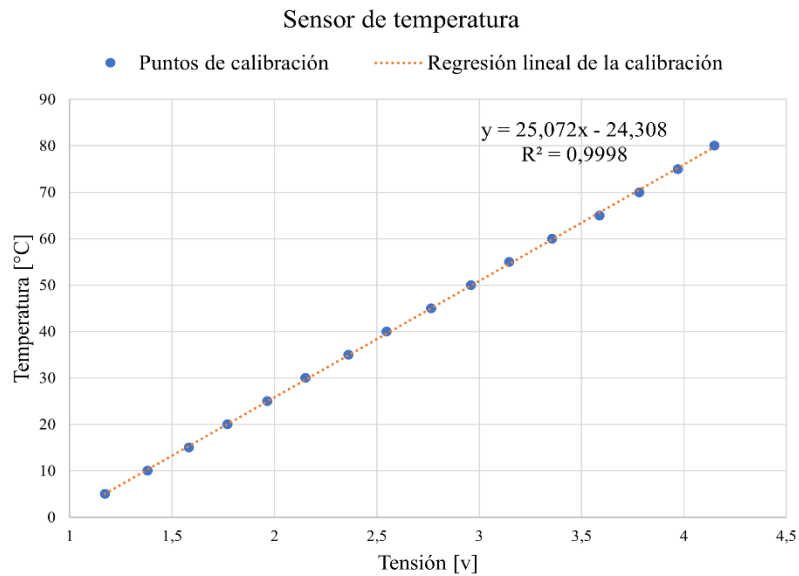
b)



c)

**Figura 9**

*Curva de calibración para el sensor de temperatura. Fuente. Elaboración propia*



**Tabla 1**

*Equipos de la bancada experimental instalada en LEMI-USP*

Equipos	Marca	Modelo
Bomba de agua	Weatherford	Tipo parafuso
Bomba de aceite	Weatherford	Tipo parafuso
Variador de frecuencia bomba de agua	WEG	CFW-09
Variador de frecuencia bomba de aceite	Yaskawa	VS-616PC5/P5
Tanque de agua	-	5.000 L
Tanque de aceite	-	5.000 L
Separador de agua y aceite	-	Placas coalescentes
Mezclador de agua y aceite	-	Tipo Y
Válvulas de control	-	Válvulas manuales
Válvulas de cierre rápido	MGA	2/2

**Tabla 2.***Instrumentos de medida instalados en LEMI-USP*

Instrumento	Marca	Modelo	Rango	Tolerancia
Medidor de caudal medio de aceite	Oval ®	Flowpet-EG LS5376 cP-430A	2,5 a 106 l/min	+/- 1%
Medidor de caudal alto de aceite	Oval ®	Flowpet – EG LS5576 cP-430A	6,67 a 233,2 l/min	+/- 1%
Medidor de caudal bajo de agua	Badgmeter	OGF HF ½”	1 a 35 l/min	+/- 0,75%
Medidor de caudal alto de agua	Oval®	Delta	30 a 1600 l/min	+/- 1%
Sensor de presión	Endress-hauser	PMD - 75	-3 a 3 kPa	+/- 0,05%
Sensor de presión	Endress-hauser	PMD - 75	-10 a 10 kPa	+/- 0,05%
Sensor de presión	Endress-hauser	PMD - 75	-40 a 40 kPa	+/- 0,05%
Medidor de temperatura	Termopar	Tipo K	0 a 100 °C	+/- 0,3%

### ***3.1.1. Propuesta esquemática para banco experimental en la Universidad Industrial de Santander***

Con la finalidad de ampliar la capacidad experimental de los laboratorios de la Escuela de Ingeniería Mecánica de la Universidad Industrial de Santander, y poder desarrollar actividades prácticas con escala industrial, se seleccionó el laboratorio de sistemas de transporte y aprovechamiento de fluidos (STAF) para realizar el diseño esquemático preliminar de un banco de prueba que permitirá la simulación de fenómenos relacionados con flujos multifásicos aplicados a la industria petroquímica.

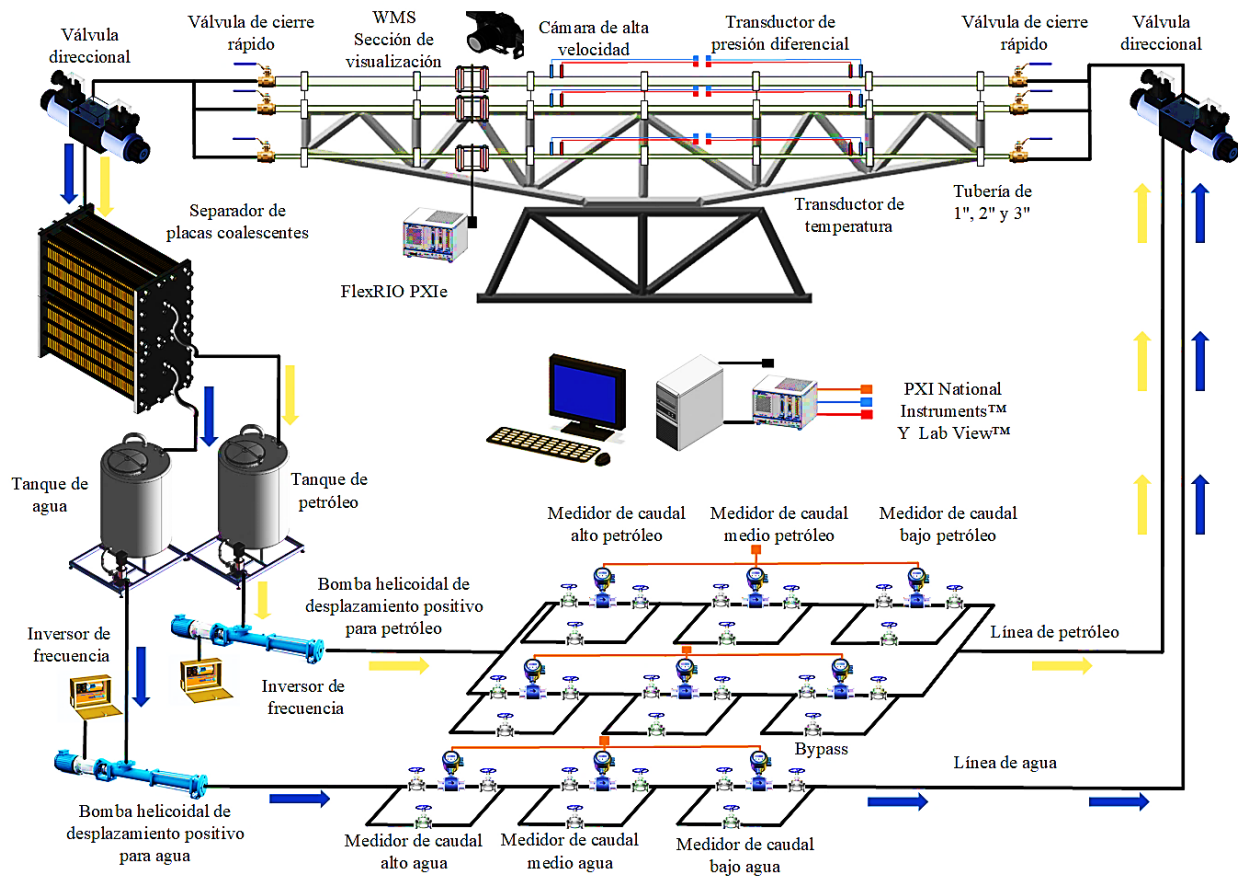
El banco experimental se desarrolló a partir de las condiciones estructurales del laboratorio de STAF, contando con un área total de 300 m<sup>2</sup> para el montaje de todos los dispositivos y la

tubería horizontal, y permitiendo la inclinación de esta hasta un ángulo de  $90^\circ$ . De manera general, el banco cuenta con tubería de sección transversal circular, con diámetros de 1, 2 y 3" por la cual fluyen los fluidos de trabajo almacenados en tanques, siendo impulsados por dos bombas helicoidales de desplazamiento positivo, conectadas cada una de ellas a inversores de frecuencia con el fin de tener más control sobre el proceso de modificación de parámetros físicos. Asimismo, el diseño esquemático cuenta con una sección de visualización para la toma de muestras tomográficas, una amplia gama de sensores de presión, temperatura y caudal, oscilando entre valores bajos, medios y altos, los cuales permiten realizar experimentaciones con una variación de parámetros elevada, ajustándose a las condiciones específicas con las que se deseen desarrollar las simulaciones.

A su vez, el diseño esquemático preliminar cuenta con un sistema de control y de adquisición de datos interconectados entre sí en el software Labview®, en una interfaz diseñada para mantener monitoreado todo el sistema en tiempo real. Todo el banco experimental se muestra en la Figura 10.

**Figura 10**

*Vista esquemática del circuito experimental diseñado para la Universidad Industrial de Santander. Elaboración propia*



### 3.2. Matriz experimental

De manera experimental, en el circuito instalado en LEMI se logró la estructuración de una base de datos de 164 puntos para flujo bifásico de aceite y agua en tubería de vidrio de borosilicato con inclinaciones de  $5^\circ$ ,  $0^\circ$  y  $-5^\circ$ , con sección transversal circular de 1 pulgada de diámetro interno y 12 [m] de longitud, sobre los cuales se realizaron los estudios iniciales. De manera general se

tomaron dos intervalos de temperatura de los fluidos, comprendidos entre [23, 34] °C y [30, 45] °C, los cuales se denominaron intervalo frío y caliente, respectivamente.

La cantidad de patrones de flujo total identificados experimentalmente fueron 9. En el intervalo frío se presentan A (8), Do/w (24), Do/w & o (7), Do/w & w (32), D w/o (3), I (4), ST (2), SWD (4) y en el intervalo caliente A (2), Do/w (18), Do/w & o (16), Do/w & w (39), D w/o (2), ST (1), SWD (2). La información recopilada experimentalmente es presentada en la Tabla 3, la cual se complementa en los apéndices A y B.

Asimismo, se estructuraron dos bases de datos a partir de la literatura para flujo bifásico de aceite y agua, una de ellas con 2156 datos para tubería horizontal, presentada en la Tabla 4 y la otra con 4864 puntos en tubería vertical presentada en la Tabla 5.

**Tabla 3**

*Información general de la base de datos experimental para flujo bifásico de aceite y agua en tubería horizontal*

Intervalo	$\bar{T}_o [^{\circ}C]$	$\bar{T}_w [^{\circ}C]$	$D_i [m]$	$\theta [^{\circ}]$	$\bar{\mu}_o [Pa \cdot s]$	$\bar{\rho}_o [kg/m^3]$	Nº. patrones de flujo	Nº. datos
Frío	32,35	32,35		5	0,13	878,8	7	28
	28,14	28,14	0,254	0	0,17	881,4	7	28
	25,8	25,8		-5	0,19	882,8	5	28
Caliente	34,78	32,5		5	0,11	877,27	5	20
	38,11	35,7	0,254	0	0,098	875,23	7	40
	35,7	35,20		-5	0,11	876,7	4	20

A su vez, la base de datos experimental inicial de 56 datos, permitió identificar los patrones de flujo ST (6), ST & MI (11), o/w (8), Do/w (15) y Do/w & w (16), la cual se presenta en el Apéndice C.

La información recopilada de la literatura para flujo bifásico de aceite y agua en tubería horizontal es presentada en la Tabla 4 y complementada en el Apéndice D, para la cual se tomaron como referencia los 18 esquemas presentados en estudios de 13 autores, en las cuales se identificaron 8 patrones de flujo y la cantidad de veces que se presenta: ST (521), ST & MI (370), D o/w & w (11), o/w (359), w/o (324), D o/w & D w/o (20), I (304) y A (247).

**Tabla 4**

*Información general de la base de datos de la literatura para flujo bifásico de aceite y agua en tubería horizontal*


Referencia	$D_i[m]$	$\mu_o[Pa.s]$	$\rho_o[kg/m^3]$	N°. patrones de flujo	No. de datos
[38]	0,021	0,799	886	5	138
[68]	0,1064	0,00188	800	4	49
[69]	0,1	0,002	825	3	99
[70]	0,0445	0,1077	881	4	27
	0,0508	0,0288	884	2	106
[71]	0,0508	0,013	858,5	2	30
	0,0508	0,013	858,5	2	88
[72]	0,026	5,6	910	2	69
	0,019	0,012	875	4	196
[73]	0,0254	0,012	875	5	268
[74]	0,025	0,107	889	5	536
[75]	0,032	0,0054	825	4	57
[76]	0,059	0,022	-----	5	76
[77]	0,0828	0,00717	831,4	5	43
[78]	0,026	5	910	2	64
	0,0056	0,0052	818	4	213
[79]	0,007	0,0052	818	4	97

La cantidad específica de datos totales obtenidos para cada autor para flujo bifásico de aceite y agua en tubería horizontal es presentada en la Figura 11. Autores como Al-Sarkhi et al

[71] y Al-Wahaibi et al [73] utilizaron más de una configuración geométrica en sus estudios, relacionados directamente con el diámetro interno de las tuberías, que de manera simbólica se representan con los números 1, 2 y 3 según corresponde.

**Figura 11**

*Número de datos por autor obtenidos de la literatura para tubería horizontal*



Tomando como referencia los esquemas desarrollados por los autores presentados en la Tabla 5, estructurados para flujo bifásico de aceite y agua en tubería vertical, se identificaron 9 patrones de flujo así: churn o/w (21), churn w/o (126), core flow (480), D o/w (947), D w/o (1292),

S o/w (459), S w/o (656), TF (314), VFD o/w (265) y VFD w/o (204). Información complementaria se puede detallar en el Apéndice E.

**Tabla 5**


*Información general de la base de datos para flujo bifásico de aceite y agua en tubería vertical*

Referencia	$D_i$ [m]	$\mu_o$ [Pa. s]	$\rho_o$ [kg/m <sup>3</sup> ]	N°. patrones de flujo	No. de datos
[37]	0,0284	0,488	925	3	392
[68]	0,1064	0,00188	800	6	49
[80]	0,02	0,011	856	3	101
[81]	0,05	0,02	850	5	126
[82]	0,04	0,035	860	4	92
[83]	0,0263	0,0201	851	2	15
[84]	0,02	0,125	801	4	175
[85]	0,127	0,001	801	2	9
[86]	0,027	0,02	801	4	109
[87]	0,0254	0,001	792	4	55
[88]	0,0254	0,001	792	5	32
[89]	0,01	0,287	1823	3	1421
[90]	0,026	0,0011	793	5	90
[91]	0,03	0,03	856	4	252
[92]	0,0284	0,5	930	1	92
[93]	0,03	0,044	860	4	98
[94]	0,02	0,09732	857	7	1699
[95]	0,04	0,0041	824	1	57

La cantidad específica de datos totales obtenidos para cada autor para flujo bifásico de aceite y agua en tubería vertical es presentada en la Figura 12.

**Figura 12**

*Número de datos por autor obtenidos de la literatura para tubería vertical*



Las bases de datos desarrolladas poseen información relacionada con velocidades superficiales de los fluidos (aceite y agua), velocidad superficial de la mezcla, fracción volumétrica del agua, fracción volumétrica del aceite, diámetros de las tuberías, viscosidad del aceite, diferencial de presión en la tubería y nombre de los patrones de flujo presentados.

### 3.3. Análisis de las bases de datos

Una fracción de complejidad en el desarrollo del problema se centra en el análisis y la organización de las bases de datos, debido a que el procesamiento de la información allí contenida está directamente relacionado con el desempeño y la estructura de los modelos desarrollados con RNA y ANFIS, al depender en gran medida del número de neuronas que componen las capas de entrada y salida, ya que son iguales al número de parámetros incluidos en cada fase respectivamente. El factor estadístico que se utiliza como determinante inicial para establecer la proximidad del modelo se genera con la minimización del error cuadrático medio (MSE), que sigue la Ecuación ((19)).

$$MSE = \frac{1}{n} \sum_{m=1}^n (Y_{(Exp,m)} - Y_{(Pred,m)})^2 \quad (19)$$

Donde  $n$  es el número total de datos de entrada, especificados por cada variable física utilizada, que en este caso corresponden a los datos totales medidos experimentalmente y contenidos en el vector  $X$ .  $Y_{(Pred)}$  es el valor de cada salida obtenido por los modelos inteligentes a partir de la interacción matemática interna de los valores para cada variable de entrada.  $Y_{(Exp)}$  es el valor experimental de la salida.

Asimismo, se incluyen dos parámetros que minimizan el error generado en la selección del mejor modelo basándose en el número adecuado de neuronas que componen la red neuronal o el número de funciones de membresía en modelos ANFIS. El primero es el error absoluto porcentual promedio (MAPE), expresado en la Ecuación ((20), debido a que es el valor descriptivo del rendimiento de las redes neuronales artificiales y los modelos ANFIS desarrollados durante el estudio. El segundo parámetro es el coeficiente de determinación  $R^2$ , que se calcula mediante la Ecuación ((21) y representa la calidad del ajuste del modelo que varía entre 0 y 1, con la variable que se pretende explicar, siendo los valores cercanos a 1 los más ajustados y los cercanos a 0 los menos ajustados, y por lo tanto menos fiables.

$$MAPE = \left[ \frac{1}{n} \sum_{m=1}^n \left| \frac{Y_{(Exp,m)} - Y_{(Pred,m)}}{Y_{(Exp,m)}} \right| \right] * 100 \quad (20)$$

$$R^2 = 1 - \frac{\sum_{m=1}^n (Y_{(Exp,m)} - Y_{(Pred,m)})^2}{\sum_{m=1}^n (Y_{(Exp,m)} - \bar{Y}_{(Pred,m)})^2} \quad (21)$$

### 3.4. Aplicación de inteligencia artificial

La estructuración de los modelos inteligentes ajustado a las condiciones reales del proceso de transporte de aceite en el presente trabajo se desarrolló tomando en cuenta todos los factores necesarios para definir la estructura de la red neuronal artificial perceptrón multicapa con feed-forward backpropagation y una modelación de estructuras ANFIS de 5 capas.

Inicialmente, se estandarizó la nomenclatura utilizada para nombrar cada red neuronal que se estructuró, en la cual se definía un vector con la información de número de entradas, número de capas ocultas y número de neuronas que integraban cada capa oculta respectivamente. El vector de entradas  $X$ , utilizado en el desarrollo de la investigación, está integrado por las velocidades superficiales de los fluidos (aceite y agua), la viscosidad del aceite, el diferencial de presión en la línea experimental y el diámetro de las tuberías de sección transversal circular, como se presenta en la Ecuación (22). Todos los parámetros que integran el vector de entradas fueron medidos experimentalmente en el laboratorio LEMI y tomados de la literatura, según las bases de datos estructuradas y organizadas. Adicionalmente, se hicieron otras estructuras para el vector de entradas, en donde se excluyeron las velocidades superficiales de los fluidos y se incluyeron las fracciones volumétricas de los mismos.

$$X = \begin{bmatrix} J_o \\ J_w \\ \mu_o \\ \Delta P \\ D \end{bmatrix} \quad (22)$$

Posteriormente, se realizó la selección de la función de entrenamiento analizando los algoritmos mostrados en la Tabla 6, y escogiendo el Levenberg-Marquardt (LM), al ser dicho algoritmo el más robusto. Con el algoritmo LM se obtiene el mejor ajuste de los datos con el menor costo computacional, al aplicar el método de mínimos cuadrados amortiguados no lineales, permitiendo encontrar específicamente el mínimo local al interpolar el algoritmo de Gauss-Newton y el método de descenso de gradiente. Esto es un factor fundamental en la optimización del rendimiento del modelo durante las fases de entrenamiento, validación y prueba de la estructura

de red neuronal desarrollada, al permitir tener control absoluto sobre los pesos sinápticos y los sesgos, generando una reducción del error obtenido.

**Tabla 6**

*Funciones de entrenamiento para las RNA*

Siglas	Algoritmo	Nombre
LM	trainlm	Levenberg-Marquardt
BFG	trainbfg	BFGS Quasi-Newton
RP	trainrp	Resilient Backpropagation
SCG	trainscg	Scaled Conjugate Gradient
CGB	traincgb	Conjugate Gradient with Powell/Beale Restarts
CGF	traincgf	Fletcher-Powell Conjugate Gradient
CGP	traincgp	Polak-Ribière Conjugate Gradient
OSS	trainoss	One Step Secant
GDX	traingdx	Variable Learning Rate Backpropagation

La función de adaptación para el aprendizaje seleccionada en la estructura de las redes neuronales desarrolladas es la función LEARNNGDM, correspondiente a la función de aprendizaje con descenso de gradiente ajustado a sus respectivos pesos sinápticos y sesgos, la cual genera un proceso optimizado en la secuencia derivativa que se lleva a cabo en el aprendizaje supervisado de la RNA y en cada iteración desarrollada, con el fin de disminuir el MSE al ajustar los  $w_{ij}$  y los  $b_j$  en cada etapa de desarrollo, siguiendo la secuencia de desempeño de la función de entrenamiento del algoritmo de LM.

Para determinar en primera medida el funcionamiento de los modelos desarrollados, se utilizó el parámetro estadístico definido anteriormente como el MSE, el cual permite apreciar de manera analítica y gráfica la calidad de los resultados de los modelos inteligentes desarrollados, a partir de las interacciones generadas entre las variables de entrada y las salidas esperadas.

El procesamiento matemático que define el desarrollo de los modelos inteligentes se origina a partir de lo establecido en la Ecuación (8), al realizar el ajuste del vector de entrada con las variables experimentales conocidas con sus respectivos pesos sinápticos y respectivos sesgos, los cuales se obtienen automáticamente por la estructura de RNA implementada junto con la función de entrenamiento LEARNGDM. De forma específica, la regresión logística ajustada a las variables utilizadas se define en la Ecuación (23).

$$S_i = \sum_{j=1}^m \begin{bmatrix} J_o \\ J_w \\ \mu_o \\ \Delta P \\ D \end{bmatrix}_i \begin{bmatrix} w_{J_o} \\ w_{J_w} \\ w_{\mu_o} \\ w_{\Delta P} \\ w_D \end{bmatrix}_{ij} + b_j \quad (23)$$

Una vez determinado  $S_i$ , se aplica una función de activación sigmoidea a dicho valor generado, con el fin de limitar los resultados y tener dominio del proceso de predicción de los valores, a partir del desarrollo del modelo inteligente, modificado con la aplicación de las funciones TanSig y LogSig, definidas por las Ecuaciones (24) y (25) respectivamente.


$$\text{TanSig}(S_i) = f(S_i) = \frac{e^{\left[ \sum_{j=1}^m \begin{bmatrix} J_o \\ J_w \\ \mu_o \\ \Delta P \\ D \end{bmatrix}_i \begin{bmatrix} w_{J_o} \\ w_{J_w} \\ w_{\mu_o} \\ w_{\Delta P} \\ w_D \end{bmatrix}_{ij} + b_j \right]} - e^{\left[ \sum_{j=1}^m \begin{bmatrix} J_o \\ J_w \\ \mu_o \\ \Delta P \\ D \end{bmatrix}_i \begin{bmatrix} w_{J_o} \\ w_{J_w} \\ w_{\mu_o} \\ w_{\Delta P} \\ w_D \end{bmatrix}_{ij} + b_j \right]}}{e^{\left[ \sum_{j=1}^m \begin{bmatrix} J_o \\ J_w \\ \mu_o \\ \Delta P \\ D \end{bmatrix}_i \begin{bmatrix} w_{J_o} \\ w_{J_w} \\ w_{\mu_o} \\ w_{\Delta P} \\ w_D \end{bmatrix}_{ij} + b_j \right]} + e^{\left[ \sum_{j=1}^m \begin{bmatrix} J_o \\ J_w \\ \mu_o \\ \Delta P \\ D \end{bmatrix}_i \begin{bmatrix} w_{J_o} \\ w_{J_w} \\ w_{\mu_o} \\ w_{\Delta P} \\ w_D \end{bmatrix}_{ij} + b_j \right]}} \quad (24)$$

$$\text{LogSig}(S_i) = f(S_i) = \frac{1}{1 + e^{-\left[ \sum_{j=1}^m \begin{bmatrix} J_o \\ J_w \\ \mu_o \\ \Delta P \\ D \end{bmatrix}_i \begin{bmatrix} w_{J_o} \\ w_{J_w} \\ w_{\mu_o} \\ w_{\Delta P} \\ w_D \end{bmatrix}_{ij} \right] + b_j}} \quad (25)$$

La expresión gráfica para las Ecuaciones (24) y (25) se muestra en la Figura 13, de la cual se puede detallar el comportamiento que adopta la derivada de las funciones al aumentar o disminuir los valores de  $S_i$ , lo cual se relaciona de manera directa con el desempeño en el aprendizaje del modelo inteligente, siguiendo las Ecuaciones (26) y (27).

**Figura 13**

*Funciones de activación: (a) LogSig, (b) TanSig. Elaboración propia*



$$\lim_{S_i \rightarrow -\infty} \text{TanSig}(S_i) = -1, \quad \lim_{S_i \rightarrow +\infty} \text{TanSig}(S_i) = 1 \quad (26)$$

$$\lim_{S_i \rightarrow -\infty} \text{LogSig}(S_i) = 0, \lim_{S_i \rightarrow +\infty} \text{LogSig}(S_i) = 1 \quad (27)$$

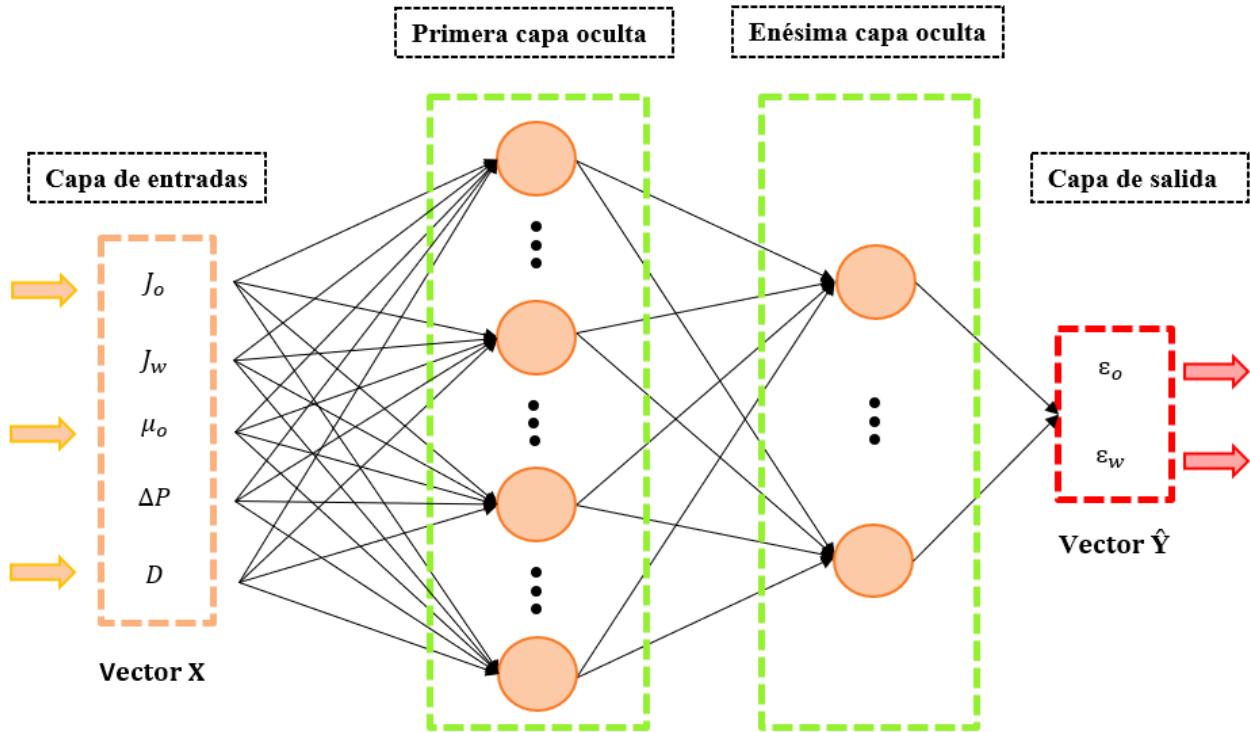
La estructuración de cada uno de los vectores que generan la formación matemática de las RNA y los modelos ANFIS, se llevó a cabo de manera paralela con la disponibilidad de la información recopilada y almacenada en las bases de datos respectivas, permitiendo así, la formación compacta y secuencial del vector de salidas del modelo predictivo  $\hat{Y}$ , conformado por los valores de las fracciones volumétricas de los fluidos aceite y agua, como se detalla en la Ecuación (28). En estudios paralelos se ajustó dicho vector de salidas, reemplazando las fracciones volumétricas de los fluidos, por sus velocidades superficiales.

$$\hat{Y} = \begin{bmatrix} \varepsilon_o \\ \varepsilon_w \end{bmatrix} \quad (28)$$

El vector  $\hat{Y}$  obtenido de la estructura de red neuronal esquematizada en la Figura 14, y el obtenido por el modelo ANFIS esquematizado en la Figura 15, fueron analizados para validar la calidad de los resultados del modelo predictivo, comparativamente con los obtenidos de manera experimental analizados en una plantilla de cálculo diseñada en el software Excel (ver Apéndice F) y por el software MATLAB, a partir de los parámetros estadísticos definidos por las Ecuaciones ((19), ((20) y ((21)((21).

**Figura 14**

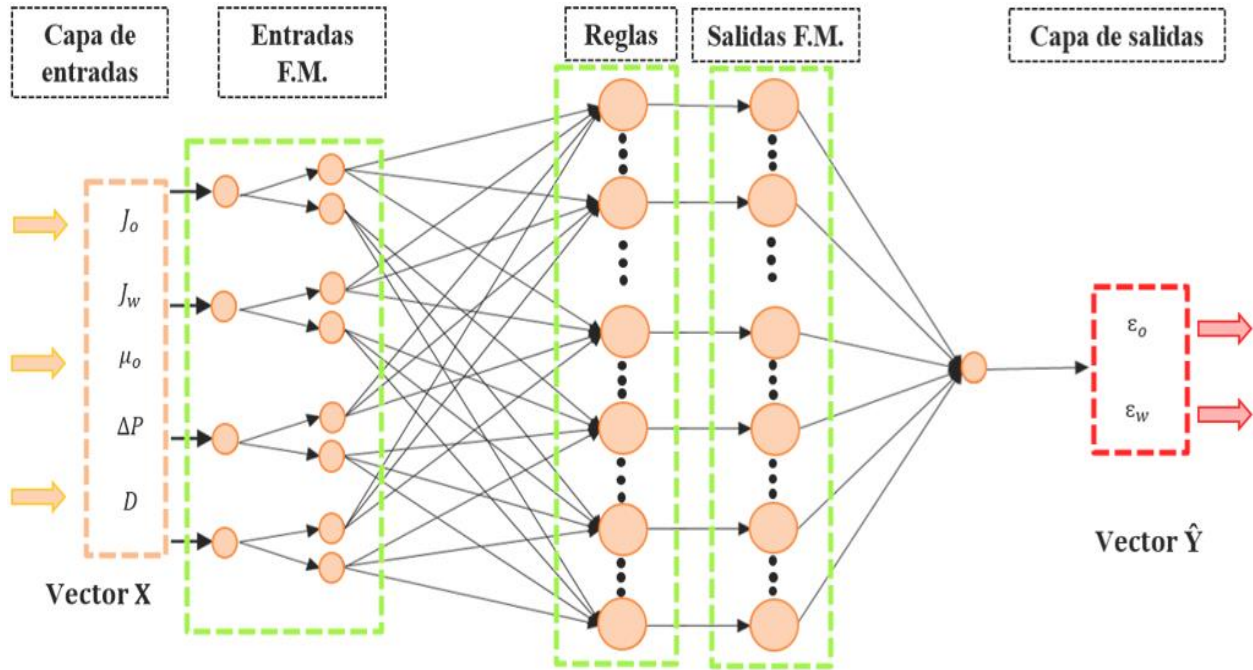
*Estructura particular de la RNA desarrollada. Elaboración propia*



El desarrollo metodológico detallado en la sección de técnicas de inteligencia artificial permitió estructurar el modelo ANFIS con el cual se desarrollaron predicciones tomando como entradas del sistema las variables que integran el vector X y como salidas los parámetros que integran el vector  $\hat{Y}$ . La estructura del modelo implementado se esquematiza en la Figura 15.

**Figura 15**

*Estructura particular del modelo ANFIS desarrollado. Elaboración propia*



El desarrollo del modelo ANFIS se implementó como una extensión de la aplicación de la RNA, basada en el diseñador neuro-fuzzy de MATLAB, utilizando como datos de entrada los correspondientes al vector X y salida para el entrenamiento y la validación, correspondientes al vector  $\hat{Y}$ . Asimismo, se realizó un ajuste de los parámetros de la función de pertenencia de los sistemas de inferencia difusa de tipo Sugeno, utilizando una función de pertenencia en forma de campana generalizada.

A partir de 506 datos para el entrenamiento y 216 para la validación, se desarrolló el modelo ANFIS, que tenía como entradas el diámetro de la tubería, la viscosidad del aceite y la

velocidad superficial del agua y del aceite. La salida del sistema era la predicción de la fracción volumétrica de aceite y agua dentro de la tubería vertical.

La estructura del modelo ANFIS tiene 5 capas de desarrollo matemático, en las que se procesa la información proporcionada en las variables de entrada, para lo que se utiliza la función de pertenencia en forma de campana generalizada. Para la salida del sistema, se agregó una función de pertenencia lineal. El entrenamiento del sistema ANFIS se llevó a cabo mediante un método híbrido en el que la tolerancia al error era cero.

Teniendo en cuenta el coste computacional y los resultados preliminares de las simulaciones, en este trabajo se definieron 3, 4, 5, 6 y 7 funciones de pertenencia para las pruebas y el análisis.

#### 4. Resultados

Para la implementación de los modelos de RNA iniciales, se realizó un preprocesamiento de los datos experimentales (56 datos iniciales y 164 complementarios) y de los obtenidos de la literatura (2156 datos en tubería horizontal y 4864 datos en tubería vertical). Para la implementación del modelo ANFIS, los datos se organizaron de manera ascendente, tomando como filtro el valor de la fracción volumétrica experimental. En los siguientes subapartados se revisan y analizan los resultados obtenidos al implementar los modelos predictivos. La estructuración de los modelos se llevó a cabo en el software MATLAB. (Ver Apéndices A, B, C, D y E)

La Tabla 7 y la Tabla 8 muestran los resultados del entrenamiento que se realizó a las RNA con 56 datos experimentales tomando como entradas las velocidades superficiales de los fluidos (aceite y agua) y el diferencial de presión en la línea, con el fin de obtener los valores de las fracciones volumétricas de los fluidos al interior de una tubería horizontal, para lo cual se asumió una variedad en el número de neuronas que integran la capa oculta (siguiendo la secuencia 1, 2, 3, 5, 8, 10, 12, 15 y 20) con sus respectivos pesos y sesgos aplicando las funciones de activación LogSig y TanSig en conjunto con la función de entrenamiento de LM.

##### **Tabla 7**

*Resultados de la variación en el número de neuronas en la capa oculta (# N.C.O.) usando la función de activación LogSig en tubería horizontal*


# N.C.O.	MSE	R <sup>2</sup>	MAPE
1	0,00767	0,9640	21,93
2	0,00137	0,9936	7,23

3	0,00503	0,9764	11,62
5	0,00449	0,9789	14,24
8	0,00103	0,9952	6,56
10	0,00157	0,9926	8,12
12	0,00217	0,9898	10,75
15	0,00220	0,9897	7,58
20	0,00217	0,9898	9,87

La Tabla 7 integra los resultados obtenidos del entrenamiento y validación de las RNA con la función de activación LogSig. A partir de la información allí recopilada se lograron determinar los valores mínimos del MAPE, siendo estos 7,58, 7,23 y 6,56, para un número de neuronas en la capa oculta de 15, 2 y 8, respectivamente, así como también sus coeficientes de determinación de 0,9897, 0,9936 y 0,9952. Los valores de MSE y  $R^2$  se presentan en la Figura 16. donde se evidencian picos en las estructuras con 1, 2, 3, 5 y 8 neuronas en la capa oculta y un comportamiento estabilizado para 12, 15 y 20.

**Figura 16.**

*Comparación entre el MSE y el R<sup>2</sup> contenidos en la Tabla 7 para tubería horizontal*



La Tabla 8 presenta los resultados obtenidos integra al entrenar la RNA con la función de transferencia TanSig, determinando como valores mínimos del MAPE a 6,48, 5,03 y 3,01 y R<sup>2</sup> de 0,9942, 0,9963 y 0,9964 para 12, 10 y 15 neuronas, respectivamente. Los valores de MSE y R<sup>2</sup> se presentan en la

Figura 17, de la cual se concluye que el peor resultado para los parámetros estadísticos analizados se logra al incluir 20 neuronas en la capa oculta, debido a que presenta un MSE de 0,01085 correspondiente al valor máximo global y un R<sup>2</sup> de 0,9491 correspondiente al mínimo global.


**Tabla 8**

*Resultados de la variación en el número de neuronas en la capa oculta usando la función de activación TanSig en tubería horizontal*

# N.C.O.	MSE	R <sup>2</sup>	MAPE
1	0,00541	0,9746	14,33
2	0,00151	0,9929	8,87
3	0,00337	0,9842	8,81
5	0,00305	0,9857	14,12
8	0,00095	0,9955	6,60
10	0,00079	0,9963	5,03
12	0,00123	0,9942	6,48
15	0,00077	0,9964	3,01
20	0,01085	0,9491	23,14

**Figura 17**

*Comparación entre el MSE y el R<sup>2</sup> contenidos en la Tabla 8 para tubería horizontal*



La

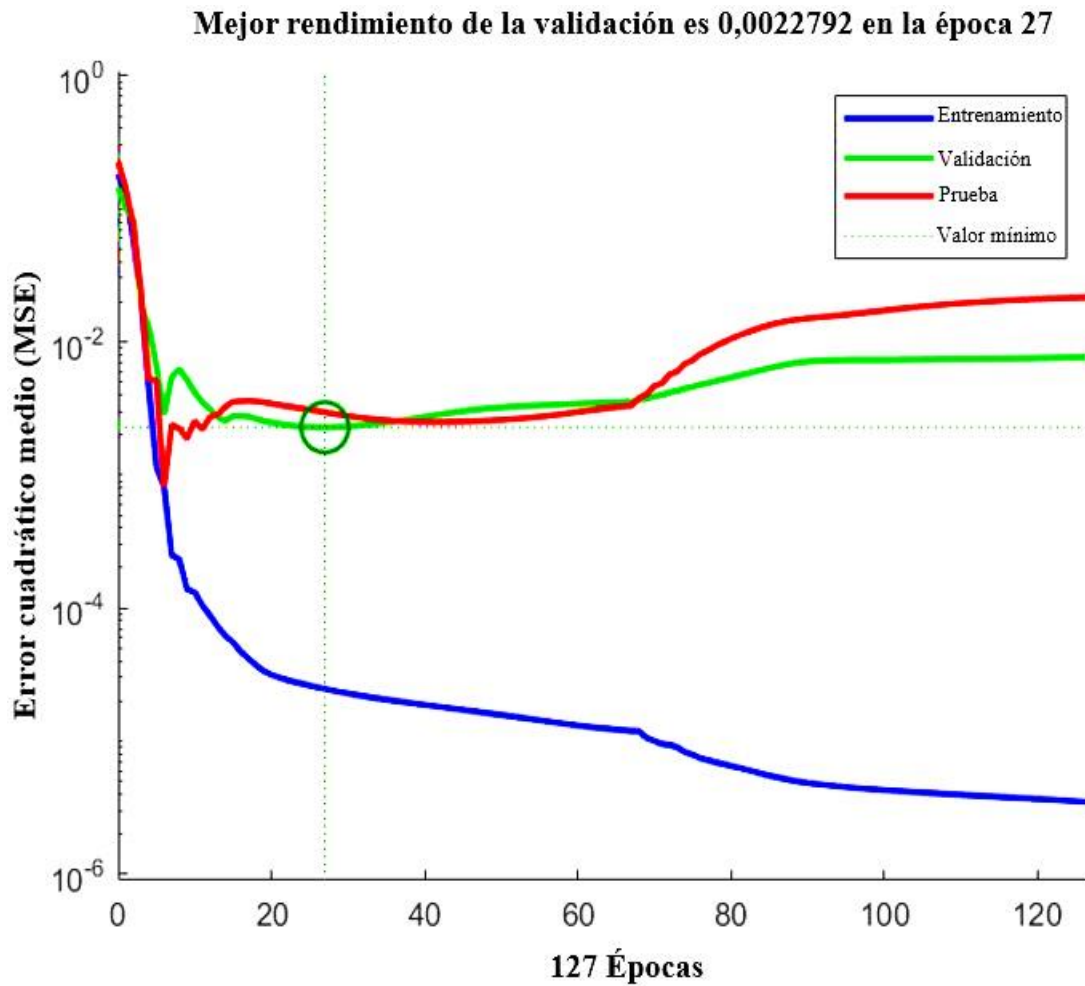
**Figura 17** muestra el comportamiento numérico del MSE y del  $R^2$  a medida que se realizan variaciones en el número de neuronas que integran la capa oculta en cada fase de validación y prueba de las RNA estructuradas. Gráficamente se demuestra que los mejores valores de  $R^2$  y MSE son los generados por la RNA que sigue la secuencia estructural [3-1-15], con un valor mínimo de MSE correspondiente a 0,00077 y 0,9964 de  $R^2$  para 15 neuronas en la capa oculta.

Analizando esta información generada a partir de los 56 datos experimentales iniciales, se logró determinar que la RNA óptima para desarrollar el modelo predictivo de fracción volumétrica para los fluidos agua y aceite es aquella que integra la función de transferencia TanSig con una capa oculta. La capa oculta está compuesta por 15 neuronas y logra un MAPE 3,01 %, un coeficiente de determinación  $R^2$  igual a 0,9964 y un MSE de 0,00077, permitiendo concluir que, de manera comparativa, dicho modelo predictivo es el mejor de los 18 que se simularon, al presentar los mejores resultados en los cálculos y en la simulación, es decir, los valores generados por el modelo predictivo eran los más próximos a los obtenidos de manera experimental.

La Figura 18 muestra el comportamiento del MSE en cada una de las fases de diseño y prueba de la RNA seleccionada que sigue la secuencia [3-1-15], con un valor mínimo de 0,0022792 transcurridas 27 iteraciones, dicho valor se alcanza durante la fase de validación, con una cantidad de datos equivalente al 15% de los totales.

**Figura 18**

*Variación del MSE en cada iteración realizada en la RNA de configuración [3-1-15] para tubería horizontal*

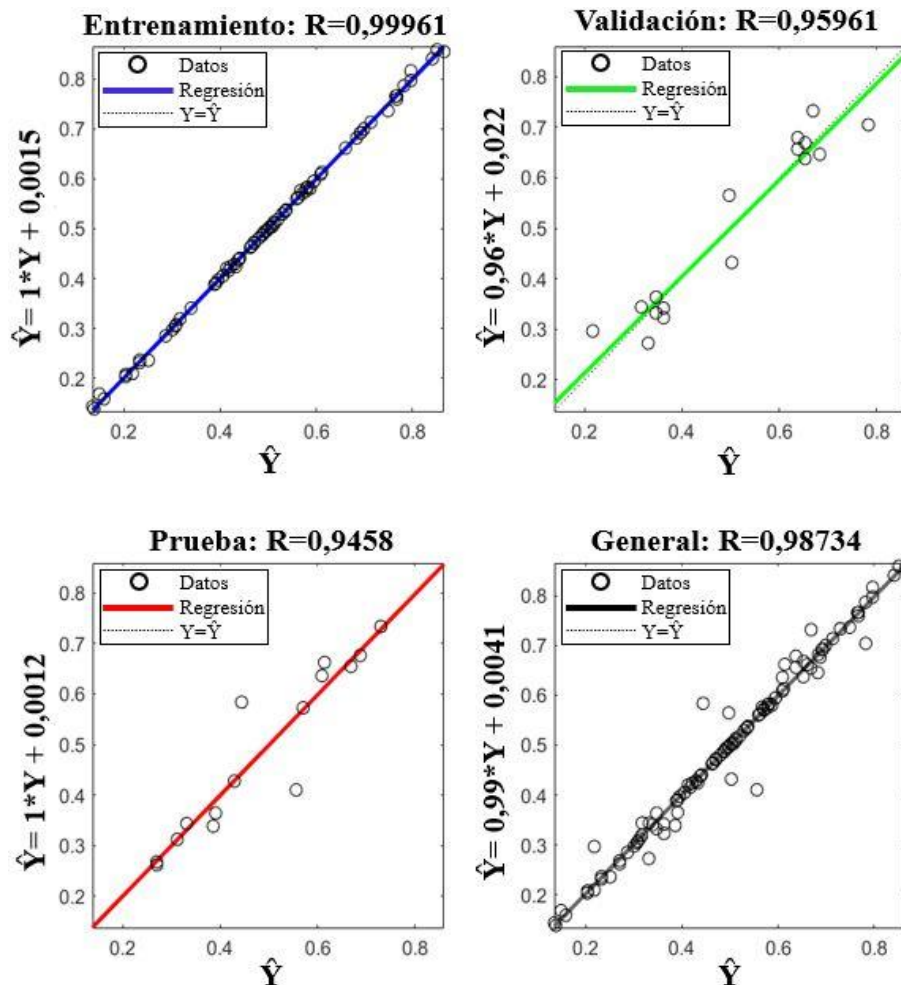


La Figura 19 muestra los resultados obtenidos en las fases de entrenamiento, validación, prueba y general, así como también sus respectivos coeficientes de correlación (R) y la regresión lineal generada. En la fase de entrenamiento se encuentra la regresión lineal con el R más alto, debido a que la cantidad de datos que se procesa en el aprendizaje de esta fase es equivalente a un

70% de la cantidad total, es decir, este valor de 0.99961 se relaciona íntimamente con la cantidad de datos de entrenamiento. Las fases de validación y prueba se realizan con el 30% de la información total, con 15% para cada una, lo cual genera valores de R inferiores al de la fase de entrenamiento, dichos valores de R para la fase de validación y prueba son respectivamente 0.95961 y 0.9458.

**Figura 19**

*Desempeño de la RNA entrenada con los datos experimentales obtenidos en LEMI en términos del coeficiente de correlación para tubería horizontal*



A partir del análisis de los anteriores resultados, se procedió con la estructuración de una RNA a partir de los 56 datos iniciales, con una función de activación única, correspondiente a la función TanSig, utilizando como parámetros de entrada las velocidades superficiales de los fluidos y el diferencial de presión en la línea, con el fin de obtener un valor predictivo de las fracciones volumétricas del agua y del aceite al interior de la tubería, al agregar una nueva capa oculta en la estructura interna de la RNA.

La Tabla 9 muestra los resultados obtenidos en el entrenamiento de la RNA y su validación al aplicar la función de activación TanSig. En dicha tabla se comparan los resultados de MSE,  $R^2$  y MAPE para distintos números de neuronas que componen las dos capas ocultas de la RNA, compuestas por el mismo número de neuronas y adicionalmente la capa de salida.

**Tabla 9**

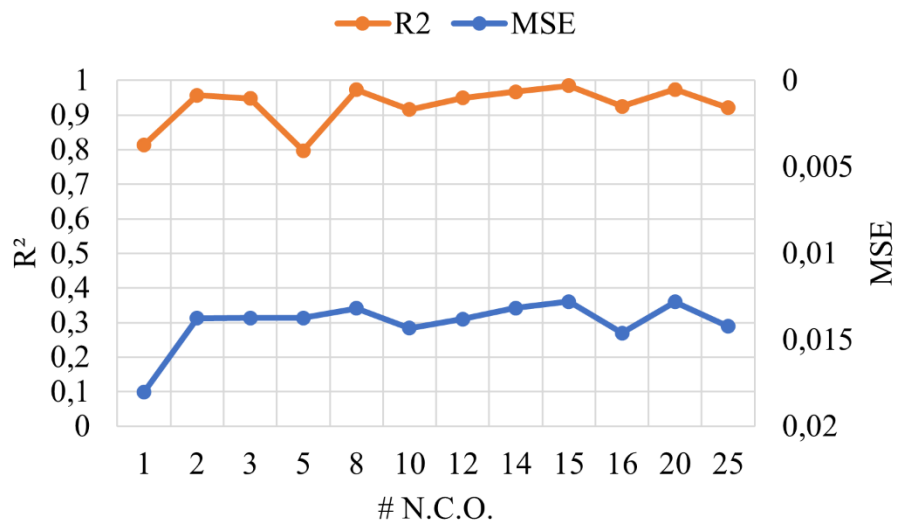
*Resultados de MSE,  $R^2$  y MAPE para diferentes números de neuronas en las dos capas ocultas de la red neuronal artificial para tubería horizontal*

# N.C.O.	MSE	$R^2$	MAPE
1	0,01801	0,814	16,20
2	0,01376	0,957	8,90
3	0,01373	0,948	8,06
5	0,01373	0,797	8,06
8	0,01318	0,973	2,83
10	0,01433	0,916	11,17
12	0,01380	0,949	6,07
14	0,01317	0,967	6,39
15	0,01280	0,985	3,07
16	0,01462	0,925	7,13
20	0,01281	0,974	3,00
25	0,01423	0,921	4,71

Analizando la información presentada en la Tabla 9 para una RNA de perceptrón multicapa compuesta por dos capas ocultas, tres entradas y su respectivo vector de salidas, es posible afirmar que el modelo que integra los valores mínimos de los parámetros estadísticos establecidos calculados es el estructurado con dos capas ocultas, con 15 neuronas en cada una de ellas, generando valores de MSE de 0.01280 %,  $R^2$  de 0.985 y un MAPE de 3.07%. Los valores de MSE y  $R^2$  se presentan en la Figura 20.

**Figura 20**

*Comparación entre el MSE y el  $R^2$  contenidos en la Tabla 9 para tubería horizontal*

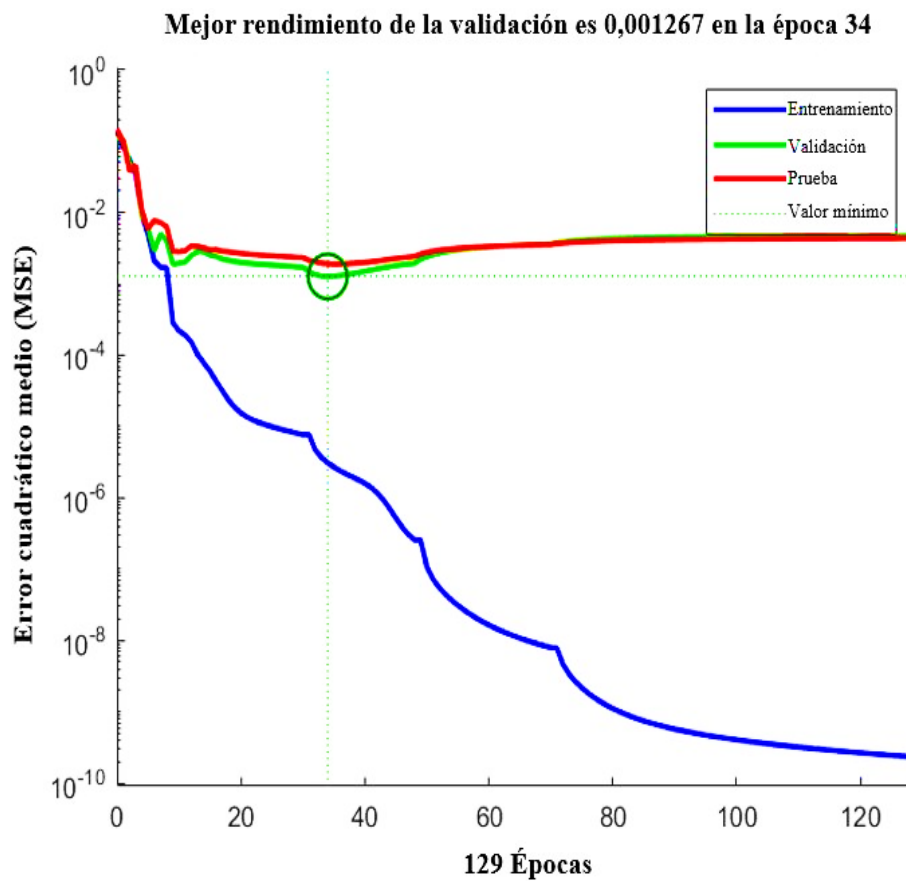


La Figura 20 permite identificar los rangos entre los cuales oscilan los valores de MSE que va desde 0,01280 a 0,01801 y  $R^2$  que va de 0,797 a 0,985, a partir de las configuraciones organizadas en la Tabla 9.

La Figura 21 muestra el comportamiento del MSE en cada una de las fases de diseño y prueba de la RNA seleccionada que sigue la secuencia [3-2-15], con un valor mínimo de 0.001267 para 15 neuronas en la capa oculta, cuando han transcurrido 34 iteraciones de las 129 realizadas hasta la estabilización del MSE.

**Figura 21**

*Rendimiento en la fase de validación del modelo de RNA [3-2-15] para tubería horizontal*

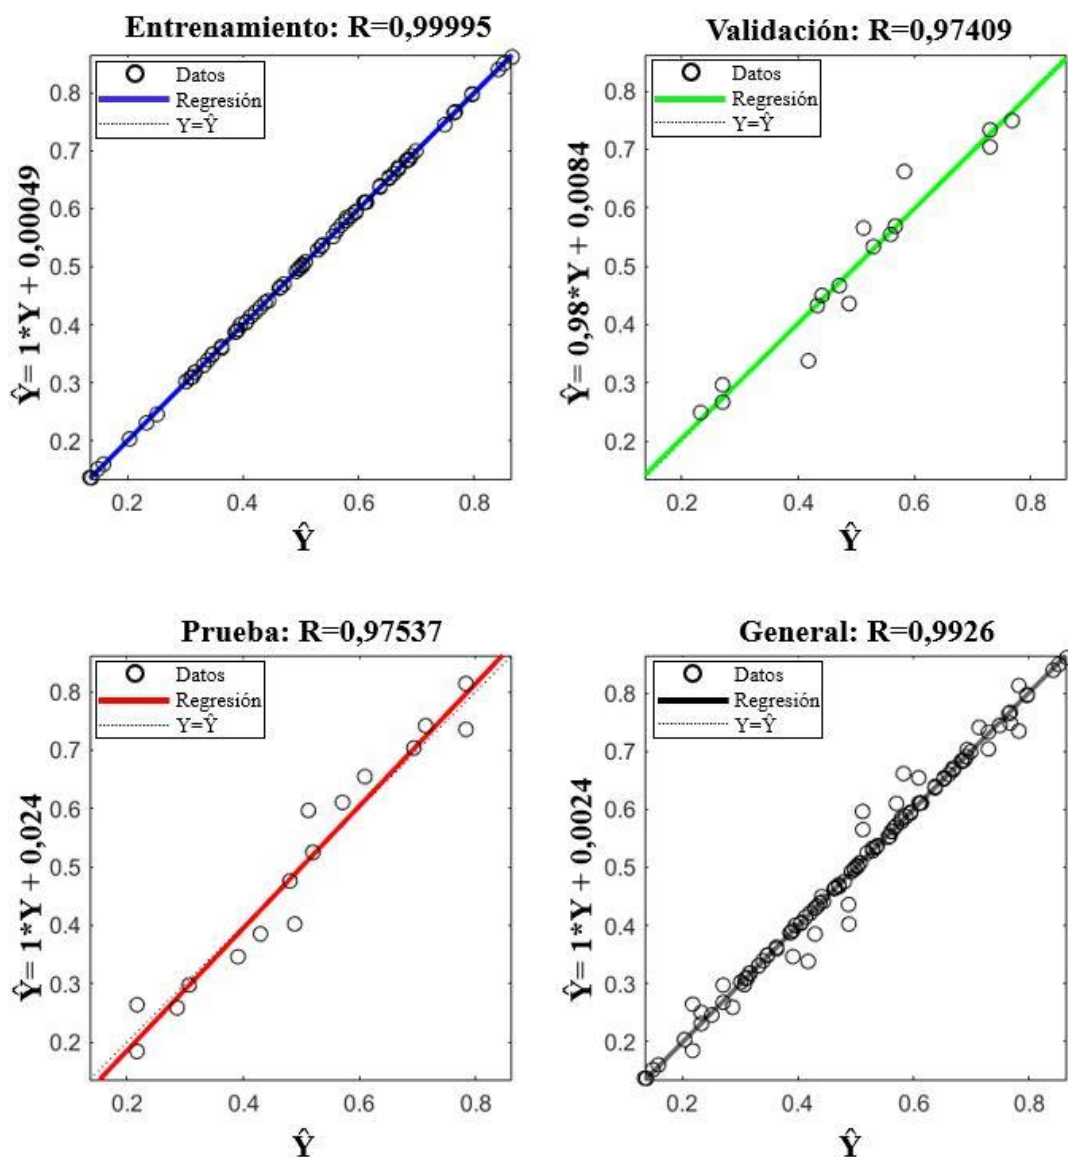


La Figura 22 muestra de manera secuencial los resultados obtenidos en las fases de entrenamiento, validación, prueba y general, así como también sus respectivos coeficientes de

correlación (R) y la regresión lineal generada, a partir de los valores de entrada y sus respectivos pares obtenidos con el modelo predictivo. El coeficiente de correlación más elevado se obtuvo en la fase de entrenamiento, alcanzando un valor de 0.99995, gracias al buen rendimiento de la RNA estructurada ([3-2-15]).

**Figura 22**

*Desempeño de la RNA [3-2-15] en términos del coeficiente de correlación (R)*



De manera consecutiva se realizó una comparación entre los resultados obtenidos por la estructura de RNA [3-1-15] y la estructura [3-2-15], de la cual se logró concluir que en este trabajo, el modelo de RNA óptimo para calcular las fracciones volumétricas de aceite y de agua al interior de una tubería horizontal, a partir de las velocidades superficiales de los fluidos ( aceite y agua) y el diferencial de presión en la línea, es el desarrollado con una capa oculta, 15 neuronas integrando dicha capa culta, en conjunto con la función de activación TanSig, función de aprendizaje LEARNGDM y el algoritmo de entrenamiento de Levenberg-Marquardt.

Con el fin de ampliar el rango de aplicación de las técnicas de inteligencia artificial mencionadas en este trabajo, se llevó a cabo un desarrollo metodológico de simulaciones con 722 datos obtenidos de la literatura para tubería vertical de sección circular para flujo bifásico de aceite y agua, a fin de comparar los resultados obtenidos por modelos estructurados de red neuronal artificial y modelos ANFIS.

Tomando en cuenta que el vector de entradas X está integrado por el diámetro de la tubería, la velocidad superficial de los fluidos y la viscosidad del aceite, que a su vez estructuran el modelamiento matemático del proceso inteligente que calcula la fracción volumétrica de aceite y agua dentro de tubería vertical.

En la Tabla 10 se presentan los resultados obtenidos del análisis y estructuración de 4 configuraciones de RNA con 8,10,12 y 15 neuronas. Teniendo en cuenta los valores presentados por el MSE,  $R^2$  y MAPE, se observa que el modelo con menores valores de error es el estructurado con 12 neuronas en la capa oculta intermedia, presentando 0,000049, 0,99932 y 0,19 %, respectivamente, lo cual permite concluir que el modelo desarrollado posee un funcionamiento óptimo dado que los parámetros estadísticos presentan valores muy buenos de aproximación, comparados con los resultados obtenidos experimentalmente. La comparación entre el valor

experimental de la fracción volumétrica del aceite ( $\epsilon_{exp}$ ) y el resultado de la predicción ( $\epsilon_{pred}$ ) para los 722 datos que implementan este modelo de RNA se muestra en la

Figura 23.


**Tabla 10**

*Resultados de los modelos RNA implementados para tubería vertical de la literatura*

# N.C.O.	MSE	R <sup>2</sup>	MAPE
8	0,0001063	0,9985440	0,218456
10	0,000163275	0,9979810	0,198804
12	4,99989E-05	0,9993201	0,199479
15	0,0001180	0,9984006	0,321182

**Figura 23**

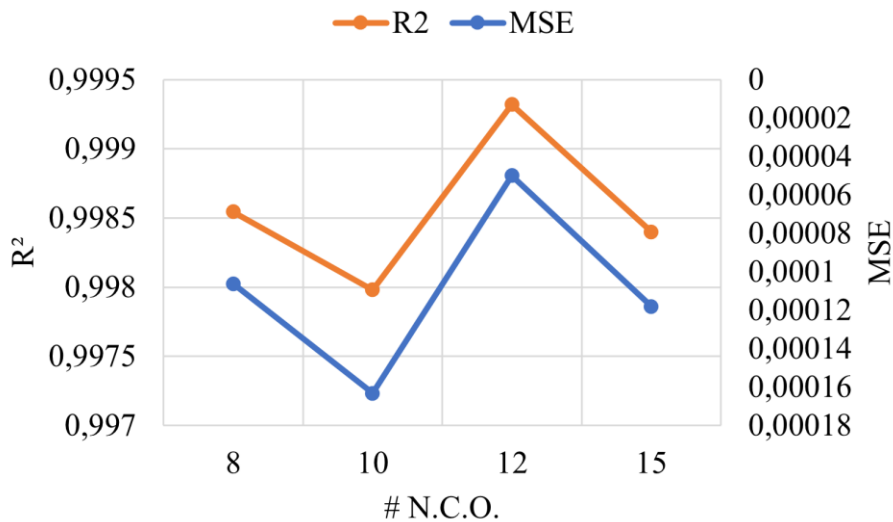
*Una comparación entre  $\epsilon_{exp}$  y  $\epsilon_{pred}$  para la RNA con 12 neuronas en la capa oculta para tubería vertical de la literatura*



Los valores presentados por el modelo estructurado con 10 neuronas en la capa oculta intermedia mostraron los valores de error más altos, con un MSE de 0,000163275 y un coeficiente de determinación de 0,9979810, comparativamente con los buenos resultados obtenidos por el modelo con 12 neuronas en la capa oculta, la cual obtuvo un MSE de 4,99989E-05 y un coeficiente de determinación de 0,9993201.

**Figura 24**

*Comparación entre el MSE y el R<sup>2</sup> contenidos en la Tabla 10 para tubería vertical de la literatura*



Los valores de MSE y R<sup>2</sup> se presentan en la Figura 24, en la cual se aprecia gráficamente que en la estructura que cuenta con 10 neuronas en la capa oculta, se obtiene el menor valor de R<sup>2</sup>

(0,9979810) y el mayor valor de MSE (0,000163275). De manera inversa, el modelo estructurado con 12 neuronas en la capa oculta presenta el mayor valor para  $R^2$  (0,9993201) y el menor valor para MSE (4,99989E-05), lo cual lo define como el mejor modelo implementado.

La Tabla 11 muestra los resultados obtenidos al realizar las respectivas simulaciones de estructuración de ANFIS, en las que se varió el número de funciones de membresía (# F.M.) que se integraron con las entradas y salidas de cada nodo, tomando los valores de 3, 4, 5, 6 y 7.

**Tabla 11**

*Resultados de los modelos ANFIS implementados para tubería vertical*

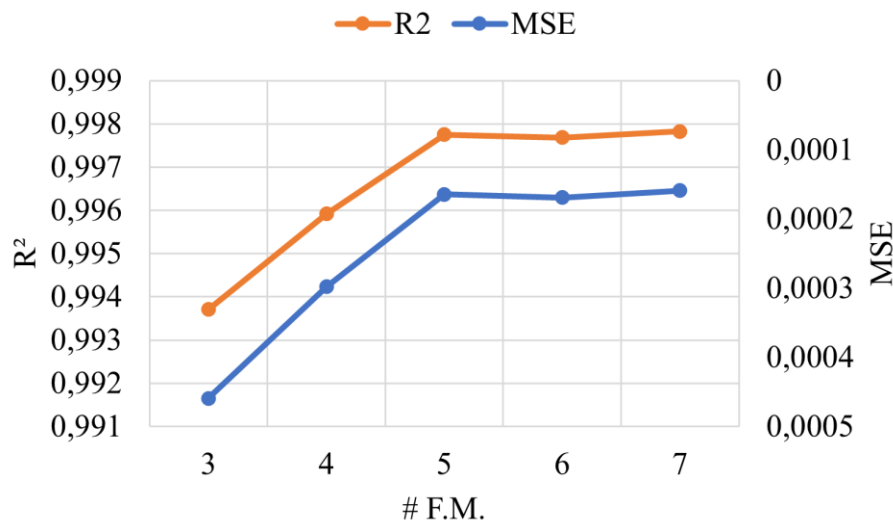
# F.M.	MSE	$R^2$	MAPE
3	0,0004593	0,9937075	1,373918
4	0,000297816	0,9959195	2,226595
5	0,0001644	0,9977480	1,735946
6	0,0001689	0,9976853	0,196800
7	0,0001589	0,9978230	0,906838

Los valores presentados por el modelo ANFIS estructurado con 3 funciones de membresía mostraron los valores de error más elevados, con un MSE de 0,00045, un  $R^2$  de 0,9937 y un MAPE de 0.0137 %.

Teniendo en cuenta los valores presentados por el MSE, el coeficiente de determinación y el MAPE, se observa que el modelo ANFIS con menores valores de error es el estructurado con 7 funciones de membresía, presentando 0,000158, 0,99782 y 0,9 %, respectivamente. Los valores de MSE y  $R^2$  se presentan en la Figura 25.

**Figura 25**

Comparación entre el MSE y el  $R^2$  contenidos en la Tabla 11 para tubería vertical de la literatura



En la Figura 25 se aprecia el aumento gradual en el rendimiento de los modelos, comenzando por valores relativamente errados para el modelo predictivo estructurado con 3 funciones de membresía, debido a que presenta el valor más alto de MSE (0,0004593) y el más bajo para  $R^2$  (0,9937075). A su vez, el comportamiento de los parámetros estadísticos se comienza a estabilizar cuando se implementan 5 funciones de membresía, que de manera consecutiva adquiere su mejor desempeño cuando se realiza la estructuración del modelo con 7 funciones de membresía, generando el valor mínimo para MSE (0,0001589) y máximo para  $R^2$  (0,9978230).

Los resultados generados por los modelos de RNA y ANFIS para la base de datos generada de la literatura para tubería vertical, permiten concluir que la técnica de inteligencia artificial

óptima en este trabajo para calcular la fracción volumétrica de aceite a partir de las velocidades superficiales de los fluidos (aceite y agua), el diámetro de la tubería y la viscosidad del aceite, es el modelo de RNA con una capa oculta integrada por 12 neuronas, al presentar valores para el MSE de 0.000049 y para el  $R^2$  de 0,9993201, es decir, es el modelo que presenta los valores predictivos más ajustados a los experimentales.

Con el fin identificar las velocidades superficiales del aceite y del agua, para determinar los patrones de flujo que se generan en la tubería vertical, se llevó a cabo la estructuración RNA perceptrón multicapa, acompañada por la función de entrenamiento de Levenberg-Marquardt y la función de adaptación de LEARNNGDM en el aprendizaje.

La Tabla 12 presenta los resultados obtenidos en la determinación de la velocidad superficial del aceite utilizando como parámetros de entrada el número de Reynolds, las fracciones volumétricas de los fluidos y la viscosidad del aceite.

**Tabla 12**

*Resultados de los modelos RNA implementados para la velocidad superficial del aceite para tubería vertical de la literatura*


# N.C.O.	MSE	$R^2$	MAPE
10	0,00379	0,93441	36,12858
11	0,00388	0,93219	38,54968
12	0,00368	0,93617	27,19751
13	0,00438	0,91863	77,43548
14	0,00439	0,91893	87,55584

Teniendo en cuenta lo presentado en la Tabla 12, se seleccionó el modelo que presentó la mejor aproximación en el cálculo de la velocidad superficial del aceite, siendo el estructurado con

12 neuronas en la capa oculta, ya que presentó un MSE de 0,00368, un  $R^2$  de 0,93617 y un MAPE de 27,19751. Los valores de MSE y  $R^2$  se presentan en la Figura 26.

**Figura 26**

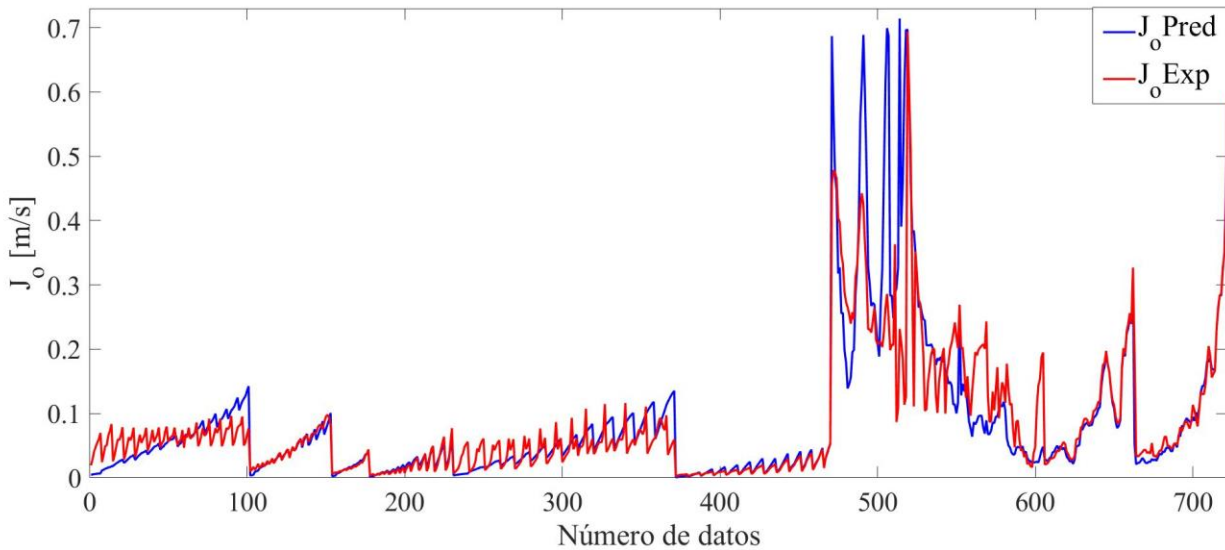
*Comparación entre el MSE y el  $R^2$  contenidos en la Tabla 12 para tubería vertical de la literatura*



La comparación entre el valor experimental de la velocidad superficial del aceite y el resultado de la predicción para los 722 datos con los que se estructuró el modelo de RNA se muestra en la Figura 27. Dichos valores se consideran aceptables, pero son evidentemente inferiores a los obtenidos por todos los modelos de RNA desarrollados durante este trabajo, al presentar un valor promedio de 53% en el MAPE.

**Figura 27**

*Comparación entre  $J_{o_{Exp}}$  y  $J_{o_{pred}}$  para la RNA con 12 neuronas en la capa oculta para cada dato incluido para tubería vertical de la literatura*



La Tabla 13 presenta los resultados obtenidos en la determinación de la velocidad superficial de agua utilizando los mismos parámetros de entrada.

**Tabla 13**


*Resultados de los modelos RNA implementados para la velocidad superficial del agua para tubería vertical de la literatura*

# N.C.O.	MSE	R <sup>2</sup>	MAPE
10	0,00038	0,99233	32,80226
11	0,00044	0,99110	37,99249
12	0,00038	0,99228	41,14588
13	0,00079	0,98406	75,13605
14	0,00080	0,98398	77,46686

Teniendo en cuenta dichos resultados, se establece que el modelo que representa los mejores valores predictivos para la velocidad superficial del agua es el estructurado con 10 neuronas en la capa oculta, presentando valores 0,00038, 0,99233 y 32,8% para el MSE, el coeficiente de determinación y el MAPE, respectivamente. Los valores de MSE y  $R^2$  se presentan en la Figura 28.

**Figura 28**

*Comparación entre el MSE y el  $R^2$  contenidos en la Tabla 13 para tubería vertical de la literatura*



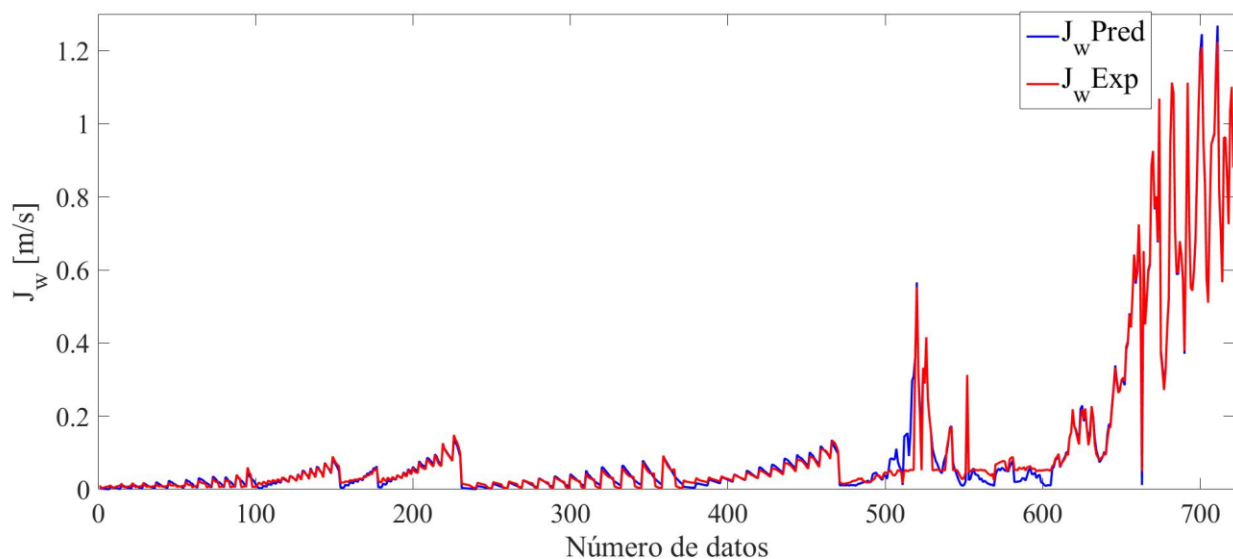
La Figura 28 permite visualizar el comportamiento del MSE y del  $R^2$  para la información contenida en la Tabla 13. Los valores del MSE presentan un aumento gradual a medida que se eleva el número de neuronas en la capa oculta, presentando como menor valor 0,00038 para 10 neuronas y mayor 0,00080 para 14 neuronas. De manera recíproca, los valores de  $R^2$  presentan una

disminución gradual a medida que aumenta el número de neuronas que integran la capa oculta, al presentar como mejor valor 0,99233 para 10 neuronas y como valor menos ajustado 0,98398 para 14 neuronas, lo cual permite concluir que el modelo que mejor se ajusta en la obtención de la velocidad del agua es el que incluye 10 neuronas en su capa oculta.

La Figura 29 muestra una comparación entre  $J_{wExp}$  y  $J_{wPred}$  para la RNA con 10 neuronas en la capa oculta.

### Figura 29

*Comparación entre  $J_{wExp}$  y  $J_{wPred}$  para la RNA con 10 neuronas en la capa oculta para tubería vertical de la literatura*




En la Figura 30 se presenta el esquema obtenido de la unión de los dos modelos anteriores de red neuronal artificial que presentaron los menores errores determinando la velocidad superficial de aceite y de agua en tuberías verticales de sección transversal circular, donde se tomó el resultado generado por los dos mejores modelos (12 neuronas en la capa oculta para aceite, 10

neuronas en la capa oculta para agua), con el fin de generar mapas de flujo descriptivos del modelo real, esquematizado por [81] y graficado en este trabajo a partir de un código en MATLAB (Ver Apéndice G).

**Figura 30**

*Mapa de flujo estructurado con valores generados por el modelo predictivo para [81]. Fuente.*

*Elaboración propia*



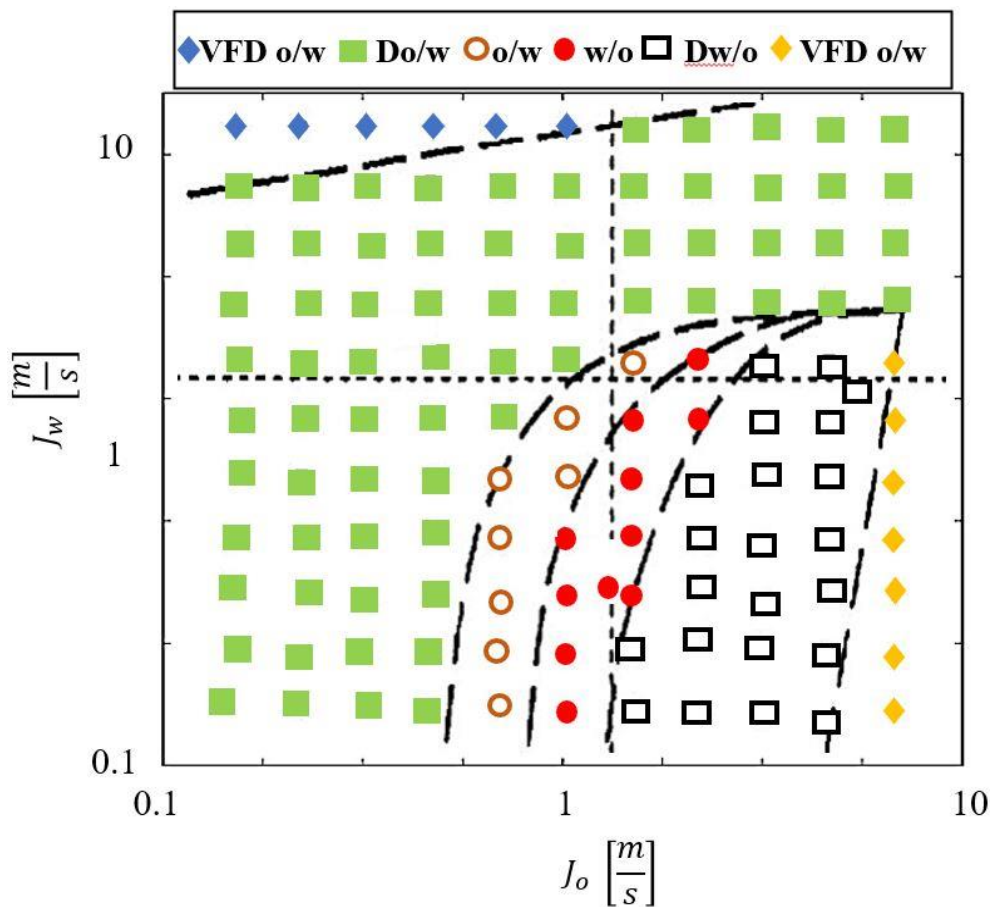
Donde F1 representa la línea de transición entre el patrón de flujo Do/w y el patrón de flujo TF. A su vez, D3 es la línea de transición entre el patrón de flujo TF y patrón de flujo el Dw/o.

En la Figura 31 se presenta el modelo original desarrollado por [81] con el fin de determinar los patrones de flujo presentes en tubería vertical, modelándolo a partir de parejas ordenadas

correspondientes a las velocidades superficiales del aceite y del agua. Las líneas punteadas representan las zonas calculadas en donde se presentan las transiciones entre un patrón de flujo y otro, que en este caso envuelve tres patrones generales, como lo son Do/w, TF y Dw/o.

**Figura 31**

*Mapa de flujo estructurado por [81]. Modificado*



Con base en los resultados obtenidos para cada modelo desarrollado de RNA y ANFIS para calcular fracciones volumétricas y velocidades superficiales de aceite y agua a partir de la base datos experimental para tubería horizontal y de la base de datos de la literatura para tubería vertical,

se procedió con el análisis de la base de datos para tubería horizontal obtenida de la literatura, llevando a cabo la estructuración de 4 configuraciones de RNA con 8,10,12 y 15 neuronas en su capa oculta, tomando como referencia el procedimiento metodológico implementado a la base de datos de la literatura para tubería vertical en el cálculo de la fracción volumétrica de aceite, utilizando como parámetros de entrada el diámetro de la tubería, la velocidad superficial de los fluidos y la viscosidad del aceite.

En la Tabla 14 se presenta la información correspondiente a los valores que se obtuvieron los parámetros estadísticos establecidos (MSE,  $R^2$  y MAPE) para cada configuración de la RNA implementada, donde se puede apreciar un rendimiento adecuado en cada estructura desarrollada al lograr valores de MSE y MAPE próximos a cero y valores de  $R^2$  próximos a 1, lo cual representa de manera explícita que el modelo generado predice valores con un ajuste óptimo entre los datos experimentales de los autores y los obtenidos por la RNA.

**Tabla 14**

*Resultados de los modelos RNA implementados para tubería horizontal de la literatura*


# N.C.O.	MSE	$R^2$	MAPE
8	0,000378727	0,99556492	1,571449795
10	0,000379446	0,99556492	0,352602081
12	0,000050769	0,99940521	0,320451261
15	0,000017760	0,99980001	0,037959504

La Figura 32 presenta el comportamiento desarrollado por el MSE y el  $R^2$  para cada estructura de RNA implementada a la base de datos en tubería horizontal de la literatura, donde ambos parámetros presentan valores óptimos en sus ajustes. El MSE alcanza su mejor valor correspondiente a 0,000017760 cuando se incluyen 15 neuronas en la capa oculta. De la misma

manera, el  $R^2$  consigue su mejor desempeño para dicha cantidad de neuronas, alcanzando un valor de 0,99980001.

**Figura 32**

*Comparación entre el MSE y el  $R^2$  contenidos en la Tabla 14 para tubería horizontal de la literatura*

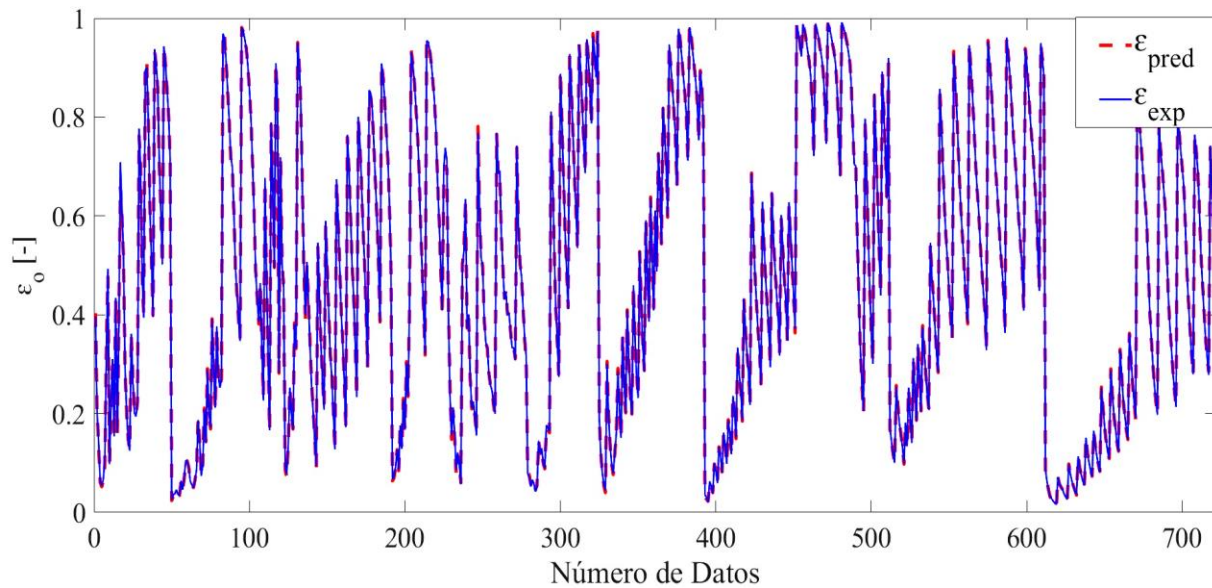


Debido al comportamiento que adquiere el modelo de RNA desarrollado al incluir 15 neuronas en su capa oculta, se tomó esa como la estructura óptima para determinar la fracción volumétrica de aceite a partir del diámetro de la tubería, la velocidad superficial de los fluidos y la viscosidad del aceite.

La comparación entre los valores experimentales de los autores para la fracción volumétrica de aceite al interior de tuberías horizontales y los generados por el modelo inteligente, son presentados en la Figura 33.

**Figura 33**

Una comparación entre  $\varepsilon_{exp}$  y  $\varepsilon_{pred}$  para la RNA con 15 neuronas en la capa oculta para tubería horizontal de la literatura



La Figura 33 presenta esquemáticamente los valores para las fracciones volumétricas de aceite generados por el modelo de RNA desarrollado con 15 neuronas en su capa oculta y los compara con los valores experimentales de la base de datos de la literatura para tubería horizontal, donde se aprecia que tienen un comportamiento altamente ajustado, soportado en la proximidad que tienen los parámetros estadísticos a los valores ideales.

## 5. Conclusiones

En el presente trabajo se desarrolló una metodología basada en inteligencia artificial para calcular de manera precisa velocidades superficiales y fracciones volumétricas de aceite y agua al interior de tuberías verticales y horizontales. Se aplicaron técnicas de inteligencia artificial como son las redes neuronales artificiales y los modelos ANFIS, y se estructuraron mapas de flujo bifásico a partir de los resultados alcanzados por cada modelo predictivo, los cuales se ajustaron a características específicas.

La metodología para la aplicación de técnicas de inteligencia artificial en la caracterización de flujos bifásicos de aceite y agua desarrollada en el presente documento es una herramienta de gran utilidad para la generación de modelos predictivos precisos entrenados con la función de Levenberg-Marquardt en conjunto con la función de aprendizaje LEARNGDM, las cuales permiten minimizar el error generado en las predicciones, al utilizar variables físicas propias de dicho fenómeno para caracterizar los flujos en tuberías horizontales y verticales, a partir parámetros de entrada como velocidades superficiales, diámetros de tubería, diferencial de presión en la línea y la viscosidad del aceite.

Las configuraciones de RNA desarrolladas para calcular la fracción volumétrica de los fluidos aceite y agua en tubería horizontal a partir de datos experimentales iniciales de velocidades superficiales y diferencial de presión en la línea, presentaron para las funciones de activación LogSig y TanSig valores óptimos en los parámetros estadísticos, correspondientes a un MSE de 0.00103,  $R^2$  de 0.9952 y MAPE de 6.56 % generado con 8 neuronas en su capa oculta ([3-1-8]) y de manera correspondiente, para la función TanSig un MSE de 0.00077,  $R^2$  de 0.9964 y MAPE de

3.01% generado con 15 neuronas en su capa oculta ([3-1-15]), siendo este el mejor modelo estructurado para los 56 datos experimentales utilizados.

El uso de la función de activación TanSig como función ideal para el para el tratamiento adecuado de la base de datos experimental para tubería horizontal utilizada, basados en los resultados anteriores, permitió generar un modelo predictivo eficiente estructurado con dos capas ocultas, una capa de entrada integrada por las velocidades superficiales de los fluidos y el diferencial de presión en la línea, y finalmente una capa de salida con las respectivas fracciones volumétricas de aceite y agua, para el cual se obtuvieron los mejores resultados al utilizar 15 neuronas en las dos capas ocultas ([3-2-15]), al presentar valores de MSE de 0.01280 %,  $R^2$  de 0.985 y un MAPE de 3.07%, lo cual permite concluir que la función de activación TanSig es la función de activación adecuada para el tratamiento de los datos experimentales utilizados.

A partir de la aplicación de las técnicas de aprendizaje automático RNA y ANFIS para estructurar un modelo capaz de predecir la fracción volumétrica de aceite para la base de datos generada de la literatura para tubería vertical, a partir del conocimiento de los diámetros de la tubería, la velocidad superficial de los fluidos y la viscosidad del aceite, se concluye que la técnica ideal para dichos fines, es la RNA, estructurada con 12 neuronas en su capa oculta ([4-1-12]) al presentar valores para el MSE de 0.000049, 0,199479 para MAPE y 0,9993201 para  $R^2$ .

Los resultados obtenidos por los modelos generados para la predicción de la velocidad superficial de los fluidos aceite y agua para la base de datos de la literatura para tubería vertical permiten concluir que la técnica de RNA es adecuada para la obtención de dichos valores utilizando como parámetros de entrada la viscosidad del aceite, la fracción volumétrica de los fluidos y el número de Reynolds, al presentar un MSE de 0,00368 y  $R^2$  de 0,93617 para la predicción de la velocidad del aceite estructurado con neuronas 12 en la capa oculta, mientras que

para la predicción de la velocidad superficial del agua se logró el mejor rendimiento con 10 neuronas en la capa oculta, generando valores de MSE de 0,00038 y  $R^2$  de 0,99233, lo cual permite concluir que el modelo desarrollado se ajusta con errores bajos en la identificación de los patrones de flujo disperso (D), agitado (Churn), finamente disperso (VFD), flujo de transición (TF), intermitente (S), estratificado (ST) y anular (A).

Con base en los resultados obtenidos para cada estructura de RNA desarrollada para predecir cálculo de la fracción volumétrica de aceite, utilizando como parámetros de entrada el diámetro de la tubería, la velocidad superficial de los fluidos y la viscosidad del aceite a partir de la base datos experimental para tubería horizontal, se concluye que el mejor modelo de RNA es aquel que incluye 15 neuronas en la capa oculta, al presentar un MSE de 0,000017760 y un  $R^2$  de 0,99980001.

De manera general, se concluye que la técnica de RNA genera el mejor modelo predictivo para el cálculo de velocidades superficiales y fracciones volumétricas de los fluidos aceite y agua en tuberías horizontales y verticales a partir de bases de datos experimentales y de la literatura, utilizando 15 neuronas en su capa oculta, la función de activación TanSig, la función de entrenamiento de Levenberg-Marquardt en conjunto con la función de aprendizaje LEARNGDM y como parámetros de entrada el diámetro de la tubería, la velocidad superficial de los fluidos y la viscosidad del aceite. (Ver Apéndice H)

## 6. Recomendaciones

Se sugiere como trabajo futuro la estructuración de modelos inteligentes basados en técnicas de aprendizaje automático como Long Short Term Memory (LSTM), Support Vector Machine (SVM), lógica difusa y gemelos digitales para determinar la fracción volumétrica y las velocidades superficiales de los fluidos aceite y agua en tuberías horizontales y verticales, a partir de bases de datos con una cantidad de información elevada, con el fin de contribuir a la Industria 4.0 en la ampliación del Big Data aplicando los desarrollos tecnológicos basados inteligencia artificial.

**Referencias Bibliográficas**

- [1] M. Süßer, “Flow Measurement Handbook: Industrial Designs, Operating Principles, Performance and Applications,” *Cryogenics (Guildf.)*, vol. 40, no. 6, p. 421, Jan. 2000, doi: 10.1016/S0011-2275(00)00051-5.
- [2] M. de M. F. Figueiredo, F. de C. T. Carvalho, A. M. F. Fileti, and A. L. Serpa, “Flow pattern classification in water-air vertical flows using a single ultrasonic transducer,” *Exp. Therm. Fluid Sci.*, vol. 119, no. January, p. 110189, Nov. 2020, doi: 10.1016/j.expthermflusci.2020.110189.
- [3] W. Tang, Z. Sun, and W. Li, “Visualization of flow patterns during condensation in dimpled surface tubes of different materials,” *Int. J. Heat Mass Transf.*, vol. 161, p. 120251, Nov. 2020, doi: 10.1016/j.ijheatmasstransfer.2020.120251.
- [4] Z. Lin, X. Liu, L. Lao, and H. Liu, “Prediction of two-phase flow patterns in upward inclined pipes via deep learning,” *Energy*, vol. 210, p. 118541, Nov. 2020, doi: 10.1016/j.energy.2020.118541.
- [5] S. Zeguai, S. Chikh, and L. Tadríst, “Experimental study of air-water two-phase flow pattern evolution in a mini tube: Influence of tube orientation with respect to gravity,” *Int. J. Multiph. Flow*, vol. 132, p. 103413, Nov. 2020, doi: 10.1016/j.ijmultiphaseflow.2020.103413.
- [6] M. Descamps, R. V. A. Oliemans, G. Ooms, R. F. Mudde, and R. Kusters, “Influence of gas injection on phase inversion in an oil-water flow through a vertical tube,” *Int. J. Multiph. Flow*, vol. 32, no. 3, pp. 311–322, 2006, doi: 10.1016/j.ijmultiphaseflow.2005.10.006.
- [7] D. M. Rocha, C. H. M. de Carvalho, V. Estevam, and O. M. H. Rodriguez, “Effects of water and gas injection and viscosity on volumetric fraction, pressure gradient and phase inversion in upward-vertical three-phase pipe flow,” *J. Pet. Sci. Eng.*, vol. 157, no. March, pp. 519–529, Aug. 2017, doi: 10.1016/j.petrol.2017.07.055.
- [8] Y. Ma, W. Liu, H. Wu, Y. Liu, J. Lyu, and Z. Cai, “Visualization experiment of gas-liquid flow pattern downstream of single-orifice plates in horizontal pipes under an intermittent upstream flow,” *Exp. Therm. Fluid Sci.*, vol. 119, no. September 2019, p. 110206, Nov. 2020, doi: 10.1016/j.expthermflusci.2020.110206.
- [9] M. W. Yaqub, R. Rusli, and R. Pendyala, “Experimental study on gas-liquid-liquid three-phase flow patterns and the resultant pressure drop in a horizontal pipe upstream of the 90° bend,” *Chem. Eng. Sci.*, vol. 226, p. 115848, Nov. 2020, doi: 10.1016/j.ces.2020.115848.
- [10] E. S. Rosa, R. M. Salgado, T. Ohishi, and N. Mastelari, “Performance comparison of artificial neural networks and expert systems applied to flow pattern identification in vertical ascendant gas-liquid flows,” *Int. J. Multiph. Flow*, vol. 36, no. 9, pp. 738–754, Sep. 2010, doi: 10.1016/j.ijmultiphaseflow.2010.05.001.
- [11] V. S. Chalgeri and J. H. Jeong, “Flow regime identification and classification based on void fraction and differential pressure of vertical two-phase flow in rectangular channel,” *Int. J. Heat Mass Transf.*, vol. 132, pp. 802–816, Apr. 2019, doi: 10.1016/j.ijheatmasstransfer.2018.12.015.
- [12] F. Liang, H. Zheng, H. Yu, and Y. Sun, “Gas-liquid two-phase flow pattern identification by ultrasonic echoes reflected from the inner wall of a pipe,” *Meas. Sci. Technol.*, vol. 27, no. 3, p. 035304, Mar. 2016, doi: 10.1088/0957-0233/27/3/035304.
- [13] C. Sunde, S. Avdic, and I. Pázsit, “Classification of two-phase flow regimes via image

- analysis and a neuro-wavelet approach,” *Prog. Nucl. Energy*, vol. 46, no. 3–4, pp. 348–358, 2005, doi: 10.1016/j.pnucene.2005.03.015.
- [14] L. S. Zhai, N. De Jin, Z. K. Gao, Z. Y. Wang, and D. M. Li, “The ultrasonic measurement of high water volume fraction in dispersed oil-in-water flows,” *Chem. Eng. Sci.*, vol. 94, pp. 271–283, 2013, doi: 10.1016/j.ces.2013.02.049.
- [15] K. J. Albion, L. Briens, C. Briens, and F. Berruti, “Multiphase Flow Measurement Techniques for Slurry Transport,” *Int. J. Chem. React. Eng.*, vol. 9, no. 1, pp. 1–4, Sep. 2011, doi: 10.2202/1542-6580.1726.
- [16] M. M. Hernández-Cely and C. M. Ruiz-Díaz, “Estudio de los fluidos aceite-agua a través del sensor basado en la permitividad eléctrica del patrón de fluido,” *Rev. UIS Ing.*, vol. 19, no. 3, pp. 177–186, Apr. 2020, doi: 10.18273/revuin.v19n3-2020017.
- [17] M. M. F. Figueiredo, J. L. Goncalves, A. M. V. Nakashima, A. M. F. Fileti, and R. D. M. Carvalho, “The use of an ultrasonic technique and neural networks for identification of the flow pattern and measurement of the gas volume fraction in multiphase flows,” *Exp. Therm. Fluid Sci.*, vol. 70, pp. 29–50, Jan. 2016, doi: 10.1016/j.expthermflusci.2015.08.010.
- [18] H. Wu, F. Zhou, and Y. Wu, “Intelligent identification system of flow regime of oil–gas–water multiphase flow,” *Int. J. Multiph. Flow*, vol. 27, no. 3, pp. 459–475, Mar. 2001, doi: 10.1016/S0301-9322(00)00022-7.
- [19] T. A. AL-Qutami, R. Ibrahim, I. Ismail, and M. A. Ishak, “Virtual multiphase flow metering using diverse neural network ensemble and adaptive simulated annealing,” *Expert Syst. Appl.*, vol. 93, pp. 72–85, 2018, doi: 10.1016/j.eswa.2017.10.014.
- [20] M. R. G. Meireles, P. E. M. Almeida, and M. G. Simões, “A comprehensive review for industrial applicability of artificial neural networks,” *IEEE Trans. Ind. Electron.*, vol. 50, no. 3, pp. 585–601, 2003, doi: 10.1109/TIE.2003.812470.
- [21] F. A. Gomide, “Redes neurais artificiais para engenharia e ciências aplicadas: curso prático,” *Sba Control. Automação Soc. Bras. Autom.*, vol. 23, no. 5, pp. 649–652, Oct. 2012, doi: 10.1590/S0103-17592012000500011.
- [22] Y. Yan, L. Wang, T. Wang, X. Wang, Y. Hu, and Q. Duan, “Application of soft computing techniques to multiphase flow measurement: A review,” *Flow Meas. Instrum.*, vol. 60, no. November 2017, pp. 30–43, Apr. 2018, doi: 10.1016/j.flowmeasinst.2018.02.017.
- [23] G. H. Roshani, E. Nazemi, and M. M. Roshani, “Intelligent recognition of gas-oil-water three-phase flow regime and determination of volume fraction using radial basis function,” *Flow Meas. Instrum.*, vol. 54, no. October 2016, pp. 39–45, Apr. 2017, doi: 10.1016/j.flowmeasinst.2016.10.001.
- [24] C. M. Salgado, L. E. B. Brandão, C. M. N. A. Pereira, and W. L. Salgado, “Salinity independent volume fraction prediction in annular and stratified (water–gas–oil) multiphase flows using artificial neural networks,” *Prog. Nucl. Energy*, vol. 76, pp. 17–23, Sep. 2014, doi: 10.1016/j.pnucene.2014.05.004.
- [25] C. M. Salgado, C. M. N. A. Pereira, R. Schirru, and L. E. B. Brandão, “Flow regime identification and volume fraction prediction in multiphase flows by means of gamma-ray attenuation and artificial neural networks,” *Prog. Nucl. Energy*, vol. 52, no. 6, pp. 555–562, Aug. 2010, doi: 10.1016/j.pnucene.2010.02.001.
- [26] A. Karami, G. H. Roshani, E. Nazemi, and S. Roshani, “Enhancing the performance of a dual-energy gamma ray based three-phase flow meter with the help of grey wolf optimization algorithm,” *Flow Meas. Instrum.*, vol. 64, no. October, pp. 164–172, Dec.

- 2018, doi: 10.1016/j.flowmeasinst.2018.10.015.
- [27] G. H. Roshani, R. Hanus, A. Khazaei, M. Zych, E. Nazemi, and V. Mosorov, “Density and velocity determination for single-phase flow based on radiotracer technique and neural networks,” *Flow Meas. Instrum.*, vol. 61, no. March, pp. 9–14, Jun. 2018, doi: 10.1016/j.flowmeasinst.2018.03.006.
- [28] S. Kuang, Z. Qi, A. B. Yu, A. Vince, G. D. Barnett, and P. J. Barnett, “CFD modeling and analysis of the multiphase flow and performance of dense medium cyclones,” *Miner. Eng.*, vol. 62, pp. 43–54, Jul. 2014, doi: 10.1016/j.mineng.2013.10.012.
- [29] K. Washino, E. L. Chan, T. Kaji, Y. Matsuno, and T. Tanaka, “On large scale CFD–DEM simulation for gas–liquid–solid three-phase flows,” *Particuology*, Jul. 2020, doi: 10.1016/j.partic.2020.05.006.
- [30] M. Parsi *et al.*, “Assessment of a hybrid CFD model for simulation of complex vertical upward gas–liquid churn flow,” *Chem. Eng. Res. Des.*, vol. 105, pp. 71–84, Jan. 2016, doi: 10.1016/j.cherd.2015.10.044.
- [31] A. Soleymani, A. Laari, and I. Turunen, “Simulation of drop formation in a single hole in solvent extraction using the volume-of-fluid method,” *Chem. Eng. Res. Des.*, vol. 86, no. 7, pp. 731–738, Jul. 2008, doi: 10.1016/j.cherd.2008.03.024.
- [32] R. Rzehak and S. Kriebitzsch, “Multiphase CFD-simulation of bubbly pipe flow: A code comparison,” *Int. J. Multiph. Flow*, vol. 68, pp. 135–152, Jan. 2015, doi: 10.1016/j.ijmultiphaseflow.2014.09.005.
- [33] T. Taha and Z. F. Cui, “CFD modelling of slug flow in vertical tubes,” *Chem. Eng. Sci.*, vol. 61, no. 2, pp. 676–687, Jan. 2006, doi: 10.1016/j.ces.2005.07.022.
- [34] M. Naderi and E. Khamehchi, “Well placement optimization using metaheuristic bat algorithm,” *J. Pet. Sci. Eng.*, vol. 150, no. July 2016, pp. 348–354, Feb. 2017, doi: 10.1016/j.petrol.2016.12.028.
- [35] F. J. Montáns, F. Chinesta, R. Gómez-Bombarelli, and J. N. Kutz, “Data-driven modeling and learning in science and engineering,” *Comptes Rendus Mécanique*, vol. 347, no. 11, pp. 845–855, Nov. 2019, doi: 10.1016/j.crme.2019.11.009.
- [36] Z. Lai and S. Nagarajaiah, “Sparse structural system identification method for nonlinear dynamic systems with hysteresis/inelastic behavior,” *Mech. Syst. Signal Process.*, vol. 117, pp. 813–842, Feb. 2019, doi: 10.1016/j.ymsp.2018.08.033.
- [37] A. C. Bannwart, O. M. H. Rodriguez, C. H. M. de Carvalho, I. S. Wang, and R. M. O. Vara, “Flow Patterns in Heavy Crude Oil-Water Flow,” *J. Energy Resour. Technol.*, vol. 126, no. 3, pp. 184–189, Sep. 2004, doi: 10.1115/1.1789520.
- [38] B. Grassi, D. Strazza, and P. Poesio, “Experimental validation of theoretical models in two-phase high-viscosity ratio liquid–liquid flows in horizontal and slightly inclined pipes,” *Int. J. Multiph. Flow*, vol. 34, no. 10, pp. 950–965, Oct. 2008, doi: 10.1016/j.ijmultiphaseflow.2008.03.006.
- [39] J. L. Trallero, C. Sarica, and J. P. Brill, “A Study of Oil-Water Flow Patterns in Horizontal Pipes,” *SPE Prod. Facil.*, vol. 12, no. 03, pp. 165–172, Aug. 1997, doi: 10.2118/36609-PA.
- [40] S. Kalam, M. R. Khan, Z. Tariq, F. A. Siddique, A. Abdulraheem, and R. A. Khan, “A Novel Correlation to Predict Gas Flow Rates Utilizing Artificial Intelligence: An Industrial 4.0 Approach,” Feb. 2019, doi: 10.2118/201170-MS.
- [41] B. Bahrami, S. Mohsenpour, H. R. Shamshiri Noghabi, N. Hemmati, and A. Tabzar, “Estimation of flow rates of individual phases in an oil-gas-water multiphase flow system

- using neural network approach and pressure signal analysis,” *Flow Meas. Instrum.*, vol. 66, no. December 2018, pp. 28–36, Apr. 2019, doi: 10.1016/j.flowmeasinst.2019.01.018.
- [42] H. Bao, J. Feng, N. Dinh, and H. Zhang, “Deep learning interfacial momentum closures in coarse-mesh CFD two-phase flow simulation using validation data,” *Int. J. Multiph. Flow*, vol. 135, p. 103489, Feb. 2021, doi: 10.1016/j.ijmultiphaseflow.2020.103489.
- [43] C. Chimeno-Trinchet, C. Murru, M. E. Díaz-García, A. Fernández-González, and R. Badía-Laíño, “Artificial Intelligence and fourier-transform infrared spectroscopy for evaluating water-mediated degradation of lubricant oils,” *Talanta*, vol. 219, no. June, p. 121312, Nov. 2020, doi: 10.1016/j.talanta.2020.121312.
- [44] L. M. Saini and M. K. Soni, “Artificial Neural Network-Based Peak Load Forecasting Using Conjugate Gradient Methods,” *IEEE Power Eng. Rev.*, vol. 22, no. 7, pp. 59–59, Jul. 2002, doi: 10.1109/MPER.2002.4312410.
- [45] M. Süßer, “Flow Measurement Handbook: Industrial Designs, Operating Principles, Performance and Applications,” *Cryogenics (Guildf.)*, vol. 40, no. 6, p. 421, Jan. 2000, doi: 10.1016/S0011-2275(00)00051-5.
- [46] E. Jorjani, S. Chehreh Chelgani, and S. Mesroghli, “Application of artificial neural networks to predict chemical desulfurization of Tabas coal,” *Fuel*, vol. 87, no. 12, pp. 2727–2734, Sep. 2008, doi: 10.1016/j.fuel.2008.01.029.
- [47] H. M. H. Al-Rikabi, M. A. M. Al-Ja’afari, A. H. Ali, and S. H. Abdulwahed, “Generic model implementation of deep neural network activation functions using GWO-optimized SCPWL model on FPGA,” *Microprocess. Microsyst.*, vol. 77, p. 103141, Sep. 2020, doi: 10.1016/j.micpro.2020.103141.
- [48] M. Attia, M. A. Mahmoud, A. Abdulraheem, and S. A. Al-Neaim, “Evaluation of the pressure drop due to multi phase flow in horizontal pipes using fuzzy logic and neural networks,” *SPE Middle East Oil Gas Show Conf. MEOS, Proc.*, vol. 2, no. 2, pp. 1065–1075, 2013, doi: 10.2118/164278-ms.
- [49] K. Salahshoor, S. Zakeri, and M. Haghghat Sefat, “Stabilization of gas-lift oil wells by a nonlinear model predictive control scheme based on adaptive neural network models,” *Eng. Appl. Artif. Intell.*, vol. 26, no. 8, pp. 1902–1910, Sep. 2013, doi: 10.1016/j.engappai.2013.03.007.
- [50] I. Al Selaiti *et al.*, “Robust Data Driven Well Performance Optimization Assisted by Machine Learning Techniques for Natural Flowing and Gas-Lift Wells in Abu Dhabi,” in *Day 4 Thu, October 29, 2020*, Oct. 2020, vol. 2020-October, doi: 10.2118/201696-MS.
- [51] M. R. Khan, S. Alnuaim, Z. Tariq, and A. Abdulraheem, “Machine learning application for oil rate prediction in artificial gas lift wells,” *SPE Middle East Oil Gas Show Conf. MEOS, Proc.*, vol. 2019-March, 2019, doi: 10.2118/194713-ms.
- [52] W. Dang, Z. Gao, L. Hou, D. Lv, S. Qiu, and G. Chen, “A Novel Deep Learning Framework for Industrial Multiphase Flow Characterization,” *IEEE Trans. Ind. Informatics*, vol. 15, no. 11, pp. 5954–5962, Nov. 2019, doi: 10.1109/TII.2019.2908211.
- [53] D. C. G.-E. O, and C. M, “Predictive Modeling of Holdup in Horizontal Wateroil Flow Using a Neural Network Approach,” in *14th WCCM-ECCOMAS Congress*, 2021, no. January, pp. 11–15, doi: 10.23967/wccm-eccomas.2020.283.
- [54] S. Rostami, F. Rashidi, and H. Safari, “Prediction of oil-water relative permeability in sandstone and carbonate reservoir rocks using the CSA-LSSVM algorithm,” *J. Pet. Sci. Eng.*, vol. 173, no. April 2018, pp. 170–186, 2019, doi: 10.1016/j.petrol.2018.09.085.

- [55] L. A. Zadeh, "Fuzzy Sets \* -," *Inf. Control*, vol. 8, no. 3, pp. 338–353, 1965, doi: 10.1016/S0019-9958(65)90241-X.
- [56] L. H. Tsoukalas, M. Ishii, and Y. MI, "A Neurofuzzy Methodology for Impedance-based Multiphase Flow Identification," *Eng. Appl. Artif. Intell.*, vol. 10, no. 6, pp. 545–555, 1997, doi: 10.1016/S0952-1976(97)00037-7.
- [57] F. Popa, S. Dursun, F. Halliburton, and B. Houchens, "Fuzzynistic Models for Multiphase Flow Pattern Identification," 2015, no. September, pp. 28–30.
- [58] W. A. Deabes and H. H. Amin, "Fast Intelligent Image Reconstruction Algorithm for ECT Systems," in *Advances in Intelligent Systems and Computing*, 2016, vol. 474, pp. V–VI, doi: 10.1007/978-3-319-40162-1.
- [59] J. R. Jang, "ANFIS : Adap tive-Ne twork-Based Fuzzy Inference System," vol. 23, no. 3, 1993.
- [60] T. Takagi and M. Sugeno, "Derivation of Fuzzy Control Rules from Human Operator's Control Actions," *IFAC Proc. Vol.*, vol. 16, no. 13, pp. 55–60, Jul. 1983, doi: 10.1016/S1474-6670(17)62005-6.
- [61] M. H. N. Marinho, S. Soares, and R. Ballini, "Previsão de Vazões Afluentes Naturais Usando o Modelo ANFIS Universidade Estadual de Campinas Faculdade de Engenharia Elétrica e de Computação Instituto de Economia Takagi - Sugeno," pp. 163–168, 2003.
- [62] M. Rasheed Khan, Z. Tariq, and A. Abdulraheem, "Utilizing state of the art computational intelligence to estimate oil flow rate in artificial lift wells," *Soc. Pet. Eng. - SPE Kingdom Saudi Arab. Annu. Tech. Symp. Exhib. 2018, SATS 2018*, 2018, doi: 10.2118/192321-ms.
- [63] S. Valizadeh, B. Moshiri, and K. Salahshoor, "Multiphase pipeline leak detection based on fuzzy classification," *AIP Conf. Proc.*, vol. 1159, no. 2009, pp. 72–80, 2009, doi: 10.1063/1.3223958.
- [64] E. A. El-Sebakhy, "Flow regimes identification and liquid-holdup prediction in horizontal multiphase flow based on neuro-fuzzy inference systems," *Math. Comput. Simul.*, vol. 80, no. 9, pp. 1854–1866, May 2010, doi: 10.1016/j.matcom.2010.01.002.
- [65] M. Attia, A. Abdulraheem, and M. A. Mahmoud, "Pressure drop due to multiphase flow using four artificial intelligence methods," *Soc. Pet. Eng. - SPE North Africa Tech. Conf. Exhib. 2015, NATC 2015*, pp. 170–179, 2015, doi: 10.2118/175724-ms.
- [66] S. Mottaghi, M. Nazari, S. M. Fattahi, M. Nazari, and S. Babamohammadi, "Droplet size prediction in a microfluidic flow focusing device using an adaptive network based fuzzy inference system," *Biomed. Microdevices*, vol. 22, no. 3, 2020, doi: 10.1007/s10544-020-00513-4.
- [67] R. H. Ruschel, *Proposição de modelo de fluxo de deslizamento para escoamento líquido-líquido horizontal*. Campinas, Brasil, 2020.
- [68] P. Abduvayt, R. Manabe, T. Watanabe, and N. Arihara, "Análisis of oil-water flow tests in horizontal, hilly-terrain, and vertical pipes," *Proc. - SPE Annu. Tech. Conf. Exhib.*, pp. 1335–1347, 2004, doi: 10.2523/90096-ms.
- [69] J. Cai, C. Li, X. Tang, F. Ayello, S. Richter, and S. Nestic, "Experimental study of water wetting in oil-water two phase flow-Horizontal flow of model oil," *Chem. Eng. Sci.*, vol. 73, pp. 334–344, 2012, doi: 10.1016/j.ces.2012.01.014.
- [70] G. Universidad, S. Bolívar, M. T. Universidad, K. Universidad, S. Bolívar, and C. Universidad, "DETERMINACIÓN DE ALTURA DE FASE Y HOLD UP PARA FLUJO BIFÁSICO LÍQUIDO- LÍQUIDO EN TUBERÍAS HORIZONTALES POR MEDIO DE

- PROCESAMIENTO DE IMÁGENES,” 2009, pp. 1–10.
- [71] A. Al-Sarkhi, E. Pereyra, I. Mantilla, and C. Avila, “Dimensionless oil-water stratified to non-stratified flow pattern transition,” *J. Pet. Sci. Eng.*, vol. 151, no. September 2016, pp. 284–291, Mar. 2017, doi: 10.1016/j.petrol.2017.01.016.
- [72] J. Shi, L. Lao, and H. Yeung, “Water-lubricated transport of high-viscosity oil in horizontal pipes: The water holdup and pressure gradient,” *Int. J. Multiph. Flow*, vol. 96, pp. 70–85, 2017, doi: 10.1016/j.ijmultiphaseflow.2017.07.005.
- [73] T. Al-Wahaibi *et al.*, “Experimental investigation on flow patterns and pressure gradient through two pipe diameters in horizontal oil-water flows,” *J. Pet. Sci. Eng.*, vol. 122, pp. 266–273, 2014, doi: 10.1016/j.petrol.2014.07.019.
- [74] A. Dasari, A. B. Desamala, A. K. Dasmahapatra, and T. K. Mandal, “Experimental studies and probabilistic neural network prediction on flow pattern of viscous oil-water flow through a circular horizontal pipe,” *Ind. Eng. Chem. Res.*, vol. 52, no. 23, pp. 7975–7985, 2013, doi: 10.1021/ie301430m.
- [75] R. Ibarra, I. Zadrazil, C. N. Markides, and O. K. Matar, “Towards a Universal Dimensionless Map of Flow Regime,” *11th Int. Conf. Heat Transf. Fluid Mech. Thermodyn.*, no. July, 2015.
- [76] M. Nädler and D. Mewes, “Flow induced emulsification in the flow of two immiscible liquids in horizontal pipes,” *Int. J. Multiph. Flow*, vol. 23, no. 1, pp. 55–68, 1997, doi: 10.1016/s0301-9322(96)00055-9.
- [77] O. M. H. Rodriguez and R. V. A. Oliemans, “Experimental study on oil–water flow in horizontal and slightly inclined pipes,” *Int. J. Multiph. Flow*, vol. 32, no. 3, pp. 323–343, Mar. 2006, doi: 10.1016/j.ijmultiphaseflow.2005.11.001.
- [78] J. Shi and H. Yeung, “Characterization of liquid-liquid flows in horizontal pipes,” *AIChE J.*, vol. 63, no. 3, pp. 1132–1143, 2017, doi: 10.1002/aic.15452.
- [79] A. Wegmann and P. Rudolf von Rohr, “Two phase liquid-liquid flows in pipes of small diameters,” *Int. J. Multiph. Flow*, vol. 32, no. 8, pp. 1017–1028, 2006, doi: 10.1016/j.ijmultiphaseflow.2006.04.001.
- [80] M. Du, N.-D. Jin, Z.-K. Gao, Z.-Y. Wang, and L.-S. Zhai, “Flow pattern and water holdup measurements of vertical upward oil–water two-phase flow in small diameter pipes,” *Int. J. Multiph. Flow*, vol. 41, pp. 91–105, May 2012, doi: 10.1016/j.ijmultiphaseflow.2012.01.007.
- [81] J. Flores, X. Chen, and J. Brill, “Characterization of Oil-Water Flow Patterns in Vertical and Deviated Wells,” in *Proceedings of SPE Annual Technical Conference and Exhibition*, Oct. 1997, vol. 1, pp. 55–64, doi: 10.2523/38810-MS.
- [82] T. Ganat, S. Ridha, M. Hairir, J. Arisa, and R. Gholami, “Experimental investigation of high-viscosity oil–water flow in vertical pipes: flow patterns and pressure gradient,” *J. Pet. Explor. Prod. Technol.*, vol. 9, no. 4, pp. 2911–2918, Dec. 2019, doi: 10.1007/s13202-019-0677-y.
- [83] G. W. Govier, G. A. Sullivan, and R. K. Wood, “The upward vertical flow of oil-water mixtures,” *Can. J. Chem. Eng.*, vol. 39, no. 2, pp. 67–75, Apr. 1961, doi: 10.1002/cjce.5450390204.
- [84] Y. F. Han, N. D. Jin, L. S. Zhai, H. X. Zhang, and Y. Y. Ren, “Flow pattern and holdup phenomena of low velocity oil-water flows in a vertical upward small diameter pipe,” *J. Pet. Sci. Eng.*, vol. 159, no. May, pp. 387–408, Nov. 2017, doi:

- 10.1016/j.petrol.2017.09.052.
- [85] A. R. Hasan and C. S. Kabir, “A New Model for Two-Phase Oil/Water Flow: Production Log Interpretation and Tubular Calculations,” *SPE Prod. Eng.*, vol. 5, no. 02, pp. 193–199, May 1990, doi: 10.2118/18216-PA.
- [86] A. R. Hasan and C. S. Kabir, “A simplified model for oil/water flow in vertical and deviated wellbores,” *SPE Prod. Facil.*, vol. 14, no. 1, pp. 56–62, 1999, doi: 10.2118/54131-PA.
- [87] A. K. Jana, G. Das, and P. K. Das, “Flow regime identification of two-phase liquid-liquid upflow through vertical pipe,” *Chem. Eng. Sci.*, vol. 61, no. 5, pp. 1500–1515, 2006, doi: 10.1016/j.ces.2005.09.001.
- [88] A. K. Jana, P. Ghoshal, G. Das, and P. K. Das, “An Analysis of Pressure Drop and Holdup for Liquid-Liquid Upflow through Vertical Pipes,” *Chem. Eng. Technol.*, vol. 30, no. 7, pp. 920–925, Jul. 2007, doi: 10.1002/ceat.200700033.
- [89] J. Guo *et al.*, “Heavy oil-water flow patterns in a small diameter vertical pipe under high temperature/pressure conditions,” *J. Pet. Sci. Eng.*, vol. 171, pp. 1350–1365, Dec. 2018, doi: 10.1016/j.petrol.2018.08.021.
- [90] R. A. Mazza and F. K. Suguimoto, “Experimental investigations of kerosene-water two-phase flow in vertical pipe,” *J. Pet. Sci. Eng.*, vol. 184, p. 106580, Jan. 2020, doi: 10.1016/j.petrol.2019.106580.
- [91] K. Mydlarz-Gabryk, M. Pietrzak, and L. Troniewski, “Study on oil–water two-phase upflow in vertical pipes,” *J. Pet. Sci. Eng.*, vol. 117, pp. 28–36, May 2014, doi: 10.1016/j.petrol.2014.03.007.
- [92] O. M. H. Rodriguez and A. C. Bannwart, “Experimental study on interfacial waves in vertical core flow,” *J. Pet. Sci. Eng.*, vol. 54, no. 3–4, pp. 140–148, 2006, doi: 10.1016/j.petrol.2006.07.007.
- [93] J. Xu, D. Li, J. Guo, and Y. Wu, “Investigations of phase inversion and frictional pressure gradients in upward and downward oil–water flow in vertical pipes,” *Int. J. Multiph. Flow*, vol. 36, no. 11–12, pp. 930–939, Nov. 2010, doi: 10.1016/j.ijmultiphaseflow.2010.08.007.
- [94] Y. Yang *et al.*, “Oil-Water flow patterns, holdups and frictional pressure gradients in a vertical pipe under high temperature/pressure conditions,” *Exp. Therm. Fluid Sci.*, vol. 100, no. September 2018, pp. 271–291, Jan. 2019, doi: 10.1016/j.expthermflusci.2018.09.013.
- [95] D. Zhao, L. Guo, X. Hu, X. Zhang, and X. Wang, “Experimental study on local characteristics of oil-water dispersed flow in a vertical pipe,” *Int. J. Multiph. Flow*, vol. 32, no. 10–11, pp. 1254–1268, 2006, doi: 10.1016/j.ijmultiphaseflow.2006.06.004.