

Identificación de patrones de flujo bifásico conformado por aceite lubricante y agua en tuberías verticales aplicando técnicas de inteligencia artificial.

Brayan Gonzalo Quispe Suarez

Trabajo de Grado para Optar al Título Ingeniero Mecánico

Director

Octavio Andrés Gonzáles Estrada

PhD en Ingeniería Mecánica y de Materiales

Codirector

Carlos Mauricio Ruiz Diaz

Magister en Ingeniería Mecánica

Marlon Mauricio Hernández Cely

PhD en Ingeniería Mecánica

Universidad Industrial de Santander
Facultad de Ingenierías Fiscomecánicas
Escuela de Ingeniería Mecánica
Bucaramanga

2022

Dedicatoria

Dedico este trabajo a mis padres, Gonzalo Quispe y Luz Suarez, por su apoyo incondicional en mi formación como Ingeniero Mecánico.

Agradecimientos

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

Agradezco a Carlos Mauricio Ruiz Diaz, PhD, codirector de mi proyecto de investigación, por su disposición a ayudarme a realizar este trabajo, su comprensión y acompañamiento profesional.

Agradezco a Octavio Andrés González Estrada, PhD., director de mi proyecto de investigación, por confiar en mí, por brindarme su acompañamiento profesional.

Tabla de contenido

	Pág.
Introducción	13
1 Objetivos.....	16
1.1 Objetivo general	16
1.2 Objetivos específicos.....	16
2 Flujo multifásico.....	17
2.1 Patrones de flujo en tubería vertical.....	17
2.2 VFM basado en datos	20
3 Redes neuronales artificiales	22
4 Preprocesamiento de datos	23
4.1 Normalización	24
4.2 Codificación	25
5 Estructuración del modelo LSTM	26
5.1 Arquitectura de LSTM	29
5.2 Celda de estado.....	30
5.3 Funciones de activación	33
5.4 Funciones de error.....	35
5.5 Parámetros de optimización	37
6 Evaluación del modelo	39
7 Resultados.....	42
8 Conclusiones.....	49

9	Referencias bibliográficas	51
10	Apéndices.....	57

Lista de Tablas

	Pág.
Tabla 1 Patrones de flujo en tubería vertical	23
Tabla 2 Cuantificación de datos para cada patrón de flujo	24
Tabla 3 Configuraciones de LSTM.....	37

Lista de Figuras

	Pág.
Figura 1 Patrones de flujo en tubería vertical	18
Figura 2 VFM basado en datos	21
Figura 3 Comparación neurona biológica frente a neurona artificial	22
Figura 4 Codificación OneHotEncoder	26
Figura 5 Red neuronal recurrente	27
Figura 6 (a) Red neuronal recurrente (b) LSTM.....	28
Figura 7 Estructura general de una LSTM.....	29
Figura 8 Celda de estado LSTM.	30
Figura 9 Secuencia lógica desarrollada al interior de la celda de estado LSTM. (a) primer orden lógico, (b) segundo orden lógico, (c) tercer orden lógico, (d) finalización de la secuencia	31
Figura 10 Neurona con función de activación	34
Figura 11 Funciones de activación implementadas	35
Figura 12 Evaluación de modelos con respecto a función de pérdida, (a) Fase de entrenamiento, (b) Fase de validación	39
Figura 13 Evaluación de la precisión de los modelos, (a) Fase de entrenamiento, (b) Fase de validación	41
Figura 14 Evaluación del algoritmo seleccionado, LSTM 1	43
Figura 15 Mapa de flujo con datos de autores	44
Figura 16 Mapa de flujo genera a partir de red LSTM 1	45

Figura 17 Mapa de flujo con datos de [26]	46
Figura 18 Carta de flujo generada para [28], aplicando el modelo LSTM 1	47
Figura 19 Mapa de flujo con datos de [34]	48
Figura 20 Carta de flujo generada, a partir de los datos de [34]	49

Lista de Apéndices

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

Apéndice 1. Mapa de flujo de Abduvayat

Apéndice 2. Mapa de flujo de Abduvayat generado por red LSTM 1

Apéndice 3. Mapa de flujo de Bannwart

Apéndice 4. Mapa de flujo de Bannwart generado por red LSTM 1

Apéndice 5. Mapa de flujo de Du

Apéndice 6. Mapa de flujo de du generado por red LSTM 1

Apéndice 7. Mapa de flujo de Flores

Apéndice 8. Mapa de flujo de Flores generado por red LSTM 1

Apéndice 9. Mapa de flujo de Ganat

Apéndice 10. Mapa de flujo de Ganat generado por red LSTM 1

Apéndice 11. Mapa de flujo de Govier

Apéndice 12. Mapa de flujo de Govier generado por red LSTM 1

Apéndice 13. Mapa de flujo de Han

Apéndice 14. Mapa de flujo de Han generado por red LSTM 1

Apéndice 15. Mapa de flujo de Hassan

Apéndice 16. Mapa de flujo de Hassan generado por red LSTM 1

Apéndice 17. Mapa de flujo de Hassan 1998

Apéndice 18. Mapa de flujo de Hassan 1998 generado por red LSTM 1

Apéndice 19. Mapa de flujo de Jana

Apéndice 20. Mapa de flujo de Jana generado por red LSTM 1

Apéndice 21. Mapa de flujo de Jana 2007

Apéndice 22. Mapa de flujo de Jana 2007 generado por red LSTM 1

Apéndice 23. Mapa de flujo de Jixiang

Apéndice 24. Mapa de flujo de Jixiang generado por red LSTM 1

Apéndice 25. Mapa de flujo de Mazza

Apéndice 26. Mapa de flujo de Mazza generado por red LSTM 1

Apéndice 27. Mapa de flujo de Myldraz

Apéndice 28. Mapa de flujo de Myldraz generado por red LSTM 1

Apéndice 29. Mapa de flujo de Rodriguez

Apéndice 30. Mapa de flujo de Rodriguez generado por red LSTM 1

Apéndice 31. Mapa de flujo de Xu

Apéndice 32. Mapa de flujo de Xu generado por red LSTM 1

Apéndice 33. Mapa de flujo de Yang

Apéndice 34. Mapa de flujo de Yang generado por red LSTM 1

Apéndice 35. Mapa de flujo de Zhao

Apéndice 36. Mapa de flujo de Zhao generado por red LSTM 1

Resumen

Título: Identificación de patrones de flujo bifásico conformado por aceite lubricante y agua en tuberías verticales aplicando técnicas de inteligencia artificial *

Autor: Brayan Gonzalo Quispe Suarez **

Palabras Clave: LSTM, Redes neuronales recurrentes, Flujo bifásico líquido-líquido, Patrones de flujo

Descripción: La estructuración de mapas de flujo en la industria de hidrocarburos se ha desarrollado a partir de correlaciones empíricas que integran características del flujo, como velocidades superficiales y fracciones volumétricas, en conjunto con propiedades físicas de las sustancias en análisis como densidad y viscosidad, además de utilizar parámetros geométricos como la inclinación y el diámetro interno de las tuberías. En la actualidad, se han desarrollado avances tecnológicos que permiten optimizar el proceso de identificación de patrones de flujo, a partir de la implementación de técnicas de inteligencia artificial, debido a que existen limitaciones para monitorear el patrón de flujo generado al interior de las tuberías de las plataformas instaladas en altamar, dadas las condiciones de trabajo extremas que allí se presentan. En este estudio se desarrolló una red neuronal recurrente de memoria a largo y corto plazo (LSTM), capaz de predecir los patrones de flujo generados al interior de tuberías verticales. La red LSTM fue entrenada y posteriormente validada con la información contenida en una base de datos obtenida de la literatura, mostrando un error generado en las predicciones del modelo inferior al 1%.

* Trabajo de Grado

** Facultad de Ingenierías Fiscomecánicas. Escuela de Ingeniería Mecánica. Pregrado en Ingeniería Mecánica. Director: Octavio Andrés González Estrada, PhD en Ingeniería Mecánica y de Materiales. Codirectores: Carlos Mauricio Ruiz Diaz, Magister en Ingeniería Mecánica, Marlon Mauricio Hernández Cely, PhD en Ingeniería Mecánica.

Abstract

Title: Identification of two-phases flow patterns made up of lubricating oil and water in vertical pipes applying artificial intelligence techniques*

Author: Brayan Gonzalo Quispe Suarez **

Key Words: LSTM, Recurrent neural networks, Liquid-liquid two-phase flow, Flow pattern

Description: Flow map structuring in the hydrocarbon industry has been developed from empirical correlations that integrate flow characteristics such as surface velocities and volume fractions, together with physical properties of the substances under analysis such as density and viscosity, and geometric parameters such as pipe inclination and internal diameter. Currently, technological advances have been developed to optimize the process of identifying flow patterns, from the implementation of artificial intelligence techniques, because there are limitations to monitor the flow pattern generated inside the pipes of offshore platforms, given the extreme working conditions that occur there. In this study, a long-short term memory network (LSTM) was developed in free software, capable of predicting the flow patterns generated inside vertical pipes. The LSTM network was trained and then validated with the information contained in a database obtained from the literature, showing an error generated in the prediction model less than 1%.

* Degree Work

** 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: Carlos Mauricio Ruiz Diaz, master's in mechanical engineering, Marlon Mauricio Hernández Cely, PhD in Mechanical Engineering.

Introducción

El transporte de flujo multifásico debe tenerse en cuenta en el diseño y la optimización de muchos sistemas de ingeniería como los son equipos de procesamiento de alimentos, pilas de combustible y la industria petroquímica (Amir & Zhang, 2017), esta última ha centrado sus estudios actuales en el transporte de crudo (Archibong-Eso et al., 2019). La optimización de la producción en campos petroleros ocurre con el monitoreo continuo de caudales, temperatura y presiones del fluido extraído en pozos, el desempeño se puede medir frente a los costos de extracción, el cual es posible con datos confiables que permitan tener una perspectiva clara del transporte de fluidos. A partir de los conceptos mencionados anteriormente, se han desarrollado estudios que permiten el modelamiento de flujos multifásicos en líneas de transporte en el mundo (Mauricio Ruiz Diaz et al., 2021). En los estudios desarrollados por (Andrianov, 2018), se muestra la capacidad que se tiene en el pronóstico de una clase de medidores de flujo virtual (VFM), por sus siglas en inglés, controlados por datos que alimentan las redes neuronales artificiales. En este trabajo, se demuestra que las redes neuronales pueden considerarse como una herramienta prometedora para pronosticar los valores de tasas multifásicas utilizando datos de presión y temperatura. Por otra parte, en el estudio realizado por (Hotvedt et al., 2022) se demostró que una frecuencia de actualización en los modelos VFM de estado estacionario es esencial para mantener el alto rendimiento a lo largo del tiempo en condiciones no estacionarias.

El estudio de flujos multifásicos integra conceptos relacionados de manera directa con fenómenos de transporte, en el modelaje y en la caracterización de los flujos, utilizando los principios de conservación de la masa y conservación de la cantidad de movimiento. Dichos principios permiten obtener una aproximación matemática de las características del flujo al interior de las tuberías (Çengel & Cimbala, 2006). La descripción del comportamiento de flujo multifásico

requiere del uso de datos o correlaciones experimentales, esto debido a la complejidad que conlleva su estudio. El modelaje de un flujo multifásico es una técnica en desarrollo que es posible gracias a la aparición de métodos computacionales mejorados, generalmente se necesitan datos o correlaciones experimentales en la implementación de estos (Bai & Bai, 2011).

Los flujos multifásicos los podemos encontrar en múltiples prácticas de ingeniería especialmente en la industria del petróleo, donde podemos encontrar flujos bifásicos y trifásicos (Chen & Guo, 1999). El flujo bifásico se refiere al flujo interactivo de dos fases distintas (cada fase representa una masa o volumen de materia) con interfaces comunes en un canal. Las posibles combinaciones son sólido-líquido, donde las partículas sólidas se dispersan principalmente en el líquido; sólido-gas, donde las partículas sólidas son transportadas por una corriente de gas; líquido-vapor (gas), donde la fracción de volumen de una fase en relación con la otra da como resultado diferentes regímenes de flujo y combinación de los anteriores (Faghri & Zhang, 2020).

Actualmente se tiene un precedente amplio de estudios en el comportamiento de los flujos multifásicos, donde se quiere desarrollar un modelo basado en datos, que es una técnica basada en analizar los datos del sistema y encontrar relaciones entre las variables de entrada y salida del sistema sin un conocimiento de las ecuaciones físicas (Fallis, 2013). Esto trae desafíos al momento de suministrar los datos de entrada, por lo que es fundamental dar un trato estadístico adecuado y con esto evitar un mal ajuste en los parámetros del modelo (Andrade et al., 2022). Lo anterior se logra implementado redes neuronales artificiales, la cual inicia calculando una función con las entradas puestas propagando los valores calculados desde las neuronas de entrada a las neuronas de salida y utilizando los pesos como parámetros intermedios. El aprendizaje ocurre cambiando estos pesos que conectan las neuronas (Aggarwal, 2018), para tener predicciones que se ajusten a la realidad.

El estudio realizado por (Sun et al., 2018) donde se tienen los datos diarios de la producción de crudo, agua y gas que se generó de un campo petrolífero, se emplean como principal variable de entrada para modelar una red neuronal y se tiene como resultado predicciones de producción multifase en un futuro cercano al estudiado, implementando el algoritmo Long-short term memory (LSTM) para la generación del modelo. Esto muestra que, en comparación con el modelo basado en la física de simulación numérica, este enfoque de red neuronal no depende en gran medida de los cálculos de principios de ingeniería y ofrece soluciones más rápidas y robustas. Por otra parte, en (Song et al., 2022) se realiza una investigación que emplea sistemas de inteligencia artificial con datos reales de una plataforma petrolífera en el mar de China para desarrollar un modelo de medidores de flujo virtual, en este trabajo se muestra como LSTM considera la influencia del paso del tiempo anterior sobre el caudal que está siendo evaluado, con esto captura la relación entre parámetros como la temperatura y la presión sobre el caudal a predecir. LSTM se evidencia en (Andrianov, 2018), donde se muestra que la precisión se mejora si las longitudes de entrada y salida de datos en la secuencia son iguales y se plantea como se puede quitar esta limitación sin perder precisión en la red neuronal.

En este trabajo se desarrolla un modelo de red neuronal recurrente implementando el algoritmo LSTM, con el fin de predecir los patrones de flujo generados al interior de tuberías verticales de flujo bifásico líquido-líquido de aceite lubricante y agua.

1 Objetivos

1.1 Objetivo General

Determinar los patrones de flujo bifásico para la combinación de aceite lubricante y agua al interior de tuberías verticales aplicando técnicas de inteligencia artificial con el fin de monitorear el transporte del flujo.

1.2 Objetivos Específicos

Parametrizar fracciones volumétricas de flujo bifásico en tubería vertical con flujo de aceite lubricante y agua combinados , usando las variables recurrente velocidades de inyección, viscosidad y diámetro de tubería a partir de la implementación de técnicas de inteligencia artificial aplicadas a la información contenida en bases de datos presentada por Ruiz-Diaz et al., 2021 .

Estructurar un modelo predictivo basado en Long Short Term Memory (LSTM) para la identificación de patrones de flujo bifásico conformado por aceite lubricante y agua a partir de parámetros como las fracciones volumétricas de los fluidos, velocidades superficiales, viscosidades y diferencial de presión en la línea.

Implementar una solución interactiva en el software Python a partir de la aplicación de Long Short Term Memory (LSTM) para la identificación de patrones de flujo bifásico conformado por aceite lubricante y agua.

2 Flujo multifásico

El flujo multifásico es definido como el flujo simultáneo de numerosas fases. En el entorno actual se dispone de gran atención al transporte multifásico debido a que está presente en toda la industria petrolífera. Los estudios realizados para flujo de dos fases son complejos debido a la cantidad de variables que involucra, tales como viscosidades y densidades diferentes presentes en una misma tubería, diferencia en la velocidad que viajan las fases, entre otras, se suman a la complejidad del problema. En el caso de tener una configuración ascendente de un flujo en fase líquida y gaseosa, se tiene que la fase gaseosa es menos densa y viscosa, por lo cual tiende a fluir a mayor velocidad por la tubería en cuanto se limitan a geometrías de tubería simple y a unas condiciones constantes; los desafíos que presentan los flujos multifásicos son complejos (Bai & Bai, 2011). En la caracterización de flujos multifásicos se tiene como factor determinante los patrones de flujo que son diferentes disposiciones del flujo en la tubería.

2.1 Patrones de flujo en tubería vertical

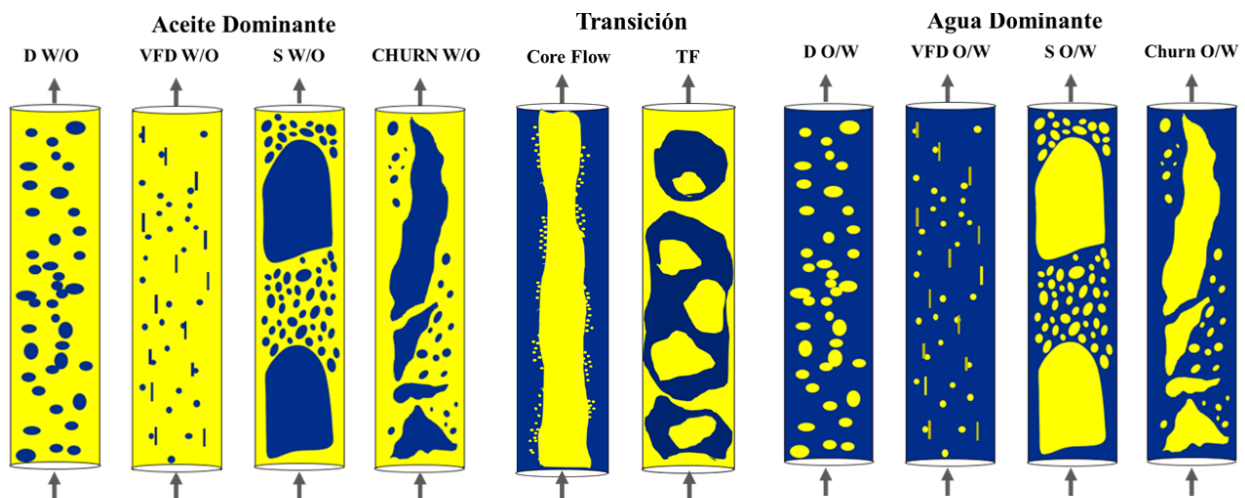
En tuberías verticales, el flujo de dos fases se puede clasificar teniendo en cuenta las configuraciones geométricas que desarrolla el flujo al interior de las tuberías bajo condiciones específicas, en este caso se representa una fase compuesta de agua que es inmisible en aceite, lo cual podemos clasificar como fluido bifásico líquido-líquido. En la Figura 1 se presentan diez tipos de patrones de flujo. Los parámetros influyentes en la formación de los patrones de flujo en tuberías verticales son: variables relativas de las fuerzas que actúan sobre los fluidos (como lo es la flotabilidad, la turbulencia, la inercia y las fuerzas de tensión superficial, que varían con las tasas de flujo volumétrico inyectado en la tubería), el diámetro de la tubería, el ángulo de inclinación, la temperatura del fluido, la rugosidad del material de la tubería y las propiedades del fluido. En este caso tenemos dos fases presentes que son agua y aceite, donde se tienen la tubería en una

posición completamente vertical, a temperatura ambiente y diámetro constante, se generan diez casos que se pueden clasificar.

Referente a la Figura 1 podemos definir que O y W representan respectivamente aceite y agua por sus siglas en inglés, para los diferentes patrones la nomenclatura de O/W representa que el fluido dominante es el agua, por el contrario, si se representa W/O dice que el fluido dominante en este patrón es el aceite.

Figura 1

Patrones de flujo en tubería vertical



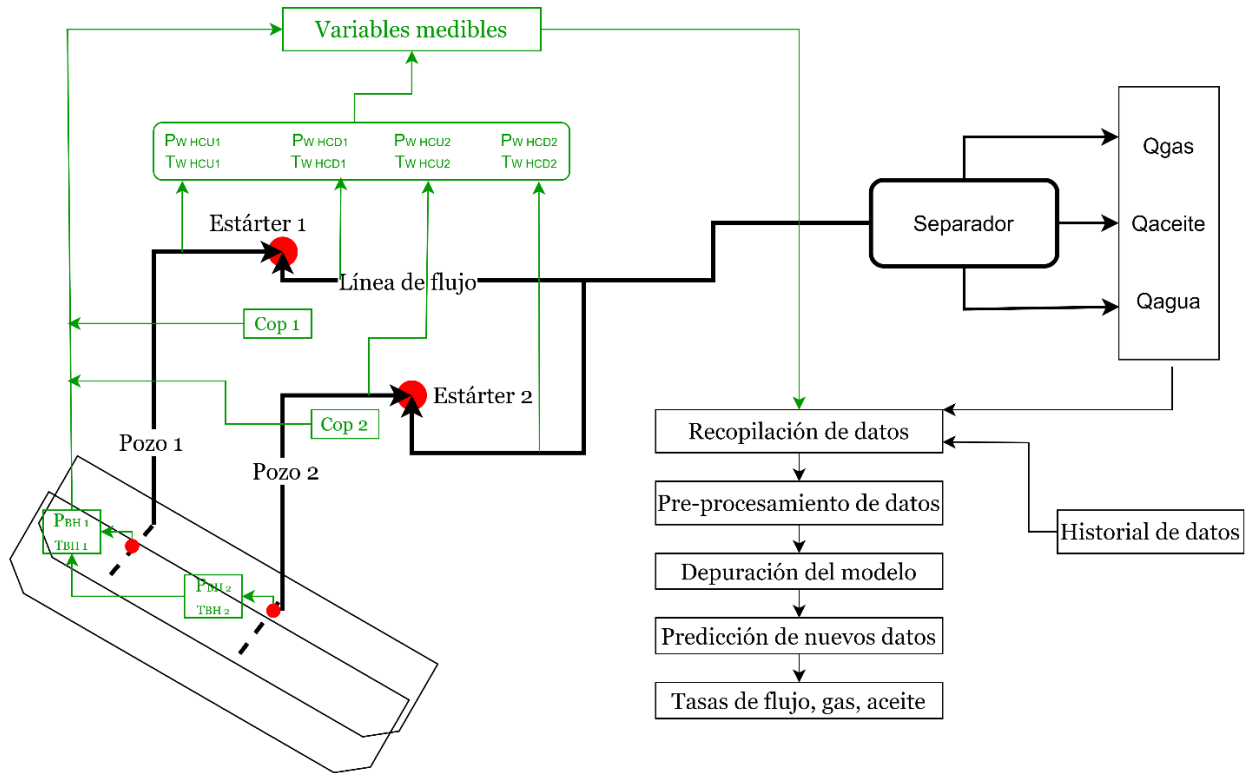
- **Gotas (D):** La simbología referente proviene del término inglés Drope. El desarrollo de gotas de fluido no compresible se presenta para caudales elevados de aceite y las gotas presentan diámetro considerable, sus formas suelen ser esferas, tapón elíptico y tapón esférico (Mauricio Ruiz Diaz et al., 2021). Las condiciones de flujo de este patrón se tienen a velocidades de entrada bajas de agua D O/W para las cuales casi no se producen rupturas de las burbujas de aceite (Guet & Ooms, 2006).

- **Dispersión muy fina (VFD):** Proviene del patrón de flujo D, donde la velocidad superficial del agua es pequeña, las grandes gotas de aceite en la fase de agua provocan un ligero aumento en el flujo con un pequeño aumento de la velocidad superficial del aceite. Esto logra que las grandes gotas de aceite en el agua se vuelvan demasiado pequeñas y se distribuyan con mayor frecuencia, dando paso al patrón de flujo VFD (Ganat et al., 2019).
- **Slug (S):** Con el aumento de la fracción de aceite de entrada, el flujo de aceite en agua se produce a una baja velocidad de mezcla de aceite y agua, esto se debe a que la energía de la turbulencia no es lo suficientemente alta para dispersar la fase de aceite. Esto hace que las gotas de aceite tengan grandes baches alargados o esféricos en el centro de la tubería, y como la velocidad de aceite aumenta, afecta las pérdidas de presión por fricción con el tubo ascendente y se genera una pequeña dispersión entre las alargadas gotas de aceite (Bai & Bai, 2011; Yang et al., 2019b).
- **Churn:** Los regímenes de flujo anteriores se consideran estables, por otra parte, el patrón de flujo Churn es un flujo intermitente, lo que siempre tendrá afectación en cómo se miden sus variables. Este ocurre cuando los tapones presentan una ruptura de forma más alargada y generando la intermitencia durante todo el recorrido del fluido por la tubería (Pan et al., 2019).
- **Core Flow:** Se presenta cuando se tiene una película de aceite fluyendo por el centro de la tubería, con esto se tiene una película de agua que es la que fricciona directamente con la tubería creando distorsiones, lo cual hace aparecer perturbaciones de alta consistencia en la película de agua (Li et al., 2022).
- **Flujo de transición (TF):** Con una fracción de agua superior al 55% el patrón evoluciona a un flujo con aceite predominante, a esto se le conoce como transición. Este es el estado

donde el flujo continuo de agua y aceite no se puede observar una fase continua (Jixiang Guo et al., 2019; Yang et al., 2019b). La energía de turbulencia aumenta, lo cual crea fluctuaciones que son las encargadas de realizar la transición de fluido dominante.

2.2 VFM basado en datos

La medición de flujo virtual o VFM, por sus siglas en inglés, tiene grandes ventajas frente a los medidores de flujo convencionales. La mayor ventaja que tiene este tipo de modelos, es la solución de sistemas o procesos para los que la solución exacta puede ser difícil de encontrar numéricamente (Andrade et al., 2022). Para modelar un VFM basado en datos, son necesario datos de calidad, tratados con técnicas de data science, una vez eliminados los outliers de los datos se dispone a realizar el modelo, el cual necesita de una parte de la data recopilada para su entrenamiento y verificación. Al momento de realizar pruebas de las predicciones arrojadas por el modelo, cabe recalcar que se tiene un margen de aceptación, esto debido a que las variables con las que es alimentado nuestro modelo presentan variaciones, lo cual genera un valor que difiere en muy poco del real.

Figura 2*VFM basado en datos*

La creación de modelos es un proceso en el cual se estudia un algoritmo que puede procesar las características de entrada y variables de salida, como se tiene en la Figura 2. El procesamiento de los datos se puede denominar entrenamiento o aprendizaje, durante el cual el algoritmo ajusta los parámetros de tal manera que estima las variables objetivo con precisión. En el caso de una red neuronal, los parámetros son los pesos que se conectan a las neuronas. El proceso de entrenamiento se logra minimizando una función de costo la cual se formula como la diferencia entre las predicciones del algoritmo y los valores reales (medidos). Una vez entrenado el modelo, debe validarse y probarse en un conjunto de datos diferentes para garantizar que el modelo entrenado funcione bien en los datos que el modelo no ha visto durante el entrenamiento (Bikmukhametov

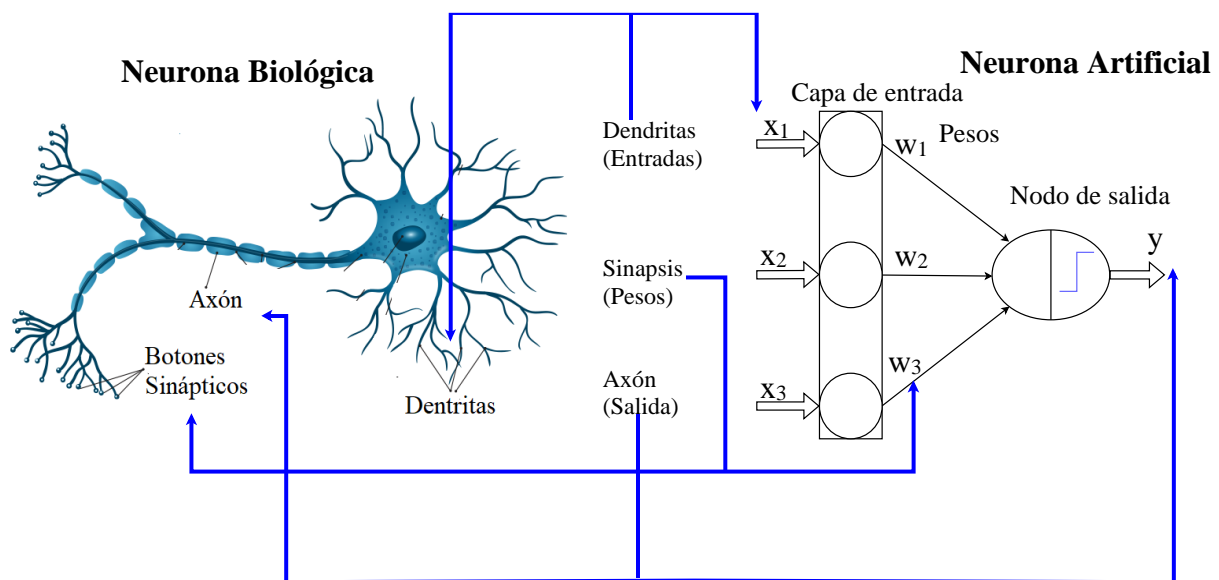
& Jäschke, 2020). La capacidad de un modelo de producir predicciones precisas sobre nuevos datos, se denomina generalización del modelo.

3 Redes neuronales artificiales

Las redes neuronales artificiales (Michie et al., 1994) son una técnica de aprendizaje automático que simulan el mecanismo de experiencia en organismos biológicos. El mecanismo biológico se simula artificialmente en unidades de computación que se denominan neuronas, dicho mecanismo es presentado en la Figura 3.

Figura 3

Comparación neurona biológica frente a neurona artificial



Para generalizar la comparación que se presenta la Figura 3 entre las redes neuronales biológicas y las redes neuronales artificiales, se parte del concepto de que las unidades de cómputo están conectadas entre sí a partir del procesamiento matemático interno, en el que se integran sumatorias que funcionan de la misma forma que las conexiones sinápticas en los organismos biológicos [13]. Una red neuronal artificial inicia calculando una función con las entradas puestas propagando los valores calculados desde las neuronas de entrada a las neuronas de salida y

utilizando los pesos como parámetros intermedios, dicha función es denominada regresión logística. El concepto que envuelve en primera medida el desempeño de la red neuronal artificial, se integra en la actualización de pesos sinápticos, dado que es a partir de sus valores que se inicializa el proceso predictivo.

4 Preprocesamiento de datos

Los datos empleados para el desarrollo de este trabajo fueron recopilados por (Mauricio Ruiz Diaz et al., 2021), agrupando información característica de flujo bifásico de aceite y agua en tubería vertical, para la cual fueron analizados los trabajos desarrollados por 18 autores de la literatura. En la Tabla 1 se presenta la información contenida en la base de datos, resumiendo características cuantitativas propias de cada trabajo analizado.

Tabla 1

Resumen base de datos recopilada

Autor	D [m]	μ_o [Pa.s]	ρ_o [Kg/m³]	N°. patrones de flujo	N°. de datos
(Bannwart et al., 2004)	0,0284	0,488	925	3	392
(Abduvayt et al., 2004)	0,1064	0,00188	800	6	49
(Du et al., 2012)	0,02	0,011	856	3	101
(Flores et al., 1998)	0,05	0,02	850	5	126
(Ganat et al., 2019)	0,04	0,035	860	4	92
(G. W. Govier, G. A. Sullivan, 1961)	0,0263	0,0201	851	2	15
(Han et al., 2017)	0,02	0,125	801	4	175
(Hasan & Kabir, 1988)	0,127	0,001	801	2	9
(Hasan & Kabir, 1999)	0,027	0,02	801	4	109
(Jana et al., 2006)	0,0254	0,001	792	4	55
(Jana et al., 2007)	0,0254	0,001	792	5	32
(Jixiang Guo et al., 2019)	0,01	0,287	1823	3	1421
(Mazza & Suguimoto, 2020)	0,026	0,0011	793	5	90
(Mydlarz-Gabryk et al., 2014)	0,03	0,03	856	4	252
(Rodriguez & Bannwart, 2006)	0,0284	0,5	930	1	92
(Xu et al., 2010)	0,03	0,044	860	4	98

(Yang et al., 2019a)	0,02	0,09732	857	7	1699
(Zhao et al., 2006)	0,04	0,0041	824	1	57

Las variables recopiladas en los diferentes estudios son las velocidades superficiales de la fase de agua (J_w) y aceite (J_o). Estas se basan en los caudales de inyección y en el área de sección transversal de la tubería, en la velocidad de la mezcla J y en las fracciones volumétricas de los fluidos aceite-agua (ε_o y ε_w) que caracterizan al flujo. Otros aspectos importantes incluidos en la recopilación de datos para caracterizar el fluido son la viscosidad del aceite (μ_o), densidad del aceite (ρ_o) y el diámetro interno de la tubería (D). Con estos datos puntuales se generan configuraciones geométricas específicas para cada combinación de parámetros, que de manera concreta se agrupan para este trabajo en 10 patrones de flujo, los cuales son los datos de salida del modelo inteligente a desarrollar. En la Tabla 2 se presenta la cantidad específica de datos que se tiene para cada patrón de flujo.

Tabla 2

Cuantificación de datos para cada patrón de flujo

Tipo de Patrón de Flujo	D O/W	D W/O	Churn O/W	Churn W/O	Coreflow	S O/W	S W/O	TF	VFD O/W	VFD W/O
Cantidad de datos	947	1292	21	127	481	460	657	315	366	205
% del Total	19%	27%	0.40%	3%	10%	9%	13%	6%	8%	4%

4.1 Normalización

Para hacer el entrenamiento de la red es importante homogenizar la información que se utilizará como entradas del modelo inteligente, entregándole a la red datos claros que permitan relacionar las variables suministradas con el patrón a predecir. La normalización se define como un cambio de escala de los datos originales para que estos estén en un rango específico (Brownlee

Disclaimer, 2017). Se normaliza el vector de entrada de la red, este contiene $x = [j_o, j_w, j, \varepsilon_o, \varepsilon_w, D, \mu_o]$. Como los rangos de los datos varían, se usa la normalización para poder homogenizar estos. La ecuación (1) presenta la definición matemática empleada para normalizar cualquier tipo de información numérica.

$$X_{normalizada} = \frac{x - X_{mínima}}{X_{máxima} - X_{mínima}} \quad (1)$$

La variable $X_{máxima}$ representa el valor máximo de la serie en estudio, a su vez $X_{mínima}$ representa el valor mínimo de la serie, x corresponde al valor puntal a normalizar. Con esto se obtiene el resultado de $X_{normalizada}$

4.2 Codificación

Teniendo en cuenta que el patrón de flujo se define en la base de datos como una variable categórica, es necesario codificar la etiqueta que se tiene en las diferentes configuraciones (10). Para llevar a cabo dicha codificación, se asigna un número del 0 al 9, correspondiente a cada uno de los patrones de flujo definidos. Se tienen diferentes etiquetas de datos, por lo tanto, la simple codificación no es suficiente. En este caso, la codificación se lleva a cabo con la función OneHotEncoder, la cual elimina la variable codificada de forma entera y se agrega una variable binaria para cada valor entero único. En la Figura 4 se presenta el resultado de la codificación de los 10 patrones de flujo con su respectiva representación binaria.

Figura 4*Codificación OneHotEncoder*


ID	Patron de flujo
0	D O/W
1	D w/O
2	Chum o/w
3	Chum W/O
4	Coreflow
5	S o/w
6	S W/O
7	TF
8	VFD O/W
9	VFD W/O

OneHotEncoder

ID	D O/W	D w/O	Churn o/w	Churn w/o	Coreflow	S o/w	S W/O	TF	VFD O/W	VFD W/O
0	1	0	0	0	0	0	0	0	0	0
1	0	1	0	0	0	0	0	0	0	0
2	0	0	1	0	0	0	0	0	0	0
3	0	0	0	1	0	0	0	0	0	0
4	0	0	0	0	1	0	0	0	0	0
5	0	0	0	0	0	1	0	0	0	0
6	0	0	0	0	0	0	1	0	0	0
7	0	0	0	0	0	0	0	1	0	0
8	0	0	0	0	0	0	0	0	1	0
9	0	0	0	0	0	0	0	0	0	1

5 Estructuración del modelo LSTM

Las Redes neuronales recurrentes o RNN, por sus siglas en inglés, integran arquitecturas que son inherentemente diseñadas para datos multidimensionales en las que los atributos son en gran medida independientes entre sí. También existen casos donde los datos son dependientes de atributos antecesores, esto se puede ejemplificar en la lectura de una oración, palabras presentadas al inicio de una oración se relacionen con palabras mostradas mucho después, para al finar dar sentido al texto. En la Figura 5 se presenta la estructura general de una red neuronal recurrente.

Figura 5*Red neuronal recurrente*


Las RNN se caracterizan por tomar tanto las salidas de cada nodo de entrada actual, como lo que ha entrenado previamente para su aprendizaje respecto a las entradas anteriores. A diferencia de las redes neuronales convencionales, que siguen un avance direccional de la capa de entrada hacia las capas de salida sin retornar información previa. Se aplican aleatoriamente los pesos a la capa actual, así como a la entrada anterior y ajusta su peso tanto para el descenso del gradiente como para el Backpropagation a lo largo del tiempo (BPTT). Las conexiones recurrentes agregan estado o memoria a la red y le permiten aprender y aprovechar la naturaleza ordenada de las observaciones dentro de las secuencias de entrada.

La red neuronal de memoria de corto/largo plazo o LSTM es una extensión de red neuronal recurrente o RNN (Kanagachidambaresann, 2021). La Figura 6 presenta una comparativa de las dos redes, donde se evidencia que la red LSTM presenta un concepto de celda de memoria. Dicha celda es la que permite quitar las limitaciones que se tiene con las RNN, cuya mayor dificultad en el desarrollo de RNN es su poca memoria a la hora de comparar datos.

La celda de memoria funciona como válvula para implementar el estado oculto anterior en las diferentes capas cuando este sea necesario, con esto se logra que la red neuronal tenga una propagación de estados y que la función de activación tenga poca influencia en la anidación de dichas funciones. Con esto se genera una red robusta que almacena los datos y los suministra según sea la necesidad.

Figura 6

(a) Red neuronal recurrente (b) LSTM



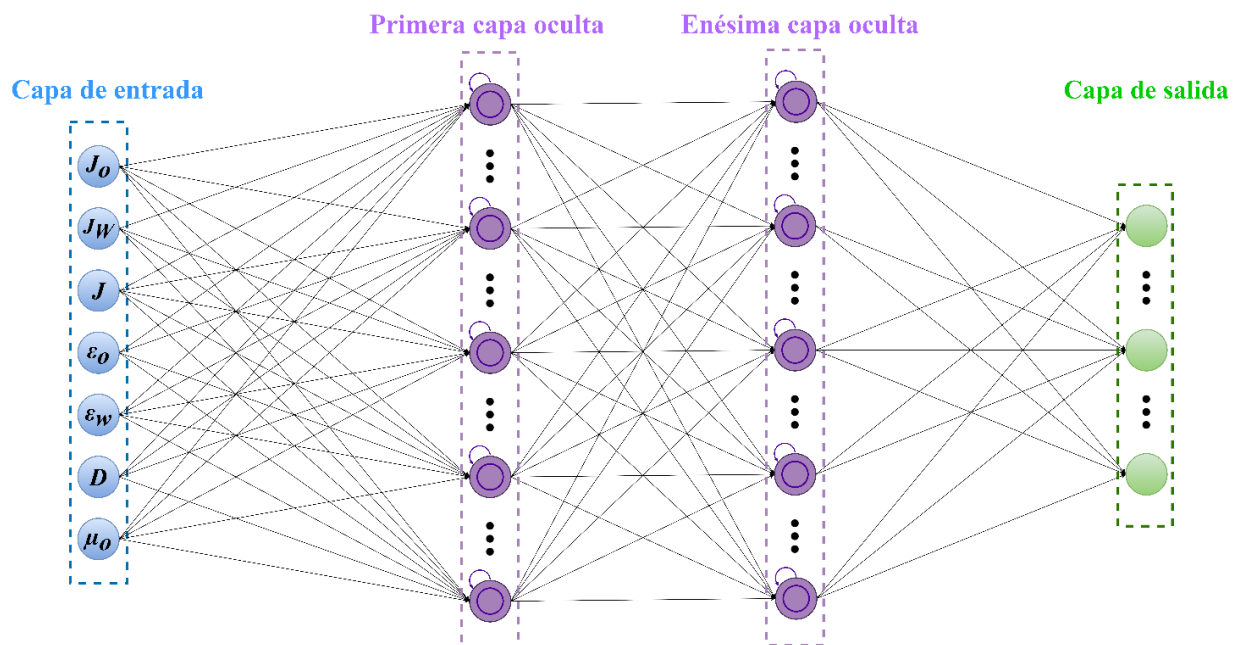
En los siguientes capítulos se medirá su desempeño para diferentes configuraciones, para este trabajo se desarrollaron 4 diferentes modelos.

5.1 Arquitectura de LSTM

Con la totalidad de la información procesada, se procede con la definición de la estructura interna de la LSTM a desarrollar. Un esquema general de la estructura de este tipo de redes neuronales se presenta en la Figura 7, asimismo, es presentado el vector con los parámetros de entrada que serán utilizados para generar las predicciones.

Figura 7

Estructura general de una LSTM



En la Figura 7 se presenta cómo la primera capa oculta en la red debe definir el número de entradas que se esperan. El vector de entrada es tridimensional y está compuesto por muestras, pasos del tiempo y características. Los pasos del tiempo son las observaciones pasadas de una característica, variables de retraso.

Una vez definido el vector con los parámetros de entrada se define la clase, que será la salida del modelo predictivo. En este caso, se ha asignado a dicha salida el patrón de flujo desarrollado al interior de las tuberías verticales.

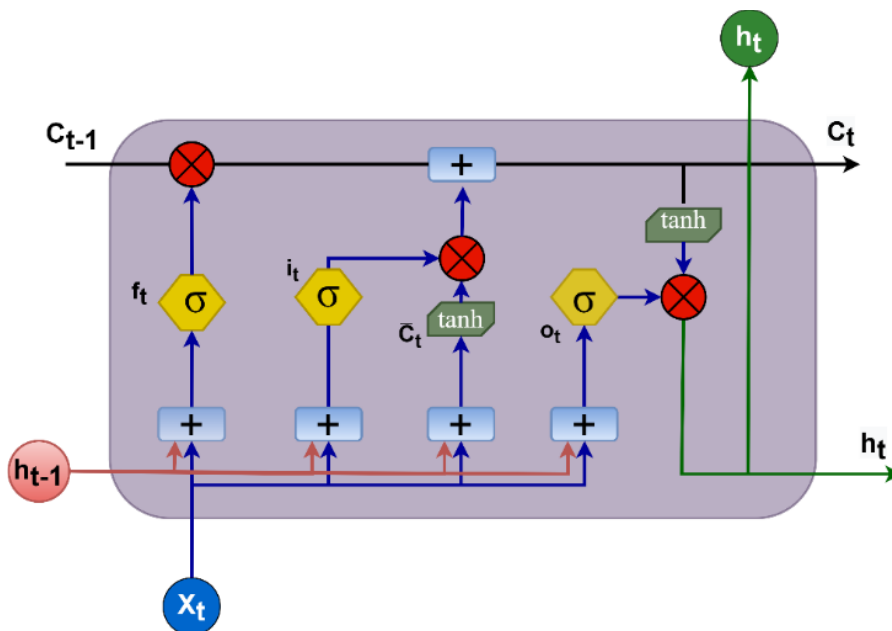
La definición del tamaño de la LSTM se definió a partir de un proceso iterativo ordenado, en el que se realizaron variaciones en el número de capas ocultas y a la cantidad de neuronas que las integran. Analizando en rendimiento con los valores presentados por la función de pérdida, tal como se detalla en la metodología.

5.2 Celda de estado

El funcionamiento de una LSTM se genera a partir del proceso interno que se desarrolla en las celdas de estado, en las cuales se integran funciones de activación para procesar la información nueva y la información procedente de procesamientos previos desarrollados en celdas de estado anteriores. El esquema general de una celda de estado es presentado en la Figura 8.

Figura 8

Celda de estado LSTM.



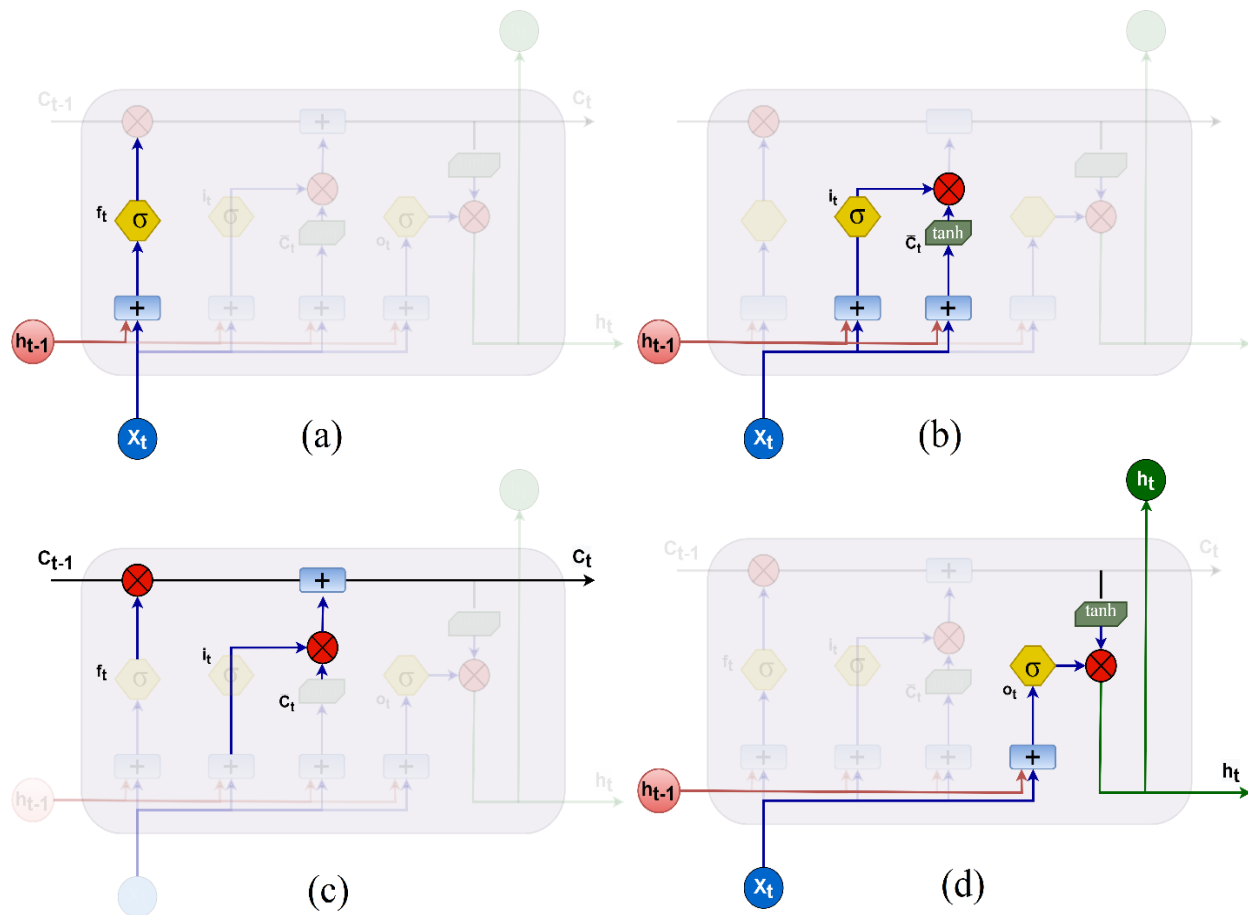
Las LSTM poseen la capacidad de capacidad de eliminar o agregar información a la celda de estado, gracias a las puertas lógicas que tiene integradas en la entrada y en la salida de cada celda. Las funciones sigmoideas representadas con color amarillo al interior de la celda de estado

generan valores entre cero y uno, los cuales están relacionados con la información que será agregada o depurada en la siguiente celda, ya que un valor 0 significa que la información no seguirá adelante en procesamiento interno de la misma y por el contrario el valor de 1 tiene en cuenta toda la información procesada.

La Figura 9 presenta un esquema de la secuencia lógica que sigue una celda de estado internamente. Ocurren varios pasos antes de obtener un estado oculto o una salida de la celda que implican múltiples transformaciones de los datos.

Figura 9

Secuencia lógica desarrollada al interior de la celda de estado LSTM. (a) primer orden lógico, (b) segundo orden lógico, (c) tercer orden lógico, (d) finalización de la secuencia



La secuencia lógica desarrollada al interior de las celdas LSTM permite detallar el orden en el cual se genera el procesamiento de la información que pasa por ella. Así, la Figura 9 (a) presenta un filtro de que información se conserva y cual se desecha en la celda de estado, esta operación se realiza gracias a la capa sigmoidea (σ) conocida como “puerta de olvido”. Dicha puerta analiza h_{t-1} y X_t , los cuales corresponden respectivamente a la entrada actual y a la salida del estado anterior, genera un número entre 0 y 1 para cada número en el estado de la celda C_{t-1} , así, cuando la función genera un 1, guarda esta información, mientras que cuando genera un valor de 0, omite del procesamiento la información tratada. El modelo matemático de dicha estructuración es presentado en la ecuación (2).

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (2)$$

En la Figura 9 (b), la red neuronal selecciona la información que será almacenada en la celda de estado. Dicho procesamiento se realiza en dos partes, en la primera una capa sigmoidea selecciona los valores que serán actualizados y la segunda parte utiliza una capa con la función tangente hiperbólica (\tanh) para crear un nuevo vector con los valores candidatos C_t , de los cuales algunos serán agregados a la celda de estado. Dicha secuencia es sintetizada en las ecuaciones (3),(4)

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (3)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (4)$$

La Figura 9 (c) muestra como después de seleccionada la información que se incluirá en la celda de estado, se procede a actualizarla. C_{t-1} que es el estado anterior se convierte en \tilde{C}_t , para

esto se multiplica el estado anterior por F_t , posterior a esto se agrega $i_t * C_t$. Con esto se tiene la ecuación (5)

$$C_t = f_t * C_{t-1} + i_t * \check{C}_t \quad (5)$$

Finalmente, en la Figura 9 (d) se selecciona el valor que continuará el proceso hacia las celdas superiores. Esta salida se basa en el estado de la celda, se ejecuta una capa sigmoidea que decide qué partes del estado de la celda se genera. Posteriormente, el estado de la celda es procesado con una función \tanh que convierte a los valores a un rango entre -1 y 1, esto se multiplica por la salida de la puerta sigmoidea, de modo que solo se endosen las partes que se seleccionaron, generando las ecuaciones (6),(7)

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (6)$$

$$h_t = o_t * \tanh (C_t) \quad (7)$$

5.3 Funciones de activación

En la solución de problemas empleando redes neuronales, las funciones objetivo tienden a la no linealidad, se tiene que la naturaleza de las neuronas artificiales es una regresión logística, que da como resultado una función lineal.

$$P = \frac{1}{1 + e^{-y}} \quad (8)$$

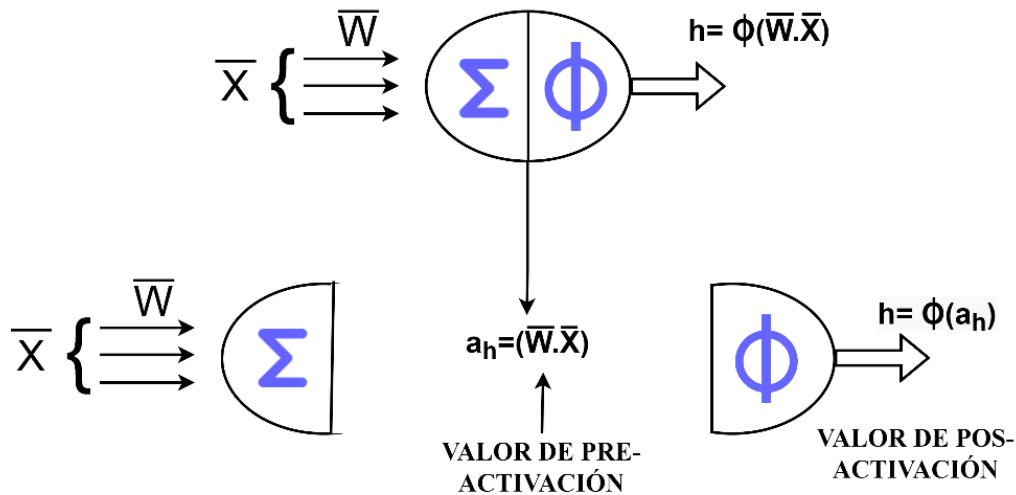
$$y = a_1x_1 + \dots + a_nx_n \quad (9)$$

La ecuación (8) muestra la función de la regresión logística que es una función discreta binaria, por otra parte, la ecuación (9) representa una función lineal. Si se agrupan varias neuronas

en múltiples capas, la red se convierte en una super neurona, cuyo objetivo final es una función lineal. De esta forma, se implementan las funciones de activación para redes neuronales lo cual genera la no linealidad en la función objetivo. Para desarrollar el proceso de aprendizaje, las redes neuronales utilizan funciones de activación que no son lineales (Chandriah & Naraganahalli, 2021). En la Figura 10 se presenta el proceso que sigue la información a ser tratada con la función de activación seleccionada.

Figura 10

Neurona con función de activación

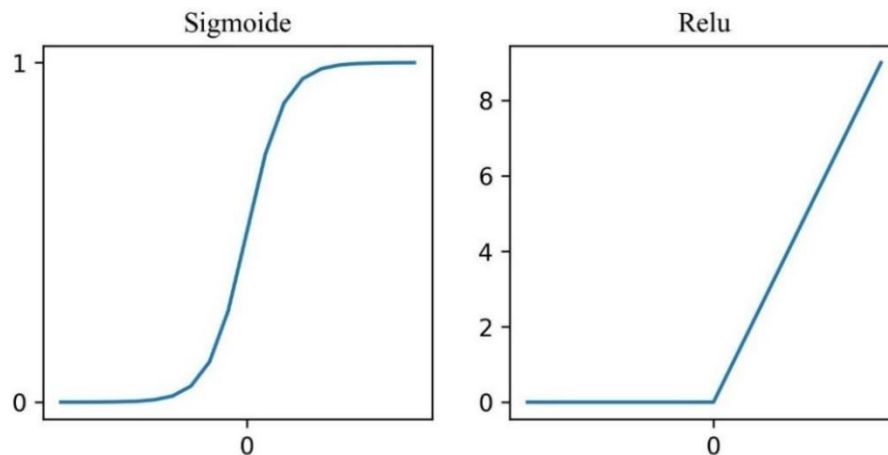


En el trabajo desarrollado por (Aggarwal, 2018) la elección de la función de activación es una parte crítica del diseño de redes neuronales. En este sentido, en las configuraciones planteadas en este estudio, se implementa la función de activación del sigmoide, al ser necesario predecir una

etiqueta de clase binaria. La Figura 11 presenta las dos funciones de activación implementadas en las configuraciones del modelo. Su desempeño varía según los ajustes de sus parámetros.

Figura 11

Funciones de activación implementadas



5.4 Funciones de error

La Función de pérdida es fundamental para estimar en primera medida el rendimiento del modelo inteligente. A continuación, se presentan los parámetros estadísticos utilizados en la determinación del rendimiento y precisión del modelo estructurado.

- **Error cuadrático medio (MSE)**

El error cuadrático medio (*mean squared error*) es una métrica de evaluación de modelos desarrollados con variables numéricas. El MSE se utiliza en modelos de regresión debido a su utilidad en valores inesperados que tiene gran importancia. El MSE calculado de un modelo con respecto a un conjunto de pruebas, es la media de los errores de predicción al cuadrado en todas las instancias del conjunto de pruebas. El error de predicción es la diferencia entre el valor verdadero y el valor predicho para una instancia (Geoffrey I. Webb & Claude, 2017). La ecuación (10) representa la función de MSE.

$$mse = \frac{\sum_{i=1}^n (y_i - \lambda(x_i))^2}{n} \quad (10)$$

Donde y_i es el valor objetivo para la instancia de prueba x_i , $\lambda(x_i)$ es el valor objetivo previsto para la instancia de prueba x_i y n es número de instancias de prueba.

- **Entropía cruzada (Cross Entropy)**

La entropía cruzada es una medida de la diferencia entre dos distribuciones de probabilidad para una variable aleatoria dado un conjunto de eventos. Este tipo de función de pérdida implementa la regresión logística multinomial (Calin, 2020). Concretamente, se apoya en la idea de la entropía de la teoría de la información y calcula la cantidad promedio de bits necesarios para representar o transmitir un evento de una distribución en comparación con la otra distribución. Si se considera una distribución de probabilidad objetivo o subyacente P y una aproximación de la distribución objetivo Q , entonces la entropía cruzada de Q en P es el número de bits adicionales para representar un evento usando Q en lugar de P (Brownlee, 2020). Se puede representar la entropía cruzada con la ecuación (11)

$$H(P, Q) \quad (11)$$

Donde H es la función de entropía cruzada, P es la distribución objetivo y Q es la aproximación de la distribución objetivo y la entropía cruzada se calcula usando probabilidades de los eventos de P y Q , como se muestra en la ecuación (12)

$$H(P, Q) = - \sum_{\{x \in X\}} P(x) \times \log(Q(x)) \quad (12)$$

Donde $P(x)$ es la probabilidad del evento x en P , $Q(x)$ es la probabilidad del evento x en Q y $\log()$ es el logaritmo en base 2, lo que significa que los resultados están en bits. Si se tiene una base diferente en el logaritmo como es base e , $\ln()$, el resultado tendrá unidades llamadas NATS. Este cálculo es para distribuciones de probabilidad discretas.

5.5 Parámetros de optimización

Se estructuran diferentes configuraciones variando parámetros de la composición de la red neuronal, como lo son el número de celdas por capa, el número de capas ocultas apiladas, la función de activación del modelo y la función de pérdida. Todos estos ajustes se realizan usando lenguaje de código abierto. Los datos para cada tipo de configuración se presentan en la Tabla 3.

Tabla 3

Configuraciones de LSTM

Algoritmos	Hiperparámetro	Selección	Otros	Selección
Red LSTM 1	Ratio de aprendizaje	0.001	Función de activación	Sigmoide
	Número de capas ocultas	2	Función de pérdida	Entropía cruzada categórica
	Número de celdas por capa	80	optimizador	Adam
	Tamaño de lote	128	épocas	300
Red LSTM 2	Ratio de aprendizaje	0.001	Función de activación	Sigmoide
	Número de capas ocultas	2	Función de pérdida	Entropía cruzada categórica
	Número de celdas por capa	30	optimizador	Adam
	Tamaño de lote	32	épocas	300
Red LSTM 3	Ratio de aprendizaje	0.001	Función de activación	Sigmoide
	Número de capas ocultas	3	Función de pérdida	Entropía cruzada categórica

Red LSTM 4	Número de celdas por capa	30	optimizador	Adam
	Tamaño de lote	128	épocas	300
	Ratio de aprendizaje	0.001	Función de activación	Relu
	Número de capas ocultas	2	Función de pérdida	MSE
	Número de celdas por capa	80	Optimizador	Adam
	Tamaño de lote	1	Épocas	300

Se plantea la elaboración de un modelo del tipo “muchos a uno”. Este modelo significa que con varias características se predice una sola salida. El vector de entrada del modelo inteligente tiene 7 pasos de tiempo, estos representan una característica que sería la salida de la red neuronal y a su vez esta representa el patrón de flujo en ese instante. La elección de la función de activación es más importante para la capa de salida, ya que esta define el formato que tomaran las predicciones. En la Tabla 3 se presenta las diferentes configuraciones de las redes LSTM. La estructura de la red LSTM 4, en la cual se implementa la función MSE, esto por su particularidad de tener una única codificación y no tener una salida de forma binaria.

Siguiendo la fase de estructuración y desarrollo del modelo predictivo, se hace énfasis en su compilación teniendo en cuenta todos los parámetros seleccionados para llevar a cabo el entrenamiento de la red. En la red LSTM 3 se tiene el caso de compilación de un modelo especificando Adam como optimizador y entropía cruzada categórica como función de pérdida, implementados para obtener un mayor rendimiento en la clasificación de la serie teniendo en cuenta el tipo de información que se está utilizando.

Una vez desarrollado el proceso de compilación, el modelo entrenado debe ser ajustado. Esto se concreta llevando a cabo una actualización de los pesos para cada parámetro incluido en el conjunto de entrenamiento, teniendo en cuenta que en cada uno de ellos se integran estados de celdas anteriores. Todas las estructuraciones de LSTM fueron entrenadas con el 80% de los datos

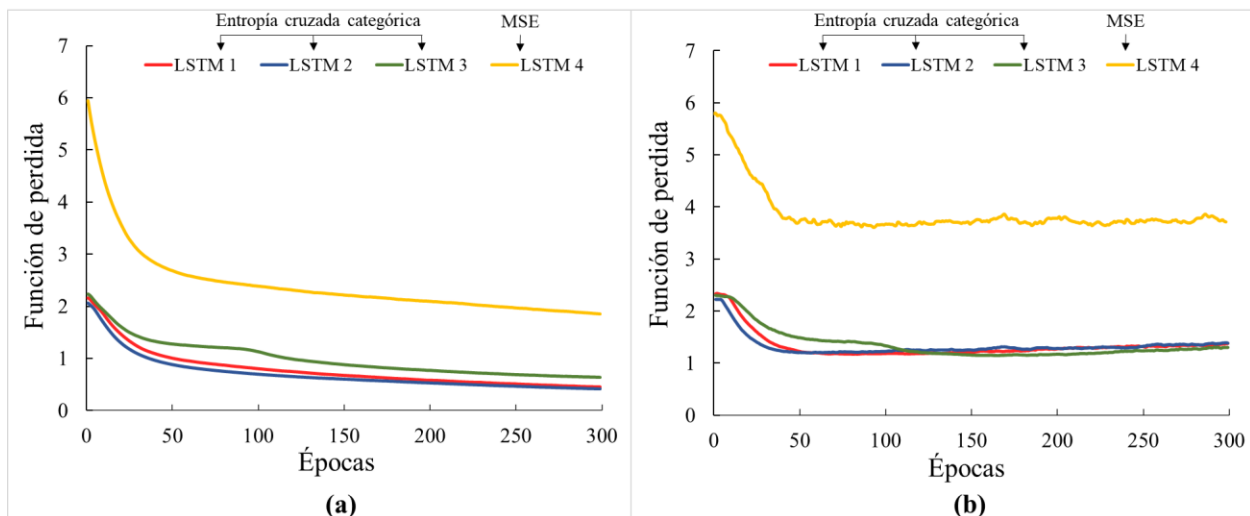
recopilados. En la evaluación del modelo se destinan el 20% restante de los datos, en esta se verifica el resultado en cada una de las métricas especificadas al momento de compilar el modelo. Se requiere que la red entrene para un número específico de épocas o exposiciones a todas las secuencias del conjunto de datos de entrenamiento, para ello, cada época se puede dividir en grupos de pares de patrones de entrada-salida llamados tamaño de lote. Este parámetro define la cantidad de patrones a los que está expuesta la red antes de que los pesos se actualicen dentro de una época; si la actualización se realizara de manera constante actualizando los pesos con el paso de cada dato ocurrirá una saturación de la entrada en la memoria.

6 Evaluación del modelo

Para definir el modelo con el mejor rendimiento se realiza un análisis gráfico, teniendo en cuenta los valores obtenidos por cada modelo tanto en la fase de entrenamiento como en la fase de validación, en las cuales se tiene en cuenta 300 épocas. Este desarrollo gráfico de la función de pérdida es presentado en la Figura 12.

Figura 12


Evaluación de modelos con respecto a función de pérdida, (a) Fase de entrenamiento, (b) Fase de validación



Al evaluar el desempeño de las diferentes configuraciones, se evidencia que en el entrenamiento la red LSTM 1 tiende a decrecer el error más rápido que los otros modelos, esta es la configuración óptima para predecir los patrones de flujos. En la Figura 12 (a) se presenta el desempeño frente al error en cada uno de los 4 modelos para los datos de entrenamiento. La red LSTM 1 se selecciona frente a las demás debido al desempeño mostrado en su fase de validación siendo el modelo con el error más bajo en esta fase, por otra parte, el modelo LSTM 4 implementa una ecuación de pérdida diferente a las demás, empieza su entrenamiento con un error considerable y tarda más en decrecer. Esto se debe a las características de la función de pérdida, la cual no clasifica binariamente los patrones de flujo esperados, sino que los trata como una codificación de número entero, al compararse con el esperado crea una discrepancia en la salida de la red. En la Figura 12 (b) se presenta el desempeño de las redes con los datos de validación, esta sección detalla el comportamiento de las redes frente a problemas con datos desconocidos, se tiene que el error fluctúa frente al obtenido en el entrenamiento. Los valores tienden a converger si la función de error es la misma, al momento de probar con la función MSE presenta un error superior al 2%, con esto se evidencia que es el modelo con el desempeño más bajo.

Figura 13

Evaluación de la precisión de los modelos, (a) Fase de entrenamiento, (b) Fase de validación



La Figura 13 (a) presenta las curvas de tendencia generadas con los valores obtenidos para cada modelo en la etapa de entrenamiento. Los modelos LSTM 1,2,3 tienden a aumentar su precisión, solo el modelo LSTM 4 el cual tiene una función de error diferente, presenta un comportamiento lineal estancándose en una precisión menor al 0.1 en su resultado. Dicho comportamiento se debe a la complejidad de la predicción, esta complejidad viene dada por la necesidad de predecir 1 patrón de flujo dentro de 10 diferentes tipos. Con la codificación OneHotEncoder se obtiene mejor desempeño que con la codificación normal, el mejor desempeño se debe a que OneHotEncoder codifica de forma binaria los datos. Se necesita tener mayor cantidad de datos para poder aumentar la precisión de la red. La Tabla 2 muestra como un determinado patrón de flujo representa menos del 1% en el total de datos, esto puede incurrir en un sobre ajuste de la red (Overfitting), lo que causa que el modelo recuerde los datos suministrados, pero sea impreciso con datos de evaluación del modelo.

El ajuste del número de épocas tiende a ser indiferente si se prolonga en el tiempo, esto debido a que tiene una tendencia convergente. Para probar la generación de mapas de flujo se toma

el modelo LSTM 1, dicha elección se debe a que el error obtenido en este modelo es menor al 1% y a su vez la precisión crece exponencialmente con el pasar de las épocas quedando en un valor cercano al 0.9 en su entrenamiento. En este modelo se parametrizan los datos suministrados, para ver el comportamiento del modelo.

7 Resultados

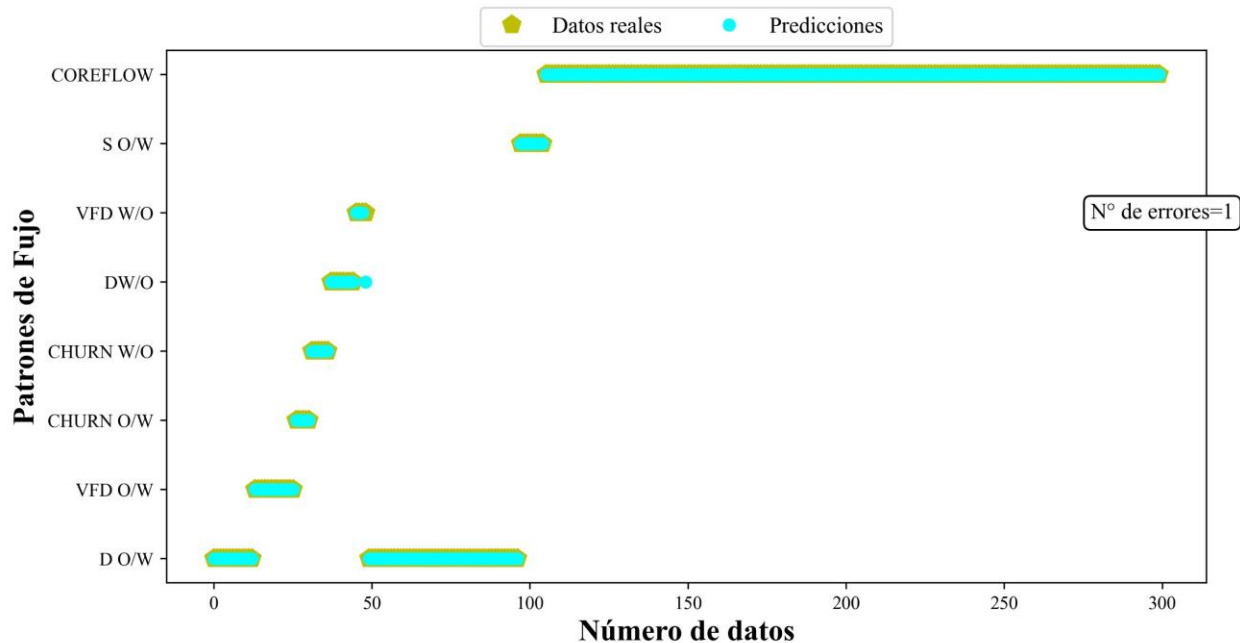
Esta sección presenta como el modelo LSTM 1 se desempeña frente a la predicción de patrones de flujo y se verifica el error visto en la sección anterior. Con esto, se presentan los diferentes mapas de flujo generados por la red LSTM 1 con datos de autores.

Una vez seleccionado el modelo con mayor desempeño, en este caso LSTM 1, se prueba frente a la generación de mapas de flujo. Para esto se suministran 300 conjuntos de datos en el vector de entrada, la Figura 14 presenta la cantidad de veces que el modelo predice correctamente el patrón de flujo, cada pentágono corresponde al patrón de flujo para los datos suministrados y el círculo se refiere a las predicciones que genera la red con los mismos datos. Se evidencia que el error obtenido es de 0.3%, esto concuerda con los resultados vistos en Figura 12 (a). La función de pérdida con la que se está evaluando el modelo genera un excelente desempeño en la clasificación, el cual indica que el modelo se aproxima al real, en este caso el número de coincidencias es 1, lo esperado es que si se aumenta la data el error crezca hasta alcanzar 0.8% cuando estén representados los datos totales. Se tiene que los datos suministrados para la generación de esta gráfica contienen únicamente 8 de los 10 patrones de flujo, pero representa una muestra significativa debido a la cantidad de datos tomados, donde el modelo predijo un patrón que no era el correcto para esa data. Se tiene que su predicción no generó patrones adicionales a los 8 presentes en el rango, para los datos puntuales del vector de entrada $x =$

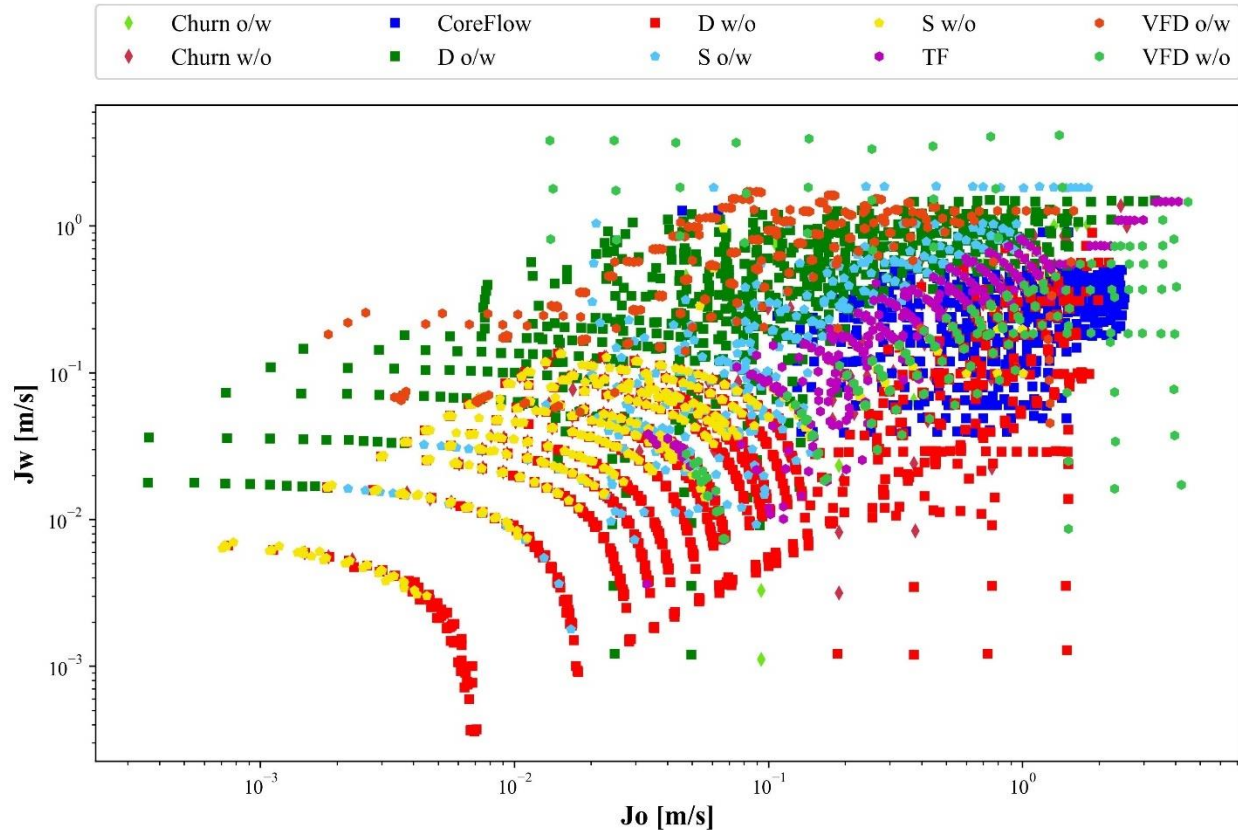
$[j_o, j_w, j, \varepsilon_o, \varepsilon_w, D, \mu_o]$ predijo un patrón D W/O y su esperado era VFD W/O, esto está dentro de los márgenes esperados por el error.

Figura 14


Evaluación del algoritmo seleccionado, LSTM 1



El mapa de flujo generado con el conjunto completo de datos es presentado en la Figura 15, esta grafica el patrón de flujo determinado por los diferentes autores dependiendo de J_w y J_o . Dicho esquema es estructurado bajo escala logarítmica, ya que permite identificar que la disminución en las magnitudes de las velocidades del agua y el aceite genera la formación de patrón de flujo de S w/o y D w/o. La Figura 15 permite identificar también, que el aumento en la magnitud de las velocidades J_w y J_o genera la formación de diferentes tipos de patrón de flujo, en la cual se evidencia que el patrón de flujo S O/W presenta puntos superpuestos, estos representan la influencia de las demás variables en la conformación de un patrón de flujo, como lo es su diámetro interno y viscosidad del aceite.

Figura 15*Mapa de flujo con datos de autores*


En la Figura 16 se presentan los patrones de flujo obtenidos al implementar la red LSTM 1, haciendo uso de toda la información contenida en la base de datos. Las diferencias desarrolladas entre los esquemas presentados en las Figura 15 y 16 se visualiza en la región del mapa de flujo en el cual se presenta la transición entre patrones de flujo, generada cuando la velocidad de aceite es alta y la de agua es baja. Los rangos de magnitud de las velocidades superficiales de las sustancias son: 0.01-1 m/s para J_w y de 0.1-1 m/s para J_o .

Figura 16*Mapa de flujo genera a partir de red LSTM 1*

También, fueron desarrollados 2 mapas de flujo teniendo en cuenta la información de cada autor correspondiente. La Figura 17 presenta el mapa de flujo estructurado con la información presentada por [26], en la cual se identifican 5 patrones de flujo (CoreFlow, D o/w, D w/o, TF, VFD o/w) y un total de 125 datos. Asimismo, se presenta la zona de separación entre los patrones de flujo D w/o y D o/w. Teniendo en cuenta las magnitudes de las velocidades desarrolladas por las sustancias, se presenta un 60% de puntos del patrón de flujo D o/w. Por otro lado, el patrón de flujo Coreflow se presenta en la zona de velocidades superficiales elevadas para el agua y bajas para el aceite.

Figura 17


Mapa de flujo con datos de (Flores et al., 1998)



Llevando a cabo el proceso de implementación de la red LSTM 1, se obtiene el mapa de flujo presentado en la Figura 18. Su rendimiento es muy bajo en la zona de transición del fluido, presenta múltiples errores en la predicción y genera patrones que no son los establecidos en esa zona. En este caso se tiene un acierto en la predicción de 9 de 18, esto se debe al comportamiento que tiene el fluido en esta área; la transición implica el cambio del fluido dominante y los diferentes autores tienen una cantidad de información reducida en dicha zona debido a su comportamiento caótico del cual no se puede tener control absoluto. Asimismo, se detalla que la red LSTM 1 predice de manera precisa los patrones de flujo desarrollados en las demás zonas del mapa de flujo.

Figura 18


Carta de flujo generada para (Flores et al., 1998), aplicando el modelo LSTM 1



Asimismo, se presenta la Figura 19, en la cual se esquematiza el mapa de flujo desarrollado con la información de (Mydlarz-Gabryk et al., 2014) en la cual se presenta una cantidad superior de puntos en la zona de transición de patrón de flujo 38 para 252 y a su vez presenta menos patrones de flujo (D o/w, D w/o, S o/w, TF). Con dicha información, se evalúa el algoritmo LSTM 1 y se determinó la cantidad de patrones de flujo predichos que se localizan fuera de los límites reales creados por la información de dicho autor.

Figura 19

Mapa de flujo con datos de (Mydlarz-Gabryk et al., 2014)




La Figura 20 muestra los resultados obtenidos al procesar los datos con la red LSTM 1, en la cual se identifican 31 patrones correctos de los 38 esperados, mostrando un mejor desempeño frente a la carta de flujo generada en la Figura 18. Genera VFD o/w esto corresponde a un patrón intermedio delimitado por TF y D w/o, comportamiento acertado de la red. A su vez, muestra que solo se generan 2 patrones fuera del rango delimitado por los datos del autor, en este caso los patrones son los patrones VFD o/w y VFD w/o. También, en el rango de velocidades de 0.01 a 0.1 m/s para J_w y de 0.09 a 0.1 m/s para J_o , se presenta el patrón de flujo S o/w, para el cual las predicciones desarrolladas por la red implementada presentan una precisión elevada cuando las velocidades superficiales de inyección de agua y aceite son bajas, mostrando únicamente 1 error de 52 predicciones en esta área. A partir de este análisis, se identifica que el incremento en la

velocidad de inyección del aceite genera el desplazamiento de la zona, hasta las proximidades de la zona de transición, en la cual se genera nuevamente imprecisión en los patrones de flujo obtenidos con la implementación del modelo LSTM 1.

Figura 20

Carta de flujo generada, a partir de los datos de (Mydlarz-Gabryk et al., 2014)



El resto de las figuras generadas para cada autor se encuentran en los apéndices.

8 Conclusiones

En este estudio se estructuraron diferentes modelos de LSTM para la predicción de series de datos, dichas series contienen como vector de entrada características del fluido bifásico líquido-líquido aceite y agua, dichas características son las velocidades de inyección de agua y aceite, fracciones volumétricas de agua y aceite, viscosidad del aceite y el diámetro interno de la tubería

por donde circulan, esto para determinar el patrón de flujo presente en determinado valor de cada una de las características. Se plantean 4 diferentes configuraciones para la red LSTM, una vez compilada y entrenada cada red, se mide el error que tiene frente a las predicciones esperadas, con esto se obtienen errores en el modelo, con un 0.98% para LSMT 1, 1.2% para LSTM 2, 1.4% para LSTM 3 y 3.5% para LSTM 4, de los cuales, los mejores resultados fueron obtenidos con la red LSTM 1. La cual fue configurada con dos capas ocultas, 80 celdas de memoria en cada capa oculta y la entropía cruzada categórica como función de pérdida, logrando un error menor al 1% en la predicción de patrones de flujo en una tubería vertical.

Se concluye que el bajo desempeño del modelo LSTM 1 desarrollado se genera en las zonas de transición, debido a la poca cantidad de datos disponibles en esta zona, también se demostró que el desempeño de los modelos mejora drásticamente al suministrar grandes cantidades de datos, pasando de 50% de precisión a 83% de precisión. Esto muestra como mejora considerablemente la precisión al suministrar más datos para el entrenamiento de la red en esta zona.

En este trabajo se demostró que, a partir de velocidades de inyección, fracciones volumétricas, diámetro y viscosidad, se pueden desarrollar modelos basados en la predicción de series temporales a partir de la implementación de LSTM con el fin de determinar los patrones de flujo bifásico líquido-líquido de aceite y agua en tubería vertical. Trabajos futuros incluyen el estudio del comportamiento de la red frente a datos suministrados por plataformas off-shore y el uso de motores físicos para la obtención de muestras.

9 Referencias Bibliográficas

- Abduvayt, P., Manabe, R., Watanabe, T., & Arihara, N. (2004). Analisis of oil-water flow tests in horizontal, hilly-terrain, and vertical pipes. *Proceedings - SPE Annual Technical Conference and Exhibition*, 1335–1347. <https://doi.org/10.2523/90096-ms>
- Aggarwal, C. C. (2018). *Neural Networks and Deep Learning* (Vol. 1).
- Amir, F., & Zhang, Y. (2017). Transport Phenomena in Multiphase Systems. In *Perspectives on Statistical Thermodynamics* (pp. 81–93). <https://doi.org/10.1017/9781316650394.010>
- Andrade, G. M. P., de Menezes, D. Q. F., Soares, R. M., Lemos, T. S. M., Teixeira, A. F., Ribeiro, L. D., Vieira, B. F., & Pinto, J. C. (2022). Virtual flow metering of production flow rates of individual wells in oil and gas platforms through data reconciliation. *Journal of Petroleum Science and Engineering*, 208. <https://doi.org/10.1016/j.petrol.2021.109772>
- Andrianov, N. (2018). *A Machine Learning Approach for Virtual Flow Metering and Forecasting*. <https://github.com/nikolai-andrianov/VFM/>.
- Archibong-Eso, A., Okeke, N. E., Baba, Y., Aliyu, A. M., Lao, L., & Yeung, H. (2019). Estimating slug liquid holdup in high viscosity oil-gas two-phase flow. *Flow Measurement and Instrumentation*, 65(March 2018), 22–32. <https://doi.org/10.1016/j.flowmeasinst.2018.10.027>
- Bai, Y., & Bai, Q. (2011). *Subsea structural engineering handbook*. Gulf Professional Pub.
- Bannwart, A. C., Rodriguez, O. M. H., De Carvalho, C. H. M., Wang, I. S., & Vara, R. M. O. (2004). Flow patterns in heavy crude oil-water flow. *Journal of Energy Resources Technology, Transactions of the ASME*, 126(3), 184–189. <https://doi.org/10.1115/1.1789520>
- Bikmukhametov, T., & Jäschke, J. (2020). First Principles and Machine Learning Virtual Flow Metering: A Literature Review. In *Journal of Petroleum Science and Engineering* (Vol. 184).

- Elsevier B.V. <https://doi.org/10.1016/j.petrol.2019.106487>
- Brownlee Disclaimer, J. (2017). *Long Short-Term Memory Networks With Python Develop Sequence Prediction Models With Deep Learning*.
- Brownlee, J. (2020). *Beginner-3: Probability for Machine Learning*. <https://machinelearningmastery.com/probability-for-machine-learning/>
- Calin, O. (2020). *Deep Learning Architectures*. Springer International Publishing. <https://doi.org/10.1007/978-3-030-36721-3>
- Çengel, Y. A., & Cimbala, J. M. (2006). *Mecánica De Fluidos Fundamentos Y Aplicaciones* (Çengel Yunes A & Cimbala .John M (eds.); Primera Ed).
- Chandriah, K. K., & Naraganahalli, R. V. (2021). RNN / LSTM with modified Adam optimizer in deep learning approach for automobile spare parts demand forecasting. *Multimedia Tools and Applications*, 80(17), 26145–26159. <https://doi.org/10.1007/s11042-021-10913-0>
- Chen, X., & Guo, L. (1999). Flow patterns and pressure drop in oil–air–water three-phase flow through helically coiled tubes. *International Journal of Multiphase Flow*, 25(6–7), 1053–doi:10.1016/S0301-9322(99)00065-8
- Du, M., Jin, N. De, Gao, Z. K., Wang, Z. Y., & Zhai, L. S. (2012). Flow pattern and water holdup measurements of vertical upward oil-water two-phase flow in small diameter pipes. *International Journal of Multiphase Flow*, 41, 91–105. <https://doi.org/10.1016/j.ijmultiphaseflow.2012.01.007>
- Faghri, A., & Zhang, Y. (2020). *Fundamentals of Multiphase Heat Transfer and Flow*.
- Fallis, A. . (2013). Practical Hydroinformatics: Computational Intelligence and Technological Developments in Water Applications. In *Journal of Chemical Information and Modeling* (Vol. 53, Issue 9). www.springer.com/series/6689

- Flores, J. G., Chen, X. T., Sarica, C., & Brill, J. P. (1998). Characterization of oil-water flow patterns in vertical and deviated wells. In *Proceedings of the International Oil & Gas Conference and Exhibition in China, IOGCEC* (Vol. 1, pp. 55–64). <https://doi.org/10.2523/38810-ms>
- G. W. Govier, G. A. Sullivan, R. K. W. (1961). *The upward vertical flow of oil-water mixures.*
- Ganat, T., Ridha, S., Hairir, M., Arisa, J., & Gholami, R. (2019). Experimental investigation of high-viscosity oil–water flow in vertical pipes: flow patterns and pressure gradient. *Journal of Petroleum Exploration and Production Technology*, 9(4), 2911–2918. <https://doi.org/10.1007/s13202-019-0677-y>
- Geoffrey I. Webb, & Claude, S. (2017). *Encyclopedia of Machine Learning and Data Mining.*
- Guet, S., & Ooms, G. (2006). Fluid mechanical aspects of the gas-lift technique. In *Annual Review of Fluid Mechanics* (Vol. 38, pp. 225–249). <https://doi.org/10.1146/annurev.fluid.38.061505.093942>
- Han, Y. F., Jin, N. D., Zhai, L. S., Zhang, H. X., & Ren, Y. Y. (2017). Flow pattern and holdup phenomena of low velocity oil-water flows in a vertical upward small diameter pipe. *Journal of Petroleum Science and Engineering*, 159(September), 387–408. <https://doi.org/10.1016/j.petrol.2017.09.052>
- Hasan, A. R., & Kabir, C. S. (1988). New model for two-phase oil/water flow: production log interpretation and tubular calculations. *Society of Petroleum Engineers of AIME, (Paper) SPE, PI*(May), 369-382 18216. <https://doi.org/10.2118/18216-pa>
- Hasan, A. R., & Kabir, C. S. (1999). A simplified model for oil/water flow in vertical and deviated wellbores. *SPE Production and Facilities*, 14(1), 56–62. doi: 10.2118/54131-PA
- Hotvedt, M., Grimstad, B. A., & Imsland, L. S. (2022). Passive learning to address nonstationarity

- in virtual flow metering applications. *Expert Systems with Applications*, 210(August), 118382. <https://doi.org/10.1016/j.eswa.2022.118382>
- Jana, A. K., Das, G., & Das, P. K. (2006). Flow regime identification of two-phase liquid-liquid upflow through vertical pipe. *Chemical Engineering Science*, 61(5), 1500–1515. <https://doi.org/10.1016/j.ces.2005.09.001>
- Jana, A. K., Ghoshal, P., Das, G., & Das, P. K. (2007). An analysis of pressure drop and holdup for liquid-liquid upflow through vertical pipes. *Chemical Engineering and Technology*, 30(7), 920–925. <https://doi.org/10.1002/ceat.200700033>
- Jixiang Guo, Yuqi Yang, Bo Ren, Shuai Zhang, Ruiying Xiong, Dengshan Zhang, Chang Cao, Zhiyong Liao, Shiling Zhang, & Shunkang Fu. (2019). Heavy oil-water flow patterns in a small diameter vertical pipe under high temperature pressure conditions . *Experimental Thermal and Fluid Science*.
- Kanagachidambaresann, K. G. (2021). *Programming with TensorFlow Solution for Edge Computing Applications*.
- Li, H., Pourquié, M. J. B. M., Ooms, G., & Henkes, R. A. W. M. (2022). Simulation of a turbulent annulus with interfacial waves in core-annular pipe flow. *International Journal of Multiphase Flow*, 154(May). <https://doi.org/10.1016/j.ijmultiphaseflow.2022.104152>
- Mauricio Ruiz Diaz, C., German González Silva, C., & Mauricio Hernández Cely, M. (2021). *Caracterización hidrodinámica de flujos multifase empleando técnicas de inteligencia artificial*.
- Mazza, R. A., & Suguimoto, F. K. (2020). Experimental investigations of kerosene-water two-phase flow in vertical pipe. *Journal of Petroleum Science and Engineering*, 184(xxxx), 106580. <https://doi.org/10.1016/j.petrol.2019.106580>

- Michie, D., Spiegelhalter, D. J., & Taylor, C. C. (1994). Machine Learning, Neural And Statistical Classification. *Machine Learning, Neural And Statistical Classification*, 1. <http://citeseerx.ist.psu.edu/viewdoc/similar?doi=10.1.1.27.355&type=cc>
- Mydlarz-Gabryk, K., Pietrzak, M., & Troniewski, L. (2014). Study on oil-water two-phase upflow in vertical pipes. *Journal of Petroleum Science and Engineering*, 117, 28–36. <https://doi.org/10.1016/j.petrol.2014.03.007>
- Pan, Y., Li, C., Ma, Y., Huang, S., & Wang, D. (2019). Gas flow rate measurement in low-quality multiphase flows using Venturi and gamma ray. *Experimental Thermal and Fluid Science*, 100, 319–327. <https://doi.org/10.1016/j.expthermflusci.2018.09.017>
- Rodriguez, O. M. H., & Bannwart, A. C. (2006). Experimental study on interfacial waves in vertical core flow. *Journal of Petroleum Science and Engineering*, 54(3–4), 140–148. <https://doi.org/10.1016/j.petrol.2006.07.007>
- Song, S., Wu, M., Qi, J., Wu, H., Kang, Q., Shi, B., Shen, S., Li, Q., Yao, H., Chen, H., & Gong, J. (2022). An intelligent data-driven model for virtual flow meters in oil and gas development. *Chemical Engineering Research and Design*, 186, 398–406. <https://doi.org/10.1016/j.cherd.2022.08.016>
- Sun, J., Ma, X., & Kazi, M. (2018). Comparison of decline curve analysis DCA with recursive neural networks RNN for production forecast of multiple wells. *SPE Western Regional Meeting Proceedings, 2018-April(April)*. <https://doi.org/10.2118/190104-ms>
- Xu, J. yu, Li, D. hui, Guo, J., & Wu, Y. xiang. (2010). Investigations of phase inversion and frictional pressure gradients in upward and downward oil-water flow in vertical pipes. *International Journal of Multiphase Flow*, 36(11–12), 930–939. <https://doi.org/10.1016/j.ijmultiphaseflow.2010.08.007>

- Yang, Y., Guo, J., Ren, B., Zhang, S., Xiong, R., Zhang, D., Cao, C., Liao, Z., Zhang, S., & Fu, S. (2019). Oil-Water flow patterns, holdups and frictional pressure gradients in a vertical pipe under high temperature/pressure conditions. In *Experimental Thermal and Fluid Science* (Vol. 100). <https://doi.org/10.1016/j.expthermflusci.2018.09.013>
- Yang, Y., Guo, J., Ren, B., Zhang, S., Xiong, R., Zhang, D., Cao, C., Liao, Z., Zhang, S., & Fu, S. (2019b). Oil-Water flow patterns, holdups and frictional pressure gradients in a vertical pipe under high temperature/pressure conditions. *Experimental Thermal and Fluid Science*, 100, 271–291. <https://doi.org/10.1016/j.expthermflusci.2018.09.013>
- Zhao, D., Guo, L., Hu, X., Zhang, X., & Wang, X. (2006). Experimental study on local characteristics of oil-water dispersed flow in a vertical pipe. *International Journal of Multiphase Flow*, 32(10–11), 1254–1268. doi:10.1016/j.ijmultiphaseflow.2006.06.004

10 Apéndices

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