

ESTUDIO DE FLUJOS BIFÁSICOS DE ALTA VISCOSIDAD: UN ENFOQUE MODERNO CON REDES NEURONALES ARTIFICIALES

LIZETH TORRES, WASSILA AJBAR,
JONATHAN HERNÁNDEZ, JOSÉ ENRIQUE GUZMÁN,
ARTURO PALACIO, ALEJANDRO RODRÍGUEZ

La investigación de flujos bifásicos de alta viscosidad es fundamental debido a su presencia en diversos procesos industriales, especialmente en los sectores de petróleo, gas, ingeniería química y procesamiento de alimentos. En este contexto, las tuberías desempeñan un papel protagonista, ya que actúan como las venas que dirigen estos flujos. No obstante, es importante resaltar que las tuberías pueden convertirse en un punto vulnerable para la seguridad en estos procesos industriales si no se diseñan, operan y mantienen de manera adecuada. El riesgo de fallas en tuberías se atribuye a varios factores identificados; destacan el diseño deficiente, prevenible con atención detallada en la fase de diseño, y la amenaza de corrosión, evitable con mantenimiento preventivo. Sin embargo, los riesgos más elevados surgen durante la fase de operación.

Durante la operación de tuberías, los aumentos repentinos de presión representan un riesgo con repercusiones drásticas, especialmente en aquellos casos donde se transportan flujos con alta viscosidad. Aún así, este riesgo puede atenuarse mediante la implementación de sistemas automatizados de supervisión conformados por sensores inteligentes y modelos predictivos basados, por ejemplo, en Redes Neuronales Artificiales (RNA). Para diseñar sistemas de supervisión es necesario investigar los fenómenos que provocan los cambios súbitos de presión. Algunos de estos fenómenos son la transición de régimen de flujo y la formación de tapones, que son ocasionados por las variaciones en la velocidad del flujo, por la relación de mezcla entre las fases, por las condiciones del sistema y por la naturaleza compleja del flujo bifásico. Esta última causada por la interacción dinámica entre fases, cada una con propiedades físicas muy diferentes. Por ello, identificar de manera temprana estos fenómenos es esencial para ajustar automáticamente las condiciones operativas y salvaguardar la operación de los sistemas de transporte.

A diferencia del flujo monofásico, que se clasifica únicamente en flujo laminar en transición y turbulento; el flujo bifásico

presenta diversos regímenes conocidos como patrones de flujo. Estos patrones son estructuras geométricas en constante evolución temporal y espacial, configuradas por la distribución de las dos fases dentro de la tubería por la que fluyen. Muchos patrones de flujo ya han sido clasificados, lo que permite su identificación cuando aparecen (ver Figura 1). Además, es posible inducir y controlar estos patrones para satisfacer de manera específica las necesidades de cada proceso, tales como los objetivos de transferencia de calor, la eficiencia de mezcla, la distribución de fases necesaria y la capacidad del sistema para gestionar fluctuaciones. En consecuencia, no hay un patrón de flujo universalmente adecuado para todos los procesos, ya que diferentes aplicaciones pueden requerir enfoques distintos. Sin embargo, algunos regímenes de flujo se consideran más propensos a desafíos y riesgos, entre ellos:

Flujo de Tapones: Los tapones son regiones cilíndricas voluminosas de una fase que se desplazan a través de la otra. En el caso de flujo líquido-gas, el término flujo de tapones se refiere a la presencia de cilindros de gas arrastrados por un líquido continuo, cuya presencia puede generar cambios súbitos de presión.

Flujo Anular: Cuando hay un flujo rápido y concentrado de una fase en el centro de la tubería, puede generar condiciones turbulentas y cambios bruscos en la distribución de fases. Esto podría afectar la estabilidad del sistema.

Flujo Burbuja: Si hay burbujas de gas de gran tamaño en el flujo, pueden causar interferencias significativas en la transferencia de calor y provocar fluctuaciones en la presión.

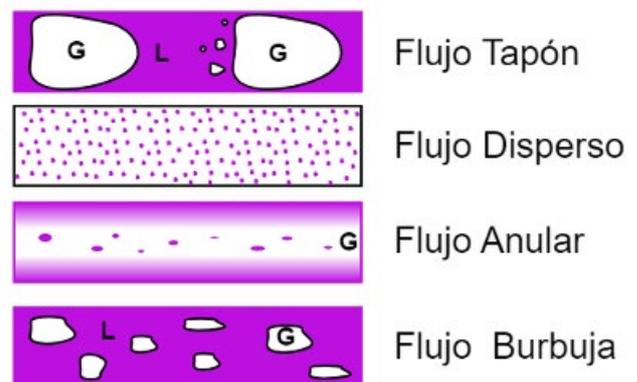


Figura 1. Patrones de Flujo Bifásico

Al conocer e identificar los patrones de flujo asociados con situaciones de riesgo, se pueden tomar medidas preventivas antes de que se intensifiquen los problemas. Por ejemplo, se pueden ajustar los parámetros de entrada, como la inyección de líquido, o sintonizar los sistemas de control para prevenir transiciones no deseadas. En resumen, la identificación de patrones de flujo no sólo permite una comprensión más profunda del comportamiento del sistema, también, brinda la capacidad de implementar estrategias proactivas. Para ello, se han utilizado diversas herramientas y técnicas. Algunas de las más comunes incluyen el uso de sensores y medidores tradicionales como sensores de presión, caudalímetros y medidores de nivel que, aunque no identifican directamente los patrones de flujo, proporcionan información clave que puede ser utilizada en conjunto con otras técnicas para inferir el régimen de flujo, tales como técnicas estadísticas y de procesamiento de señales. Otros tipos de sensores menos convencionales son los sensores de impedancia eléctrica que miden las variaciones en la conductividad del fluido, por tanto, pueden utilizarse para la identificación basándose en las propiedades eléctricas de las fases^[1].

Otra técnica común es la visualización directa a través de cámaras instaladas en la tubería o mediante ventanas transparentes en el sistema. Sin embargo, esta opción puede ser limitada en sistemas cerrados o de difícil acceso. Una mejora de la visualización directa es el uso de técnicas de procesamiento de imágenes capturadas con cámaras y posteriormente procesadas con algoritmos de visión. Por otro lado, las RNA y otros algoritmos de aprendizaje automático han demostrado ser eficaces en la identificación de patrones de flujo a partir de datos recopilados. Pueden analizar patrones complejos y adaptarse a cambios en las condiciones del sistema.

La identificación de patrones de flujo mediante RNA implica dos procesos clave: extracción de características y clasificación.^[2] Diversos estudios han propuesto diferentes métodos utilizando RNA y otros algoritmos de aprendizaje automático, que ofrecen mejoras en precisión y eficiencia en comparación con métodos tradicionales. Las RNA han sido utilizadas tanto para identificar patrones de flujo como para predecir el comportamiento de caídas de presión^[3] y las fracciones de vacío (*hold up*)^[4] también, para corregir errores de medición de caudalímetros^[5] y para caracterizar flujo de tapones, entre otras muchas aplicaciones.^[6]

Siguiendo esta tendencia e innovando para crear otras, investigadores y estudiantes de la Subdirección de Electromecánica, particularmente de las Coordinaciones tanto de Eléctrica y Computación como la de Ingeniería de Procesos Industriales y Ambientales del Instituto de Ingeniería de la UNAM (IIUNAM), colaboran para desarrollar inteligencia artificial que ayude a optimizar la operación de sistemas de transporte de flujo bifásico de alta viscosidad. Además, trabajan en la creación de

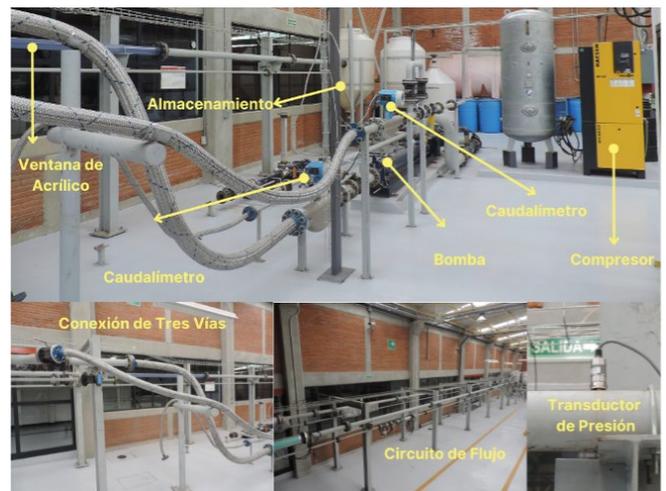


Figura 2. Circuito experimental de flujo multifásico

sistemas de supervisión y control destinados a salvaguardar la integridad de dichos sistemas. Para ello, en el Laboratorio de Flujos Multifásicos del IIUNAM, se instaló un circuito experimental. Su diseño fue concebido después de realizar una serie de visitas a laboratorios de punta que cuentan con instalaciones que representan el estado actual en circuitos multifásicos. Este avance fue posible gracias al respaldo financiero proporcionado por CONACyT. La Figura 2 muestra una serie de fotografías de este circuito donde es posible hacer fluir tres tipos de flujos: aire, agua y glicerina. Este circuito se compone de una tubería de 54 metros de longitud y 3" de diámetro, en la que se instalaron cuatro transductores de presión distribuidos a lo largo de su recorrido, así como tomógrafos y una sección de acrílico que permite visualizar el flujo y videograbarlo con cámaras de alta velocidad. También, cuenta con un circuito alterno de 1" de diámetro. Para suministrar la fase líquida se utiliza una bomba de cavidad progresiva (Seepex Mod. BN35-24). Esta bomba es capaz de proporcionar caudales máscicos constantes que varían entre 0.0 y 6.1 kg/s. Para suministrar aire seco a temperatura ambiente, se emplea un compresor (Kaeser Aircenter SK.2). La mezcla de ambas fases tiene lugar en la conexión de 3 vías, como se muestra en la Fig. 1. Para medir los caudales máscicos de entrada, se utilizan caudalímetros (Endress-Hausser Coriolis) con una precisión de $\pm 0.1\%$; mientras que para medir las presiones se emplea un conjunto de transductores convencionales (MEAS U5300) con una precisión de $\pm 1\%$.

Con los datos que se han adquirido durante la realización de experimentos en el circuito de flujo multifásico del IIUNAM, se han desarrollado en los últimos años varias aplicaciones basadas en RNA. Algunas de estas se describen a continuación.

Identificación de gastos máxicos: se implementaron dos redes neuronales convolucionales (RNC) para estimar los gastos máxicos de glicerina y aire inyectados en la entrada del circuito de flujo. Para las fases de entrenamiento, validación y pruebas se utilizaron imágenes (*.jpg) de espectrogramas construidos a partir de datos de presión adquiridos experimentalmente. Estos espectrogramas se construyeron utilizando la transformada de Fourier de tiempo corto (ver Figura 3). La correlación de la predicción de ambas redes neuronales con respecto a datos experimentales fue alrededor de 80%. Estos resultados, que parecen modestos, se obtuvieron con un número limitado de imágenes, por lo que se sigue trabajando en la realización de experimentos que complementen los ya ejecutados, así como en la mejora de la eficiencia de predicción de las redes.^[7]

Predicción de las presiones en coordenadas específicas del circuito: Se desarrolló un conjunto de modelos basados en RNA para predecir la evolución temporal de las fluctuaciones de presión a lo largo de una tubería horizontal. Específicamente, el enfoque se centra en la predicción de estas fluctuaciones que se generan por el desplazamiento simultáneo de masas de aire y glicerina, en coordenadas espaciales predeterminadas.

Los modelos se alimentan de los gastos de flujo máxico de ambas fases medidos en la entrada de la tubería, junto con valores de presión medidos en ubicaciones previas a la ubicación de la presión a predecir. Con el fin de determinar la arquitectura óptima para la RNA, se probaron cuatro funciones de transferencia en la capa oculta y se usó el algoritmo de Levenberg-Marquardt para la etapa de entrenamiento. Posteriormente, los modelos fueron evaluados estadísticamente mostrando una capacidad para proporcionar predicciones con un R_2 superior a 0.98.

Predicción de la presión de salida: se desarrolló una colección de RNA con diversas arquitecturas para descubrir el modelo más adecuado para predecir la presión de salida de una tubería horizontal con flujo bifásico de alta viscosidad. Las RNA se construyeron combinando tres diferentes variables de entrada (gasto máxico de aire, gasto máxico de glicerina y mediciones de presión en puntos espaciales específicos). Cada una de estas RNA fue entrenada con una cantidad variable de neuronas en la capa oculta. En especial, una RNA mostró los mejores resultados con un valor de $R^2=0.9943$ [8]. Un esquema general de estos modelos se muestra en la Figura 4.

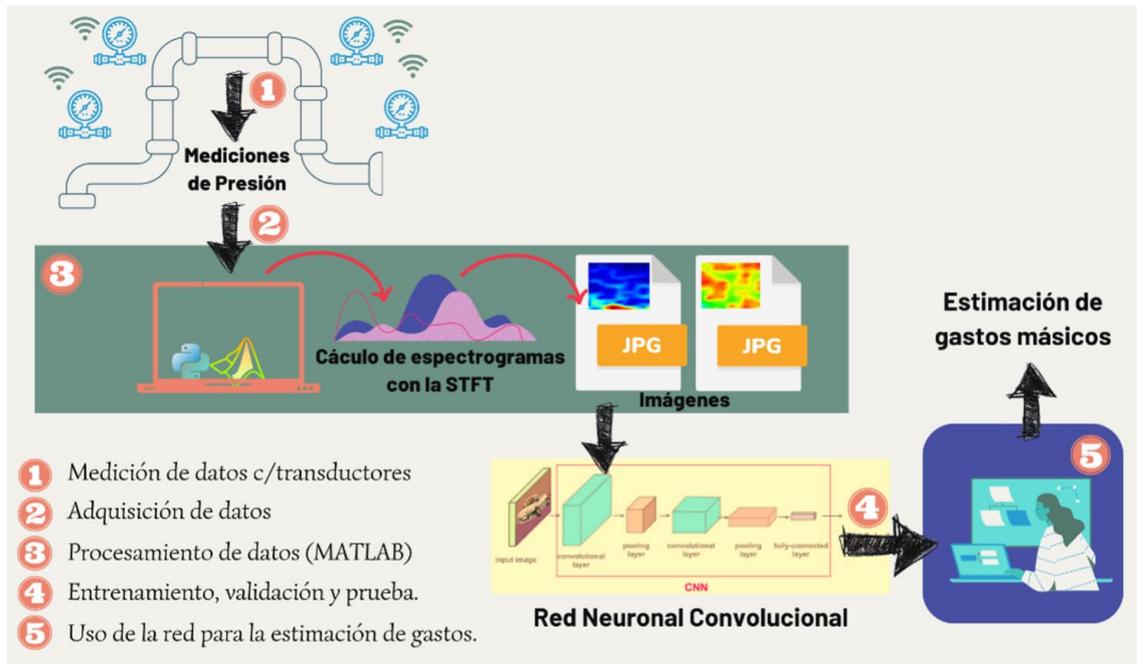


Figura 3. Procedimiento para la estimación de gastos máxicos empleando RNC

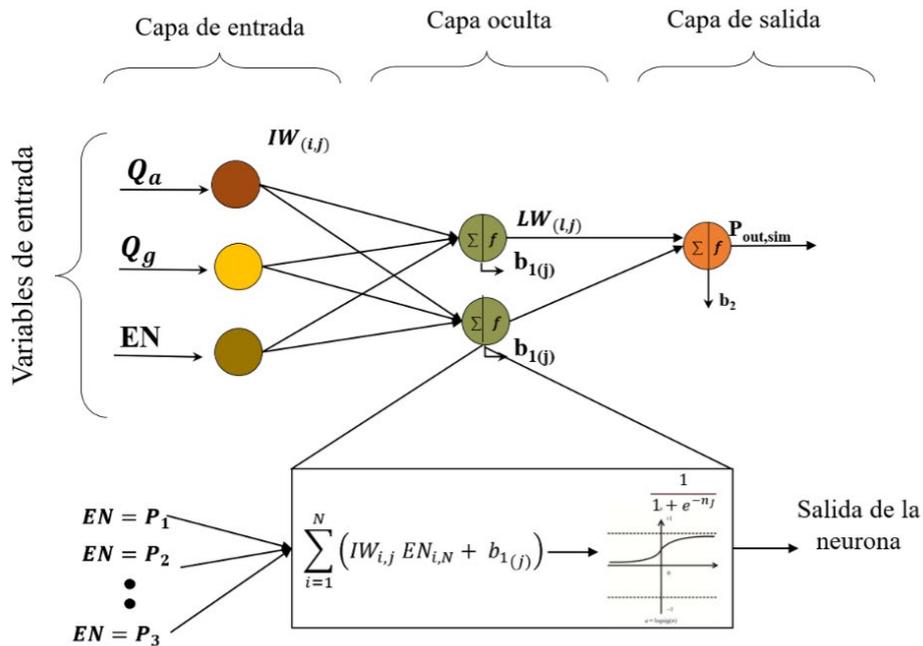


Figura 4. Esquema de RNA para la estimación de una presión cerca de la descarga

Además de estas aplicaciones de RNA, que ya fueron publicadas en revistas y congresos de gran prestigio, actualmente, se están desarrollando y aplicando nuevas RNA para predecir las fracciones de vacío mediante mediciones de presión. Además, se está explorando la regulación de presiones mediante RNA inversas y algoritmos de optimización.

Para concluir, es importante destacar que la aplicación de la inteligencia artificial para comprender la complejidad del flujo bifásico con fluidos altamente viscosos tiene bifurcaciones que conducen a áreas de investigación aún inexploradas. Explorar estas áreas es esencial para desarrollar nuevas tecnologías que resulten beneficiosas para la sociedad. |

Referencias

- Hernández, L.; Juliá, J. E.; Chiva, S.; Paranjape, S. e Ishii, M. (2006). Fast classification of two-phase flow regimes based on conductivity signals and artificial neural networks. *Measurement Science and Technology*, 17(6), 1511.
- Li, Q. (2008). "Flow Pattern Identification of Two-Phase Flow Using Neural Network and Empirical Mode Decomposition," En: Fourth International Conference on Natural Computation, Jinan, China, pp. 375-378.
- Alizadehdakhel, A.; Rahimi, M.; Sanjari, J. y Alsairafi, A. A. (2009). CFD and artificial neural network modeling of two-phase flow pressure drop. *International Communications in Heat and Mass Transfer*, 36(8), 850-856.
- Azizi, S.; Awad, M. M. y Ahmadloo, E. (2016). Prediction of water holdup in vertical and inclined oil-water two-phase flow using artificial neural network. *International Journal of Multiphase Flow*, 80, 181-187.
- Liu, R. P.; Fuent, M. J.; Henry, M. P. y Duta, M. D. (2001). A neural network to correct mass flow errors caused by two-phase flow in a digital coriolis mass flowmeter. *Flow Measurement and Instrumentation*, 12(1), 53-63.
- Cozin, C.; Vicencio, F. E.; de Almeida Barbuto, F. A.; Morales, R. E.; Da Silva, M. J. y Arruda, L. V. R. (2016). Two-phase slug flow characterization using artificial neural networks. *IEEE Transactions on Instrumentation and Measurement*, 65(3), 494-501.
- Rocha-Mancera, M. F.; Arce-Benítez, S.; Torres, L. y Vázquez, J. E. G. (2023). Estimation of Mass Flow Rates of Two-Phase Flow Using Convolutional Neural Networks. En: Kowalczyk, Z. (eds) *Intelligent and Safe Computer Systems in Control and Diagnostics. DPS 2022. Lecture Notes in Networks and Systems*, vol 545. Springer, Cham.
- Ajbar, W.; Torres, L.; Guzmán, J. E. V. y Palacio-Pérez, A. (2023). "Artificial Neural Networks for Predicting Pressure in High-Viscosity Two-Phase Flow: A Comparative Analysis." En: *Memorias del Congreso Nacional de Control Automático 2023*, Acapulco, Guerrero, México.