VOLUMEN 48
XXXI Verano De la Ciencia
ISSN 2395-9797
www.jovenesenlaciencia.ugto.mx

Generación de modelo sustituto para la generación de campos de velocidad a través de una Red Neuronal entrenada con CFD

Surrogate Model Generation for Velocity Field Prediction Using a Neural Network Trained on CFD Data

Carlos Enrique Alvarado Rodríguez[1,2], Miguel Aguilar Becerra[1], Diego Ian Agabo Aguilar[1]
[1]Departamento de Ingeniería Química, División de Ciencias Naturales y Exactas, Universidad de Guanajuato, Campus Guanajuato, Noria Alta S/N, CP 36050.
[2]Secretaría Ciencias Humanidades Tecnología e Innovación (SECIHTI), Av. Insurgentes Sur 1582, Col. Crédito Constructor, Alcaldía Benito Juárez. CP 03940, Ciudad de México, México.
ce.alvarado@ugto.mx

Resumen

El diseño y optimización de tanques agitados en la industria química requiere una comprensión profunda de su compleja hidrodinámica, frecuentemente caracterizada por flujos turbulentos y patrones dependientes del tipo de impulsor, aunque la Dinámica de Fluidos Computacional (CFD) permite estudiar estos fenómenos sin el alto costo de la experimentación física, el tiempo computacional requerido sigue siendo una limitante. En este trabajo, se propone el uso de una red neuronal artificial como modelo sustituto para acelerar estos cálculos, inicialmente se realizaron simulaciones numéricas utilizando el método Smoothed Particle Hydrodynamics (SPH) mediante el software DualSPHysics, validando la convergencia de la solución en función del número de partículas y evaluando distintas posiciones del impulsor (z = 0.016 m, z = 0.028 m y z = 0.040 m), los campos de velocidad obtenidos de estas simulaciones se utilizaron para entrenar una red neuronal tipo Perceptrón Multicapa (MLP) de caja negra, estructurada con una arquitectura de 9x256x256x128x64x1. A partir de variables operativas y geométricas definidas previamente, la red fue capaz de predecir los perfiles de velocidad del impulsor, pues los resultados demuestran que este modelo neuronal actúa como un validador predictivo ágil que logra generar campos escalares de velocidad similares a los obtenidos con SPH con un error máximo de RMSE=0.101 pero 9391 veces más rápido.

Palabras clave: Dinámica de Fluidos Computacional (CFD), Hidrodinámica de Partículas Suavizadas (SPH), tanques agitados, redes neuronales, modelos sustitutos.

Introducción

La Dinámica de Fluidos Computacional (CFD) se ha convertido en una herramienta indispensable para nosotros como estudiantes y futuros ingenieros al momento de diseñar o mejorar equipos en la industria química, su gran ventaja es que nos ayuda a entender qué pasa dentro de un proceso cuando hacer experimentos físicos en la planta o en el laboratorio resulta muy costoso o es casi imposible por las condiciones extremas de operación. A través de la simulación y resolviendo las ecuaciones de Navier-Stokes, la CFD nos da una imagen muy clara de la velocidad y el comportamiento del fluido, ahorrándonos mucho tiempo y recursos.

Para realizar este tipo de simulaciones, un software que destaca bastante entre las opciones disponibles es DualSPHysics (Dominguez *et al*., 2022), lo interesante de este programa es que, a diferencia del software tradicional que divide el espacio en una cuadrícula o malla fija, este trabaja con el método de Hidrodinámica de Partículas Suavizadas (Smoothed Particle Hydrodynamics, SPH). Básicamente, este método trata al fluido como un conjunto de partículas que se mueven libremente siguiendo leyes físicas de conservación, esto nos resulta súper útil cuando queremos simular tanques agitados, porque logra recrear de forma muy certera la interacción entre el líquido y las aspas en movimiento, un reto numérico que a los programas de malla les cuesta mucho trabajo resolver sin deformarse.

En la industria, los tanques agitados son equipos fundamentales, pues son los encargados de que la transferencia de masa, el intercambio de calor y la suspensión de sólidos ocurran correctamente. Para que un proceso de mezclado sea eficiente, tenemos que entender a fondo su régimen hidrodinámico, casi siempre nos enfrentamos a flujos turbulentos, llenos de remolinos a distintas escalas, que son mucho más complejos de predecir que un flujo laminar tranquilo. A esto se suma que el tipo de impulsor cambia todo el panorama, por ejemplo, una turbina Rushton avienta el fluido hacia los lados dispersando gases (flujo radial), mientras que una hélice marina (Propela) lo empuja hacia abajo (circulación axial). Si desconocemos estos patrones de movimiento, el tanque termina con "zonas muertas" donde el fluido no se mezcla, haciendo que el proceso pierda rendimiento y la energía se distribuya de forma deficiente.

Las simulaciones CFD con el método SPH requieren de un amplio tiempo de cómputo, varios investigadores han empezado a usar redes neuronales de caja negra para acelerar los cálculos, por ejemplo, Liu *et al*. (2023) y Ha *et al*. (2026) utilizaron estas redes para optimizar el diseño de eyectores de CO_2 y configuraciones de enfriamiento por inmersión, respectivamente; Lázaro *et al*. (2013) y Vahidi *et al*. (2026) lograron predecir la dinámica del humo en incendios y las fuerzas hidrodinámicas en rompeolas costeros; y Agonga *et al*. (2026) las aplicaron para detectar inestabilidades en cámaras de combustión de turbinas.

Es muy importante analizar el trabajo de estos autores porque demuestran cómo la inteligencia artificial logra reducir drásticamente los tiempos de cómputo manteniendo la precisión física de los modelos originales, esto tiene una relación muy directa con este proyecto, ya que sirve de base metodológica y comprueba que sí es completamente viable usar modelos sustitutos para evitar la carga computacional tan pesada de la dinámica de fluidos, principalmente con el método SPH.

La gran diferencia y la novedad de nuestra investigación recae en el enfoque que le damos al aprendizaje automático, a diferencia de los artículos que mencionamos (donde la red se usa principalmente para optimización global o para seleccionar qué características importan más), nosotros no empleamos el modelo para escoger variables, sino que nosotros definimos nuestras variables operativas y geométricas desde el inicio y construimos una red neuronal tipo Perceptrón Multicapa (MLP) de caja negra con una estructura de 9x256x256x128x64x1.

El objetivo de este trabajo es usar la red neuronal para predecir los campos de velocidad generados por el impulsor dentro del tanque agitado, y al comparar los campos de velocidad que predice la red con los cálculos obtenidos en DualSPHysics, verificando que el modelo funciona como un validador predictivo muy ágil, capaz de igualar la alta resolución del método SPH pero superando ampliamente los tiempos en los cuales se generan los datos de salida, en este caso, los campos de velocidad en el medio.

Metodología

Con el propósito de entrenar una red neuronal multicapa (Multilayer Perceptron, MLP) capaz de predecir el campo de velocidades en un tanque agitado, se generó un conjunto de datos mediante simulaciones numéricas utilizando el método SPH con el software libre DualSPHysics.

El caso de estudio corresponde a un tanque cilíndrico con un diámetro interno de 8 cm y una altura total de 10 cm, manteniendo una altura de líquido de 8 cm. El impulsor empleado posee un diámetro de 2.6 cm, equivalente aproximadamente a un tercio del diámetro del tanque. Además, el tanque cuenta con cuatro bafles distribuidos uniformemente sobre la pared interna, cada uno con un ancho de 0.8 cm. Durante todas las simulaciones se estableció una temperatura del fluido de 25 °C. La altura del impulsor (H_i) se consideró como una de las variables de estudio, evaluándose tres posiciones axiales dentro del tanque: Bottom (1.6 cm), Middle (2.8 cm) y Top (4.0 cm), con el propósito de analizar la influencia de su ubicación sobre el campo de velocidades.

Asimismo, se consideraron dos configuraciones de impulsores: una propela de tres aspas y un impulsor Rushton de seis palas. Cada uno de fue evaluado bajo las mismas condiciones geométricas y de operación con el fin de analizar su influencia sobre el comportamiento hidrodinámico y generar el conjunto de datos utilizado para el entrenamiento de la red neuronal.

Como condiciones de contorno, el tanque, los bafles y el impulsor fueron modelados como superficies sólidas rígidas, aplicando una condición de no penetración entre las partículas del fluido y las paredes del dominio. El impulsor se modeló con una velocidad angular constante durante cada simulación, mientras que el sistema permaneció sometido a la aceleración gravitacional de 9.81 m/s². Cada simulación tuvo una duración de 5 s, almacenándose los resultados cada 0.25 s para su posterior procesamiento mediante la herramienta MeasureTool.

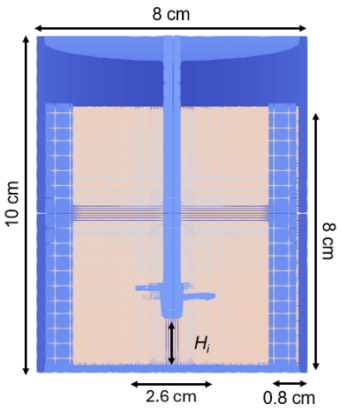


Figura 1. Geometría y dimensiones del tanque agitado utilizado en las simulaciones.

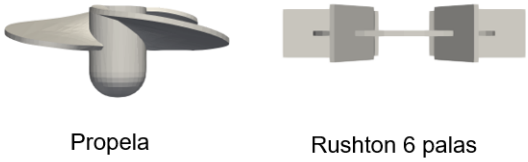


Figura 2. Geometrías de los impulsores empleadas.

Para caracterizar el movimiento de los fluidos dentro del tanque, se resolvieron numéricamente las ecuaciones de continuidad, cantidad de movimiento y estado mostradas en las ecuaciones (1) a (3).

$$\frac{d\rho}{dt} + \rho \boldsymbol{\nabla} \cdot \mathbf{v} = 0, \tag{1}$$

$$\frac{d\mathbf{v}}{dt} = -\frac{1}{\rho}\boldsymbol{\nabla P} + \boldsymbol{g} + \frac{1}{\rho}\boldsymbol{\nabla} \cdot \tau, \tag{2}$$

$$P = B\left[\left(\frac{\rho}{\rho_0}\right)^{\gamma} - 1\right], \tag{3}$$

En las ecuaciones la variable ρ es la densidad del fluido, t es el tiempo, v vector velocidad del fluido, $\Delta.v$ es la divergencia del campo de velocidad, P presión del fluido, g vector aceleración de la gravedad, τ tensor de esfuerzos viscosos, ∇P gradiente de presión, $\nabla.\tau$ divergencia del tensor de esfuerzos, B constante relacionada con la comprensibilidad del fluido, ρ_0 densidad de referencia y Ƴ constante polotrópica del modelo.

Para determinar la resolución espacial para las simulaciones, se realizó un análisis de convergencia empleando la configuración correspondiente a la posición media del impulsor (0.028 m) y manteniendo constantes las demás condiciones de operación y los parámetros numéricos utilizados en el resto de las simulaciones. Para este análisis se evaluaron cinco niveles de discretización, correspondientes a aproximadamente 100 000, 250 000, 500 000, 1 000 000 y 1 500 000 partículas. El desempeño de cada discretización se evaluó mediante el cálculo de la Raíz del Error Cuadrático Medio (RMSE) con respecto a la simulación de 1.5 millones de partículas.

Por su parte los datos empleados para el entrenamiento de la red neuronal fueron obtenidos mediante simulaciones CFD realizadas en DualSPHysics. Para cada impulsor se realizaron 12 simulaciones,

correspondientes a la combinación de cuatro velocidades de rotación (200, 300, 400 y 500 rpm) y tres posiciones axiales del impulsor bottom (z=0.016 m), middle (z=0.028 m) y top (z=0.040 m).

Una vez finalizadas las simulaciones, se utilizó la herramienta MeasureTool para extraer el campo de velocidades sobre tres planos horizontales (inferior z= 0.0235, medio z= 0.031 y superior z= 0.0385) ubicados a diferentes alturas del tanque con el propósito de representar el comportamiento del flujo en distintas regiones del dominio. Cada plano contiene aproximadamente 2642 partículas, registrándose para cada una de ellas la posición espacial y la magnitud de la velocidad en intervalos de tiempo comprendidos entre 0.25 y 5.00 s, con incrementos de 0.25 s, generando así una cantidad de 52840 datos de entrada al entrenamiento de la red para cada plano del impulsor.

Los archivos CSV generados mediante MeasureTool fueron procesados mediante scripts desarrollados en Python. Durante esta etapa se realizó la reorganización de las partículas, la estandarización de la estructura de los archivos y la integración de toda la información en un único conjunto de datos apto para el entrenamiento de la red neuronal. Cada registro quedó conformado por las siguientes variables de entrada:

Tabla 1. *Variables de entrada del conjunto de datos.*

Tiempo (s)	Velocidad de agitación (rpm)	Posición axial del impulsor (m)	Coordenada X (m)	Coordenada Y (m)	Coordenada Z (m)

Como variable de salida se utilizó la magnitud de la velocidad del fluido (m/s).

Además, se incorporaron tres variables geométricas calculadas a partir de la posición espacial de cada partícula con el objetivo de proporcionar información adicional sobre la ubicación espacial de cada partícula respecto al sistema de agitación. Las cuales son:

Distancia radial

$$r = \sqrt{x^2 + y^2}$$

Ángulo polar

$$\theta = atan2(y, x)$$

Distancia al impulsor

$$d = \sqrt{x^2 + y^2 + (z - zimp)^2}$$

donde z_{imp} corresponde a la posición axial del impulsor registrada para cada simulación

Normalización de datos

Con el objetivo de garantizar una escala homogénea para todas las variables, se aplicó una normalización fija con intervalo [-1,1]. La fórmula utilizada fue:

$$xnorm = 2\frac{x - xmin}{xmax - xmin} - 1$$

Los rangos de normalización fueron definidos a partir de las dimensiones del sistema y de las condiciones de operación. Para ello se utilizaron los siguientes rangos: tiempo de 0.25 a 5.00 s, velocidad del impulsor de 200 a 500 rpm, posición del impulsor de 0.016 a 0.040 m, coordenadas x y y de −0.04 a 0.04 m, coordenada z de 0.00 a 0.08 m, distancia radial de 0.00 a 0.060 m, ángulo polar de −π a π, distancia al impulsor de 0.00 a 0.090 m y magnitud de la velocidad del fluido de 0.00 a 1.466 m/s. La velocidad máxima utilizada para la normalización fue obtenida a partir de la velocidad tangencial máxima en la punta del impulsor:

$$V = \omega R$$

considerando un radio del impulsor de 0.028 m y una velocidad máxima de 500 rpm.

Arquitectura de la red neuronal

Se implementó una red neuronal totalmente conectada (Multilayer Perceptron, MLP) utilizando PyTorch, la arquitectura estuvo conformada por:

Tabla 2. *Arquitectura de la red neuronal multicapa (MLP).*

Capa	Arquitectura
Entrada	9 neuronas
Capas ocultas	256→ 256 → 128 → 64 neuronas
Salida	1 neurona

Como función de activación se empleó Tanh en todas las capas ocultas, la función de pérdida utilizada fue el Error Cuadrático Medio (MSE) y el entrenamiento se realizó mediante el optimizador Adam.

Con el propósito de evaluar la capacidad de generalización de la red neuronal, el conjunto de datos se dividió en datos de entrenamiento y datos de prueba. Para el entrenamiento se utilizaron únicamente los datos correspondientes a los planos superior e inferior obtenidos en cada simulación, mientras que los planos medios fueron excluidos del proceso de aprendizaje y reservados para la evaluación del modelo.

El modelo fue entrenado utilizando un único conjunto de datos para cada impulsor que integra la información correspondiente a las tres posiciones respecto al mismo(top, middle y bottom). Para cada una de estas se consideraron dos planos de muestreo, el plano superior y el plano inferior. El entrenamiento se realizó desde cero durante 500 épocas, con una tasa de aprendizaje de 0.0001, permitiendo que la red neuronal aprendiera el comportamiento del sistema a partir de todas las configuraciones espaciales incluidas en la base de datos.

El desempeño del modelo fue evaluado mediante las métricas: Error Absoluto Medio (MAE) y la Raíz del Error Cuadrático Medio (RMSE), se realizó una comparación directa entre los valores reales obtenidos mediante DualSPHysics y las predicciones generadas por la red neuronal para verificar la capacidad del modelo para reproducir el campo de velocidades del fluido además de generar archivos (.vtk) para su visualización.

Resultados

En esta sección se presentan los resultados obtenidos de los casos reportados en la metodología iniciando con los resultados de las simulaciones numéricas SPH y posteriormente con los resultados obtenidos del entrenamiento de la Red Neuronal y las predicciones de la red después de ser entrenada.

El primer caso de estudio corresponde a la convergencia de la solución numérica en función del número de partículas utilizado en la simulación. En este caso se utilizó el impulsor Ruston con posición z=0.028 para comparar un perfil de velocidad a través del tanque agitado con la finalidad de corroborar el número mínimo de partículas a utilizar en la simulación SPH que no presenta cambios en la solución numérica. En la Figura 3 se reportan los perfiles de velocidad obtenidos en para los distintos casos referentes a la convergencia y el error entre las soluciones numéricas observando que este desciende y se mantiene constante después de usar aproximadamente un millón de partículas.

VOLUMEN 48
XXXI Verano De la Ciencia
ISSN 2395-9797
www.jovenesenlaciencia.ugto.mx

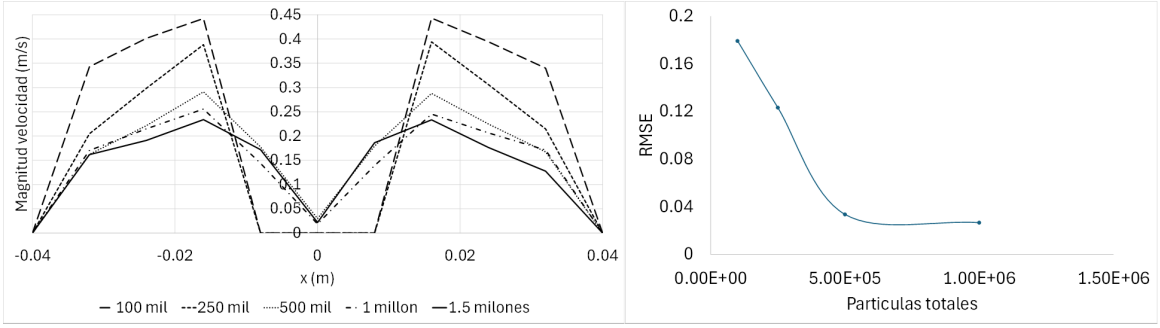


Figura 3. En el marco izquierdo se muestran los perfiles de velocidad de un diámetro en z=0.028 obtenidos de las simulaciones del caso de convergencia. En el marco derecho se muestra el error entre los perfiles de velocidad mostrados a la derecha donde se observa que el error entre ellos se mantiene constante al usar aproximadamente un millón de partículas.

A partir de las simulaciones reportadas en la metodología se obtuvieron los campos de velocidad con los cuales se entrenó la Red Neuronal para posteriormente usarla como modelo subrogado en la obtención de campos de velocidad en el interior de los tanques agitados. Los campos de velocidad utilizados para el entrenamiento se presentan en la Figura 4 y Figura 5. Los planos inferior y superior se utilizaron para el entrenamiento y el plano medio se utilizó para validación de los campos generados por la red neuronal.

El tiempo de entrenamiento para impulsor es de 4 hrs utilizando un procesador GPU GeForce RTX 2060. El tiempo de cómputo para la predicción del campo de velocidad es de 0.67 segundos (0.01 minutos)

Los resultados del entrenamiento se reportan en la Figura 6 (curva de pérdida de entrenamiento) donde el valor mínimo del error de entrenamiento es de 0.002470498 y 0.00037743 para el Rushton y propela respectivamente.

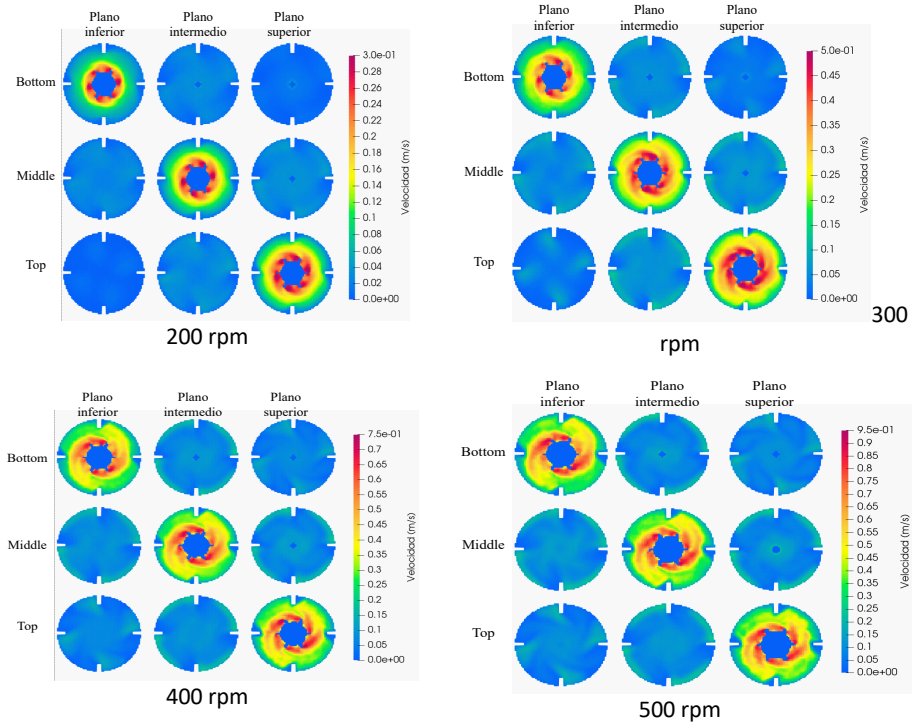


Figura 4. Campos de velocidad utilizados en el entrenamiento de la red neuronal correspondientes al impulsor Rushton para las tres posiciones (bottom, middle y top) correspondiente a t = 5 segundos. Cada campo de velocidad tiene tres posiciones axiales distintas, plano inferior z=0.0235, plano medio z=0.031 y plano superior z=0.0385, cada plano está conformado por 35 410 partículas.

VOLUMEN 48
XXXI Verano De la Ciencia
ISSN 2395-9797
www.jovenesenlaciencia.ugto.mx

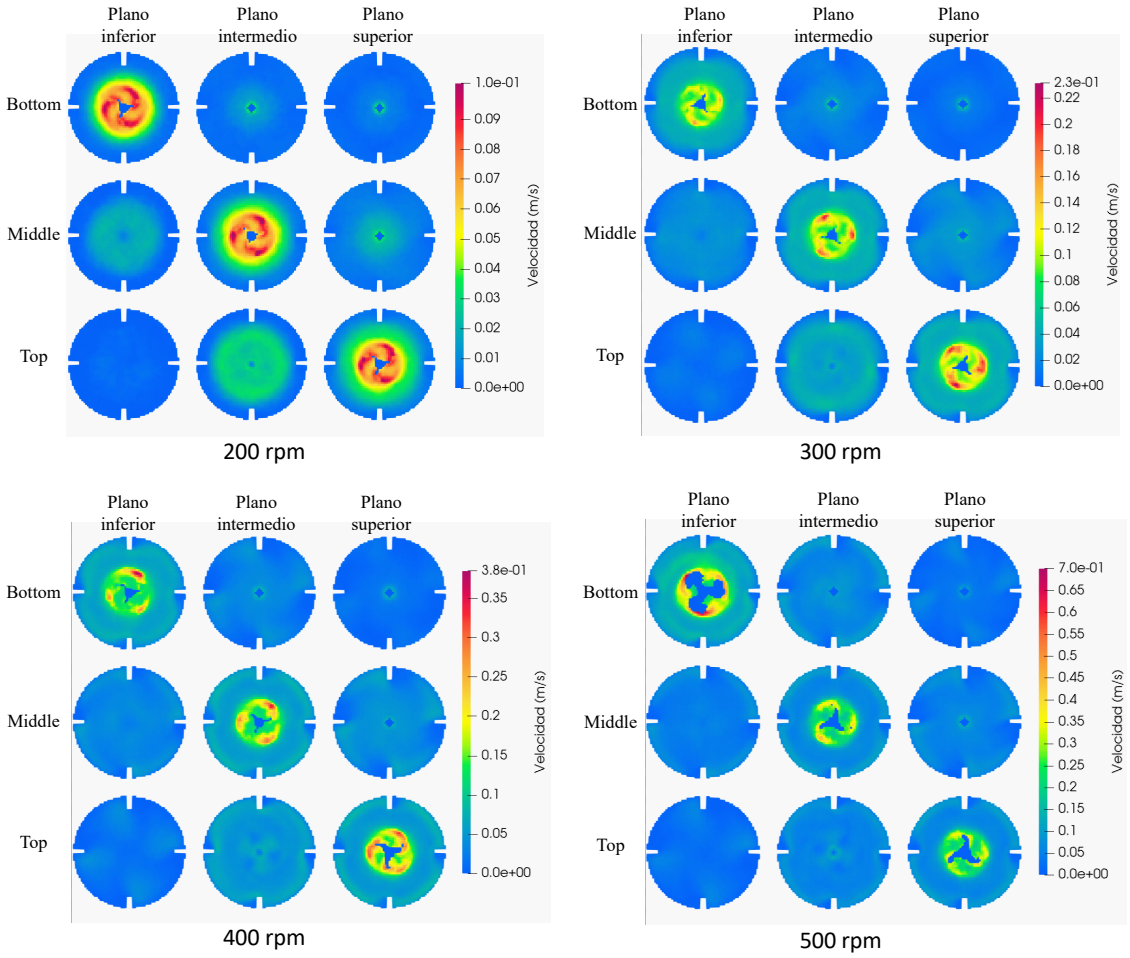


Figura 5. Campos de velocidad utilizados en el entrenamiento de la red neuronal correspondientes al impulsor propela para las tres posiciones (bottom, middle y top) correspondiente a t = 5 segundos. Cada campo de velocidad tiene tres posiciones axiales distintas, plano inferior z=0.0235, plano medio z=0.031 y plano superior z=0.0385, cada plano está conformado por 35 410 partículas.

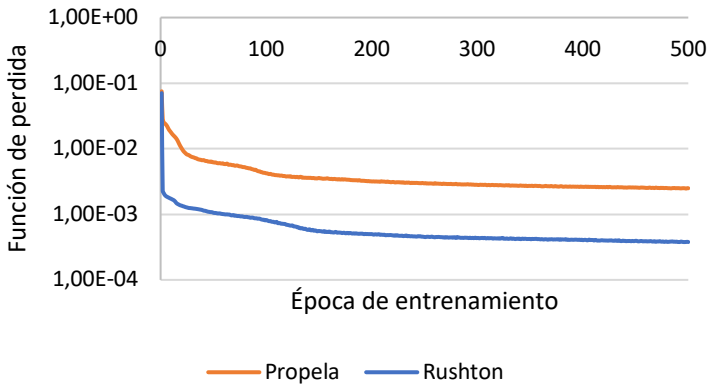


Figura 6. Curva de perdida de entrenamiento para cada uno de los impulsores.

VOLUMEN 48
XXXI Verano De la Ciencia
ISSN 2395-9797
www.jovenesenlaciencia.ugto.mx

Para la validación se compararon los campos de velocidad del plano intermedio reportados en las Figuras 4 y 5 donde se calculó el RMSE entre los datos generados por la red neuronal y los datos obtenidos por la simulación SPH, los resultados se muestran en la Tabla 1.

***Tabla 1**. Errores obtenidos en los casos de validación.*

Posición impulsor	Impulsor	Velocidad agitación	RMSE
Bottom	Propela	200	0.02423305
Bottom	Propela	300	0.03041528
Bottom	Propela	400	0.0355607
Bottom	Propela	500	0.04252899
Middle	Propela	200	0.00849403
Middle	Propela	300	0.01906178
Middle	Propela	400	0.03294289
Middle	Propela	500	0.04585182
Top	Propela	200	0.00323709
Top	Propela	300	0.00357146
Top	Propela	400	0.00577447
Top	Propela	500	0.00901733
Bottom	Rusthon	200	0.00752021
Bottom	Rusthon	300	0.0137332
Bottom	Rusthon	400	0.01016881
Bottom	Rusthon	500	0.05006199
Middle	Rusthon	200	0.02424203
Middle	Rusthon	300	0.04475527
Middle	Rusthon	400	0.06129225
Middle	Rusthon	500	0.10196785
Top	Rusthon	200	0.0096473
Top	Rusthon	300	0.02153843
Top	Rusthon	400	0.02309247
Top	Rusthon	500	0.03899404

La red Neuronal artificial entrenada con los resultados de la simulaciones SPH se utilizó como modelo sustituto para obtener campos escalares de velocidad variando la posición del impulsor, en este trabajo se reportan dos posiciones, ambas intermedias entre las posiciones de las simulaciones, es decir, la primera

justo a la mitad de bottom y middle (z=-0.5), y la segunda justo a la mitad de middle y top (z=0.5). Los campos escalares de velocidad obtenidos por el modelo sustituto se muestran en la Figura 7.

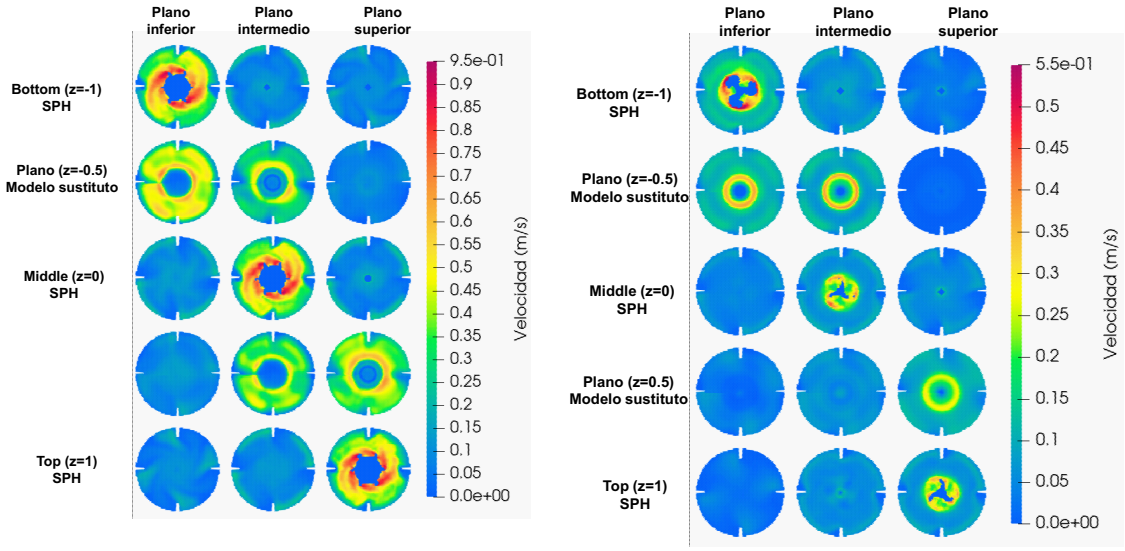


Figura 7. Campos de velocidad generados con el modelo sustituto con posiciones intermedias de los impulsores respecto a las posiciones simuladas con SPH para 500 rpm. A la izquierda se muestran los resultados para el impulsor Rushton y a la derecha para el Impulsor propela.

Con el modelo sustituto también se obtuvieron campos de velocidad para tres velocidades de agitación no simuladas 250rpm, 350rpm. Y 450 rpm. Los campos de velocidad obtenidos para estas velocidasdes se muestran en la Figura 8.

VOLUMEN 48
XXXI Verano De la Ciencia
ISSN 2395-9797
www.jovenesenlaciencia.ugto.mx

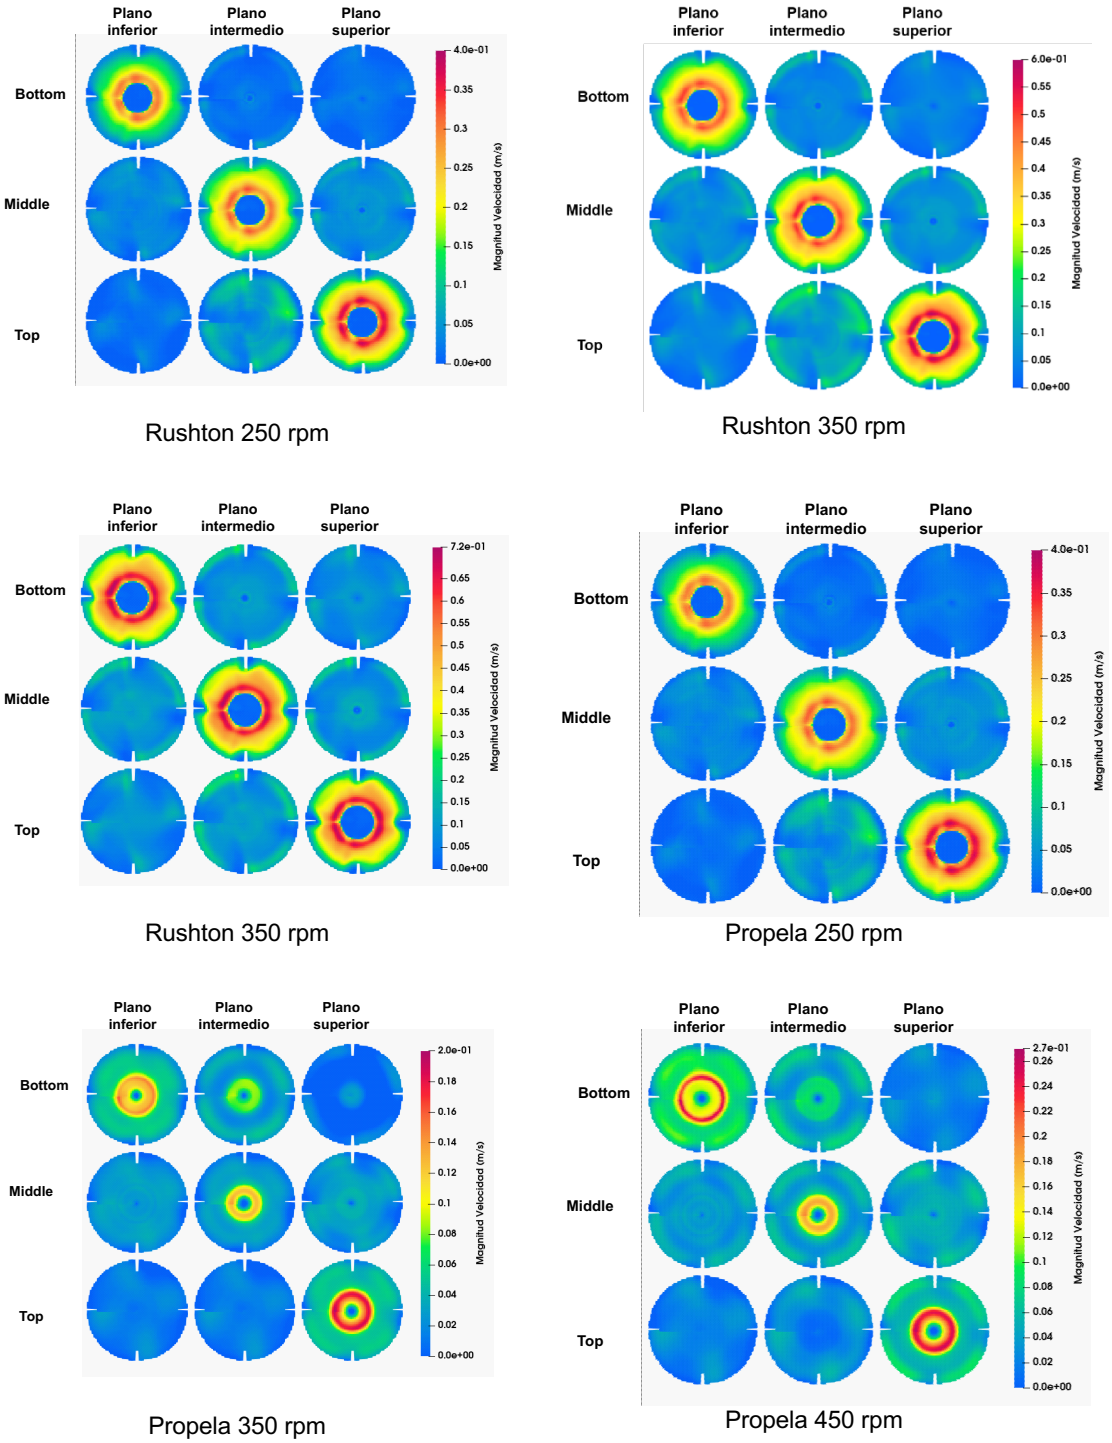


Figura 8. Campos de velocidad generados con el modelo sustituto para cada impulsor con velocidades de agitación de 250, 350 y 450 rpm.

Conclusiones

En este trabajo se demostró que es posible utilizar una red neuronal artificial como modelo sustituto para predecir campos de velocidad en tanques agitados a partir de datos generados mediante simulaciones CFD basadas en el método Smoothed Particle Hydrodynamics (SPH). Los resultados obtenidos muestran que la red neuronal fue capaz de reproducir adecuadamente los patrones hidrodinámicos asociados a diferentes velocidades de agitación, tipos de impulsor y posiciones axiales dentro del tanque, manteniendo niveles de error aceptables respecto a las simulaciones originales.

El análisis de convergencia permitió establecer que aproximadamente un millón de partículas es suficiente para obtener soluciones numéricas estables mediante SPH, garantizando así la calidad de los datos utilizados durante el entrenamiento. A partir de estas simulaciones se construyó una base de datos representativa del comportamiento hidrodinámico del sistema, la cual permitió entrenar exitosamente una arquitectura MLP de 9×256×256×128×64×1.

Los resultados de validación evidenciaron una buena capacidad de generalización del modelo, incluso para planos intermedios que no fueron incluidos durante el entrenamiento. Los errores RMSE obtenidos fueron bajos en la mayoría de los casos, con un valor máximo de 0.101, lo que confirma que la red neuronal logró capturar adecuadamente las relaciones entre las variables geométricas, operativas y el campo de velocidades generado por los impulsores.

Una de las principales contribuciones de esta investigación es la reducción drástica del tiempo de cálculo. Mientras que la generación de los datos mediante SPH requiere tiempos de simulación elevados, el modelo neuronal fue capaz de producir predicciones en aproximadamente 0.67 segundos, alcanzando una aceleración cercana a 9 391 veces respecto al método numérico utilizado para generar los datos de entrenamiento. Esta diferencia representa una ventaja significativa para tareas de diseño, optimización y análisis paramétrico de equipos de mezclado.

Además, el modelo sustituto mostró capacidad para interpolar condiciones no incluidas en el conjunto de entrenamiento, generando campos de velocidad para posiciones intermedias del impulsor y velocidades de agitación no simuladas previamente. Esto demuestra su potencial como herramienta predictiva para explorar nuevas condiciones operativas sin necesidad de ejecutar simulaciones CFD adicionales.

En conjunto, los resultados obtenidos confirman que la integración de técnicas de inteligencia artificial con herramientas de dinámica de fluidos computacional constituye una alternativa prometedora para acelerar el estudio de sistemas de mezclado. Como trabajo futuro, se propone ampliar la base de datos de entrenamiento incorporando más configuraciones geométricas, diferentes tipos de fluidos y regímenes de operación, con el fin de desarrollar modelos sustitutos con mayor capacidad de extrapolación y aplicabilidad industrial.

Referencias

Agonga, O. F., Othman, N., & Mohd Yasin, M. F. (2026). A hybrid CFD-neural network framework for the early prediction of longitudinal thermo-acoustic instabilities in hydrogen-fueled gas turbine combustors. *Next Energy*, 12, 100676. https://doi.org/10.1016/j.nxener.2025.100676

Domínguez, J. M., Fourtakas, G., Altomare, C., Canelas, R. B., Tafuni, A., García-Feal, O., Martínez-Estévez, I., Mokos, A., Vacondio, R., Crespo, A. J. C., Rogers, B. D., Stansby, P. K., & Gómez-Gesteira, M. (2022). DualSPHysics: from fluid dynamics to multiphysics problems. *Computational Particle Mechanics*, 9(5), 867-895. doi:10.1007/s40571-021-00404-2.

Ha, T. J., Kang, D. K., Min, J. H., Park, J. W., & Shin, J.-H. (2026). Optimization of heater configurations in single-phase immersion cooling systems using CFD-validated artificial neural networks. *Case Studies in Thermal Engineering*, 82, 108122. https://doi.org/10.1016/j.csite.2026.108122

Lázaro, D., Puente, E., Lázaro, M., Capote, J. A., & Alvear, D. (2013). Posibilidades de un modelo sustituto de incendios mediante el empleo de redes neuronales. *Revista Internacional de Métodos Numéricos para Cálculo y Diseño en Ingeniería*, 29(3), 103–111. https://doi.org/10.1016/j.rimni.2012.07.001

Liu, G., Zhao, H., Deng, J., Wang, L., & Zhang, H. (2023). Performance improvement of CO_2 two-phase ejector by combining CFD modeling, artificial neural network and genetic algorithm. *International Journal of Refrigeration,* 154, 151–167. https://doi.org/10.1016/j.ijrefrig.2023.07.005

Vahidi, M., Dolatshahi Pirooz, M. H., Nikoo, M. R., & Asgarinejad, M. (2026). Integration of CFD and one-dimensional convolutional neural networks for time-series prediction of hydrodynamic forces on double-layer perforated breakwaters. *Results in Engineering*, 30, 103969. https://doi.org/10.1016/j.rineng.2026.103969