

## Innovación en la optimización de turbinas hidráulicas: metodología basada en IA y CFD para la gestión de activos

Ruben Dario Aponte Nuñez  
Celsia Colombia S.A. E.S.P.  
Calle 15 No. 29B – 30 Autopista Cali - Yumbo  
E-mail: [raponte@celsia.com](mailto:raponte@celsia.com)  
Yumbo – Colombia

### Resumen

Las turbinas hidráulicas son componentes esenciales en las centrales hidroeléctricas, cuya eficiencia y desempeño pueden verse comprometidos por el desgaste erosivo, la cavitación y limitaciones en las tecnologías de manufactura que afectan la complejidad geométrica de sus componentes. Estas problemáticas incrementan los costos operativos y afectan la gestión de activos industriales. Este artículo presenta una metodología innovadora que combina Dinámica de Fluidos Computacional (CFD) y técnicas avanzadas de Inteligencia Artificial (IA), como Redes Neuronales Densas (ANN), Redes Neuronales Físicamente Informadas (PINN) y Algoritmos Genéticos (GA), para optimizar diseños de componentes críticos en turbinas hidráulicas.

La metodología se inicia con la simulación detallada de la geometría actual de la turbina mediante CFD, permitiendo caracterizar su comportamiento y validar modelos con datos experimentales. Posteriormente, se emplean técnicas de IA, como las ANN y los GA, para optimizar las geometrías de los álabes del rodete, logrando reducir significativamente el desgaste erosivo y mejorar la resistencia a la cavitación, mientras se mantiene la eficiencia operativa. Esta metodología destaca en su filosofía con respecto a otras metodologías de optimización de turbinas, añadiendo mayor coherencia y rapidez para la obtención de resultados prometedores.

Los resultados destacan que la aplicación de estas técnicas no solo incrementa la resistencia al desgaste y mejora la eficiencia, sino que también extiende los intervalos entre mantenimientos y optimiza los costos operativos. Esto representa una solución avanzada y efectiva para los desafíos de mantenimiento en plantas hidroeléctricas, integrando la inteligencia artificial en la optimización de activos industriales y contribuyendo al avance de la gestión de activos.

### Introducción

Las turbinas hidráulicas desempeñan un papel crítico en la generación de energía renovable, siendo componentes esenciales en las plantas hidroeléctricas. Sin embargo, su desempeño y longevidad suelen estar comprometidos por fenómenos como el desgaste erosivo y la cavitación, así como por limitaciones en los procesos de manufactura tradicionales que dificultaban la implementación de geometrías complejas en los perfiles de los álabes. Estas restricciones afectan su eficiencia y adaptabilidad a condiciones operativas exigentes, incrementando los costos operativos y reduciendo la eficiencia general del sistema. Estas problemáticas representan un desafío significativo dentro del ámbito de la gestión de activos industriales, donde se busca maximizar la vida útil de los equipos al tiempo que se optimizan los recursos [1].

El presente trabajo propone una metodología innovadora que combina la Dinámica Computacional de Fluidos (CFD) y técnicas de Inteligencia Artificial (IA), como las Redes

Neuronales Artificiales (ANN), Redes Neuronales Físicamente Informadas (PINN) y los Algoritmos Genéticos (GA), para abordar los retos de optimización de componentes críticos de turbinas hidráulicas. Las ANN se utilizan para modelar y predecir el comportamiento de los componentes bajo diferentes condiciones de operación, mientras que las PINN integran restricciones físicas directamente en el aprendizaje, garantizando modelos más precisos y consistentes con las leyes de la mecánica de fluidos. Por su parte, los GA generan y evalúan de forma eficiente configuraciones geométricas dentro de un espacio de diseño complejo, buscando maximizar la eficiencia hidráulica y minimizar el desgaste erosivo y la cavitación, con una menor dependencia de simulaciones completas.

Esta metodología propone una mayor coherencia y rapidez en comparación con enfoques previamente desarrollados [2], al enfatizar en la configuración inicial de una base de datos que permita entrenar modelos ANN de manera eficiente y realizar búsquedas óptimas con los GA, minimizando las iteraciones necesarias. El valor de esta metodología radica en su enfoque interdisciplinario, integrando herramientas avanzadas de simulación numérica y optimización basada en datos para desarrollar soluciones aplicadas a las turbinas hidráulicas. Este enfoque no solo responde a las demandas actuales de la industria energética, sino que también establece un precedente en la aplicación de IA en la gestión de activos. A través de su implementación, se espera aportar soluciones concretas a problemas operativos, aumentando los intervalos entre mantenimientos, disminuyendo los costos asociados y mejorando la confiabilidad de los sistemas.

En las secciones siguientes, se describe la metodología empleada, los resultados obtenidos y las implicaciones para la gestión de activos. Este trabajo busca ser una contribución significativa para los profesionales e investigadores interesados

en la intersección entre tecnologías emergentes y la optimización de sistemas industriales.

## Metodología

### Turbinas Hidráulicas

Las turbinas hidráulicas son máquinas diseñadas para transformar la energía potencial y cinética del agua en energía mecánica, que posteriormente se convierte en energía eléctrica mediante un generador. En este estudio, se analizaron turbinas Francis, ampliamente utilizadas en centrales hidroeléctricas debido a su capacidad de operar en una amplia gama de caudales y alturas de caída [3]. Estas turbinas, sin embargo, enfrentan problemas críticos como el desgaste erosivo y la cavitación, especialmente en entornos donde el agua contiene altos sedimentos y por la flexibilidad de generación que se requiere actualmente.




Figura 1. Modelo CAD de una turbina Francis.

El álabe del rodete, uno de los componentes principales de las turbinas Francis, fue el enfoque principal de este trabajo. Su diseño y optimización son cruciales para mejorar la eficiencia, reducir el desgaste y aumentar la vida útil de la turbina. Se utilizó un modelo digital del rodete basado en diseños existentes, que fue caracterizado mediante escaneos tridimensionales y datos geométricos provenientes de planos CAD [4].

### Dinámica de Fluidos Computacional (CFD)

El CFD se utilizó para analizar el comportamiento del flujo de agua dentro de la turbina. Con el método de volúmenes finitos se resuelven las

ecuaciones de Navier-Stokes de forma numérica para modelar las interacciones entre el fluido y las superficies sólidas de la turbina. Estas simulaciones permitieron identificar las áreas de mayor desgaste y los puntos de cavitación, así como evaluar la eficiencia hidráulica de las geometrías existentes.




Figura 2. Simulación CFD para una turbina Francis.

Se implementó un modelo bifásico para considerar la interacción entre el agua y las partículas sólidas presentes, utilizando el modelo de erosión de Tabakoff-Grand [5] para predecir la tasa de desgaste en los álabes. Además, se llevó a cabo una validación del modelo CFD mediante la comparación de los resultados de las simulaciones con datos experimentales obtenidos de pruebas en campo.

### Redes Neuronales Artificiales

Las redes neuronales artificiales (ANN) desempeñaron un papel clave en la optimización de las turbinas hidráulicas, especialmente en la predicción de los desempeños hidráulicos y mecánicos de diferentes diseños geométricos. Estas redes, entrenadas con un conjunto de datos generados a partir de simulaciones CFD y mediciones experimentales, se utilizaron para modelar relaciones complejas entre los parámetros geométricos de los álabes y su eficiencia, desgaste erosivo y resistencia a la cavitación.

El modelo ANN utilizado consistió en una arquitectura densa o de varias capas (multicapa), con funciones de activación no lineales que permitieron capturar la complejidad de las interacciones entre variables. Además, se implementó un proceso de validación cruzada para garantizar la generalización del modelo y evitar problemas de sobreajuste. El modelo proporcionó predicciones rápidas y precisas, lo que permitió evaluar más configuraciones en menos tiempo.

Por otro lado, se exploró el uso de redes neuronales físicamente informadas (PINN) para encontrar las constantes de ajuste del modelo de Tabakoff-Grand. Estas redes incorporaron datos experimentales de desgaste y las ecuaciones que describen el fenómeno, asegurando un ajuste preciso basado en las propiedades del acero CA6NM típico de turbinas y las condiciones del flujo con arena. Este enfoque permitió mejorar la predicción del desgaste erosivo en escenarios reales y apoyar la calibración del modelo.

### Algoritmos Genéticos

Los algoritmos genéticos (GA) desempeñaron un papel crucial en la optimización de las geometrías de los álabes del rodete, actuando como un motor de búsqueda eficiente dentro de un espacio de diseño complejo. Estos algoritmos se utilizaron para generar nuevas configuraciones de diseño que buscaban maximizar la eficiencia hidráulica y minimizar el desgaste erosivo y la cavitación.

El proceso comenzó con la generación de una población inicial de geometrías, algunas obtenidas mediante ajustes manuales y otras propuestas automáticamente por los GA. Las ANN se integraron en el flujo de trabajo para predecir rápidamente el desempeño de estas configuraciones sin necesidad de ejecutar simulaciones CFD completas. Esto permitió evaluar una mayor cantidad de soluciones en menos tiempo. Una vez identificadas las configuraciones prometedoras, estas se sometieron

a simulaciones CFD detalladas para validar su desempeño.

### Proceso Integrado de Optimización

La metodología propuesta se sintetiza en un flujo de trabajo iterativo que integra los enfoques descritos para lograr la optimización de geometrías de turbinas hidráulicas. En la Figura 3 se presenta un diagrama de flujo que resume las etapas principales del proceso, incluyendo la generación de geometrías, la evaluación mediante simulaciones CFD, el entrenamiento de la ANN y la optimización mediante GA. Este flujo asegura una integración eficiente de herramientas numéricas y técnicas de IA para alcanzar configuraciones óptimas en un tiempo reducido.

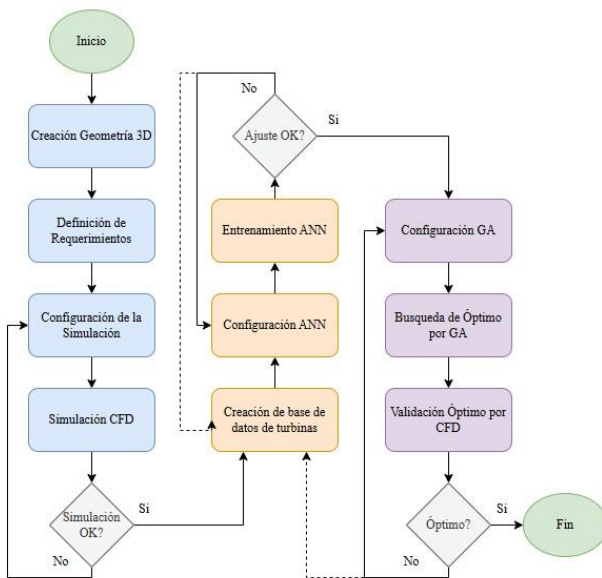


Figura 3. Metodología para la optimización de turbinas.

## Resultados

### Simulación CFD Inicial

Para la caracterización del fenómeno de desgaste erosivo en los álabes de las turbinas hidráulicas, se empleó el modelo de Tabakoff-Grand ajustado mediante una PINN. Esta integró los principios físicos del modelo en su función de pérdida y se

entrenó con datos experimentales reportados [6], logrando ajustar las constantes del modelo con alta precisión. La PINN se configuró con tres capas densas de 32 neuronas y funciones de activación tangente hiperbólica (*tanh*), mientras que la salida empleó una activación tipo *softplus* para garantizar valores positivos en las constantes ajustadas

La Figura 4 presenta la comparación entre los datos experimentales y los valores predichos por el modelo ajustado, mostrando una alta coherencia en los rangos críticos de ángulo de impacto. Este ajuste asegura que las simulaciones CFD reflejen con fidelidad los mecanismos de desgaste erosivo, proporcionando una base sólida para las siguientes etapas de optimización.

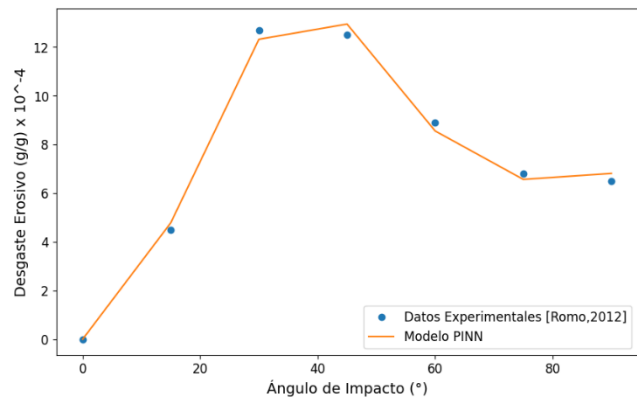


Figura 4. Comparación de Datos Experimentales y Modelo PINN.

Los resultados de las simulaciones CFD iniciales se basaron en las configuraciones geométricas reportadas en[1], empleando los parámetros ajustados del modelo de Tabakoff-Grand para evaluar el desempeño hidráulico de la turbina. Las simulaciones se llevaron a cabo para distintas condiciones de caudal, permitiendo calcular la eficiencia y la potencia generada en cada caso.

La Figura 5 presenta la comparación entre los resultados obtenidos por simulación CFD y los valores reales medidos en planta para la eficiencia y la potencia. Como se observa, los resultados CFD muestran una tendencia coherente con los datos reales, especialmente en rangos operativos de mayor caudal, validando la precisión del

modelo implementado. Estas comparaciones son clave para garantizar que el modelo CFD sirva como una base confiable para las etapas posteriores de optimización.

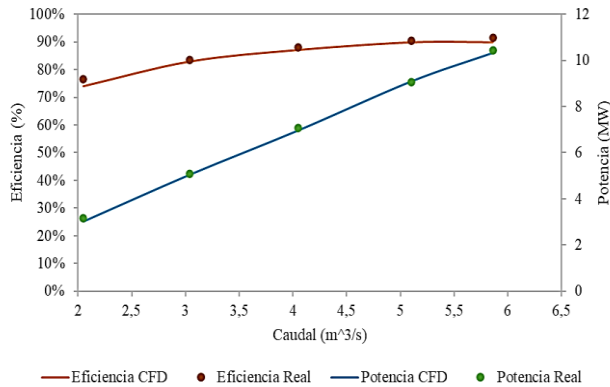


Figura 5. Comparación de la eficiencia y potencia reales y simulación CFD.

### Optimización de las Geometrías

Para optimizar las geometrías de las turbinas, se entrenó un modelo de ANN con tres capas densas de 50 neuronas, activación ReLU y regularización  $L2$  para prevenir sobreajuste, que permitió predecir con alta precisión las funciones objetivos planteadas en [2] para el desempeño hidráulico y mecánico de las configuraciones evaluadas. La Figura 6 muestra la comparación entre las predicciones del modelo y los valores reales, obteniendo un coeficiente de determinación de 0.982 y un error cuadrático medio (MSE) de 0.0074. Este nivel de precisión valida la capacidad del modelo ANN para capturar las complejas relaciones entre los parámetros geométricos y las métricas de desempeño. Para este análisis, se utilizaron 77 geometrías, dividiendo los datos en un 80% para entrenamiento y un 20% para prueba, lo que aseguró la generalización y robustez del modelo.

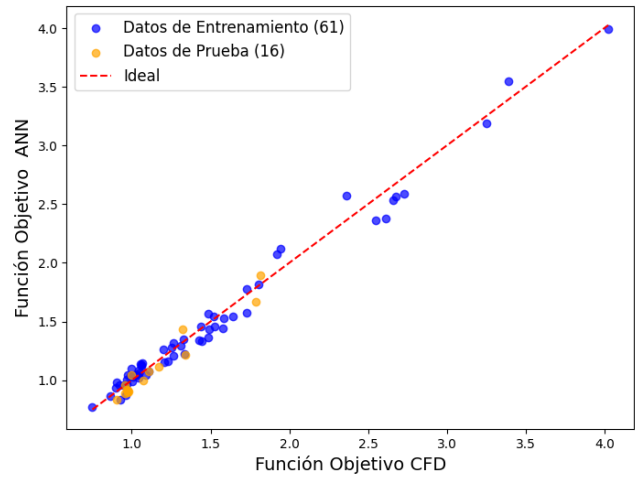


Figura 6. Comparación entre predicciones del modelo ANN y valores simulados por CFD.

Una vez se tiene el modelo de ANN, se empleó un GA para optimizar la geometría de la turbina, explorando un espacio de diseño definido por nueve parámetros geométricos clave. La función de aptitud se basó en minimizar los valores de función objetivo predichos por el modelo de ANN, permitiendo evaluar rápidamente múltiples configuraciones. A lo largo de 100 generaciones, el GA utilizó operadores de cruce y mutación para refinar las soluciones, logrando una convergencia hacia configuraciones óptimas. La Figura 7 muestra la evolución de la aptitud de la función objetivo, destacando una rápida mejora en las primeras generaciones. Este enfoque permitió identificar geometrías óptimas con una reducción significativa en el tiempo de cálculo requerido.

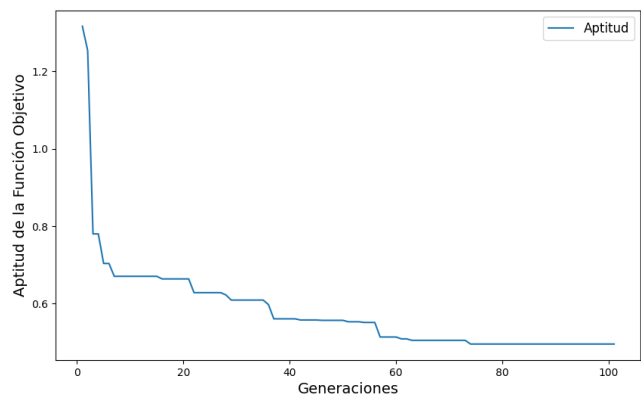


Figura 7. Evolución de la función objetivo a lo largo de las generaciones del GA.

## Comparativo entre modelo CFD Original y CFD Optimizado

El análisis comparativo entre el modelo CFD original y el optimizado evidencia mejoras significativas en la resistencia al desgaste erosivo, mientras que las condiciones de eficiencia y potencia de salida se mantienen constantes, como se muestra en la Figura 8. Las simulaciones se realizaron bajo las mismas condiciones operativas, permitiendo evaluar el impacto de las geometrías optimizadas sobre parámetros clave como eficiencia, potencia generada y tasa de desgaste.

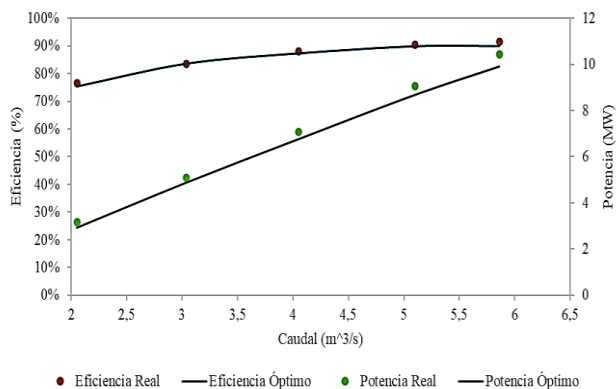


Figura 8. Comparación de eficiencia y potencia entre el modelo original y el optimizado.

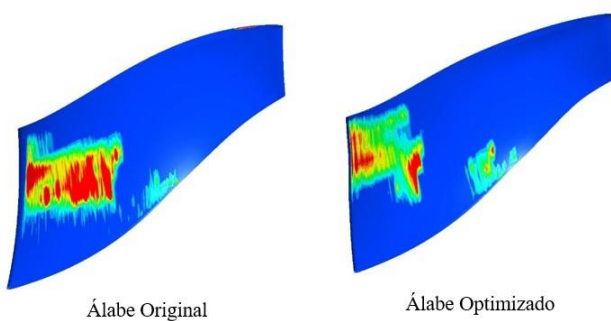


Figura 9. Distribución de densidad de erosión en los álabes (original vs. optimizado).

En cuanto al desgaste erosivo, los resultados presentados en la Figura 9 destacan una reducción significativa en las áreas críticas de los álabes, como lo evidencia la densidad de erosión visualizada en el modelo CFD. La optimización geométrica redistribuye el flujo, minimizando el

impacto de partículas erosivas sobre las superficies más vulnerables.

Finalmente, la Figura 10 muestra cómo la tasa de desgaste en función de la potencia se reduce considerablemente en el modelo optimizado, logrando valores mucho más bajos que en el modelo original en potencias bajas o carga parcial. Esto no solo mejora la durabilidad de los componentes, sino que también reduce los costos asociados al mantenimiento y reemplazo.

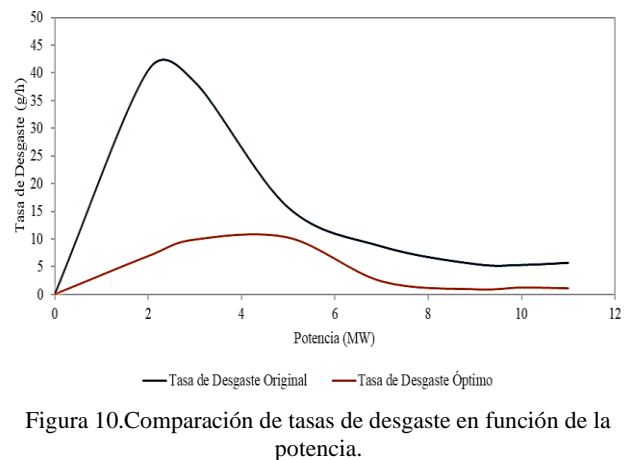


Figura 10. Comparación de tasas de desgaste en función de la potencia.

## Impacto en la Gestión de Activos y Mantenimiento

La metodología propuesta no solo demostró mejoras significativas en la resistencia al desgaste y la confiabilidad de las turbinas hidráulicas, sino también un impacto directo en la gestión de activos y las estrategias de mantenimiento.

La Figura 11 compara los tiempos y recursos requeridos por la metodología propuesta frente a estudios previos. Se observa una reducción sustancial en el tamaño de la base de datos de geometrías (de 156 a 77) y en los tiempos de simulación CFD (de 546 a 270 horas). Esto refleja una optimización de los recursos computacionales. Además, los tiempos de entrenamiento para las redes neuronales y los algoritmos genéticos se redujeron drásticamente, pasando de 133 minutos a solo 2 minutos, lo que disminuye

considerablemente el tiempo efectivo requerido para completar el ciclo de optimización, de 69 a 34 horas laborales.

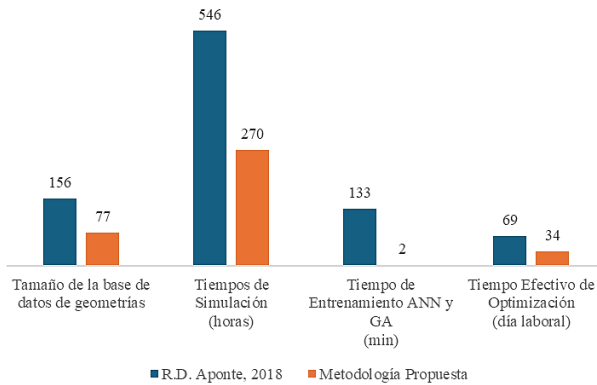


Figura 11. Comparación de tiempos y recursos requeridos: Metodología Propuesta vs. Estudio Previo.

Por otro lado, la Figura 12 evalúa el impacto de las geometrías optimizadas en la confiabilidad de los componentes. El rodete optimizado mostró un aumento notable en el Tiempo Medio Entre Fallos (MTBF) teórico, pasando de 21633 a 89173 horas, es decir, más de 4 veces. Este incremento sustancial, evidencia una mayor vida útil del rodete optimizado y una reducción significativa en la necesidad de mantenimientos no planificados.

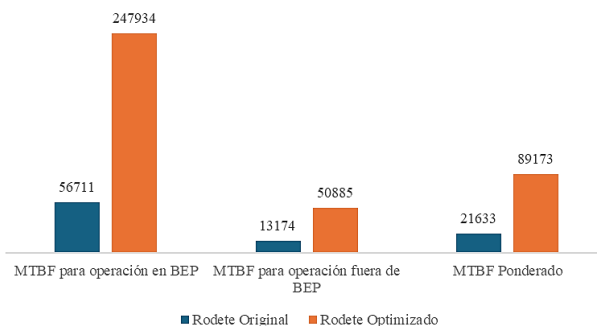


Figura 12. Tiempo Medio Entre Fallos (MTBF): Rodete Original vs. Rodete Optimizado.

En conjunto, los resultados demuestran que la metodología propuesta no solo mejora la eficiencia en el proceso de optimización, sino que también contribuye directamente a la reducción de costos operativos, incrementa la confiabilidad del sistema y apoya estrategias de mantenimiento más eficientes y sostenibles. Estos avances posicionan

a la metodología como una herramienta clave en la gestión de activos en sistemas hidroeléctricos modernos.

## Conclusiones

La metodología propuesta, que integra el CFD y técnicas avanzadas de IA, como las ANN, PINN y los GA, ha demostrado ser una solución innovadora y efectiva para optimizar componentes críticos de turbinas hidráulicas. Este enfoque interdisciplinario no solo permite abordar de manera eficiente los desafíos operativos relacionados con el desgaste erosivo y la cavitación, sino que también mejora significativamente la confiabilidad y la sostenibilidad en la gestión de activos hidroeléctricos.

Los resultados obtenidos destacan mejoras notables en la resistencia al desgaste y la durabilidad de los componentes, manteniendo la eficiencia hidráulica y la potencia generada. Además, la reducción en el tiempo y los recursos computacionales requeridos para las simulaciones y optimizaciones resalta la eficiencia del proceso, logrando extender los intervalos entre mantenimientos y reducir costos operativos. Estas mejoras incluyen un incremento significativo en el Tiempo Medio Entre Fallos (MTBF) teórico, lo que refuerza la confiabilidad del sistema y apoya la implementación de estrategias de mantenimiento más sostenibles y económicas.

Finalmente, esta metodología establece un precedente en la aplicación de tecnologías emergentes como la IA en la optimización de activos industriales, alineándose con las necesidades de modernización de la industria energética. A través de esta integración, no solo se responden a los desafíos actuales, sino que también se fomenta la innovación tecnológica en el diseño, operación y mantenimiento de sistemas hidroeléctricos. Este trabajo abre la puerta a nuevas investigaciones que exploren aplicaciones más amplias en el sector energético e industrial.

## Bibliografía

- [1] L. A. Teran *et al.*, "Analysis of economic impact from erosive wear by hard particles in a run-of-the-river hydroelectric plant", *Energy*, vol. 113, pp. 1188–1201, 2016.
- [2] R. D. Aponte *et al.*, "Minimizing erosive wear through a CFD multi-objective optimization methodology for different operating points of a Francis turbine", *Renew Energy*, vol. 145, pp. 2217–2232, ene. 2020.
- [3] C. Mataix Plana, *Turbomáquinas hidráulicas: turbinas hidráulicas, bombas, ventiladores*. Universidad Pontificia Comillas, 2009.
- [4] P. P. Gohil y R. P. Saini, "CFD: Numerical analysis and performance prediction in Francis turbine", *Proceedings of 2014 1st International Conference on Non Conventional Energy: Search for Clean and Safe Energy, ICONCE 2014*, pp. 94–97, 2014.
- [5] ANSYS, *ANSYS CFX-Solver Theory Guide*. 2021.
- [6] S. A. Romo, J. F. Santa, J. E. Giraldo, y A. Toro, "Cavitation and high-velocity slurry erosion resistance of welded Stellite 6 alloy", *Tribol Int*, vol. 47, pp. 16–24, 2012.

Ruben Dario Aponte Nuñez: Ingeniero Mecánico con un magíster en Ingeniería y especialista en Automatización Industrial de la Universidad del Valle y magister en Inteligencia Artificial de la Universidad Internacional de la Rioja. Actualmente trabaja en el área de gestión técnica mecánica en la Gerencia de Generación de Celsia. Cuenta con experiencia en proyectos de actualización tecnológica y mantenimiento mecánico en centrales hidráulicas.

Celsia Colombia S.A. E.S.P.

Calle 15 No. 29B-30 Autopista Cali –Yumbo

E-mail: [raponte@celsia.com](mailto:raponte@celsia.com)

Cali - Colombia