

Comunicación al Editor

Integración de CFD, Análisis Dimensional y Estadística en la Optimización de Turbinas Hidrocinéticas

Gustavo José Marturet Pérez¹  Gustavo Elías Marturet García² 

¹ Universidad Politécnica Territorial del Estado Bolívar-Venezuela (UPTeB).

² Universidad de Los Andes (ULA), Venezuela. Facultad de Ciencias Económicas y Sociales. Economía. Mérida, 5101, Venezuela.

marturetg@gmail.com

<https://doi.org/10.22209/rt.v48a05>

Ante la creciente demanda de energía y la necesidad de alcanzar zonas geográficamente aisladas, la tecnología ha desarrollado las turbinas hidrocinéticas. Estos dispositivos versátiles captan la energía cinética de las corrientes de agua, convirtiéndola en una solución energética viable y sostenible para diversos entornos. MeyGen en Escocia, es una planta de energía con aplicación de turbinas hidrocinéticas alcanzando hasta 50GW de electricidad generada. En las costas de Ouessant, en Bretaña-Francia, turbinas hidrocinéticas aportan hasta 25% de la electricidad consumida por los lugareños. En su investigación Marturet (2022) muestra algunos tipos de estas turbinas hidrocinéticas (Marturet et al., 2022).

Saini y Saini (2019) desarrollan una importante y profunda revisión de distintos rotores de turbinas hidrocinéticas. También, Jayaram y Bavanish (2021) en su trabajo sobre un modelo de turbinas hidrocinéticas, la Gorlov, analizan varios enfoques de diseño y simulación de turbinas Gorlov.

Para el desarrollo de turbinas hidrocinéticas con miras a lograr mayores eficiencias energéticas es necesario la aplicación de técnicas de dinámica de fluidos computacionales (CFD) y de metodologías de análisis numérico con técnicas de simulación (Marturet et al., 2023) como alternativa frente a costos importantes en la experimentación con fluidos para determinar potenciales de energía.

Este artículo tiene como objetivo principal analizar la integración de CFD, el análisis dimensional, a través del teorema π de Buckingham, y la Estadística en el proceso de optimización de turbinas hidrocinéticas. Asimismo, se presenta una revisión de la literatura existente en torno a estas metodologías y su aplicación en el desarrollo de turbinas hidrocinéticas, con miras a construir un marco teórico que sirva de base para futuras investigaciones en el área.

No se deja de reconocer que las tecnologías de turbinas hidrocinéticas se han beneficiado significativamente de la aplicación de CFD, el análisis dimensional y la estadística, pero también, la integración de la inteligencia artificial (IA) en este campo específico, representa un enfoque relativamente novedoso. Esta investigación, también explora cómo la aplicación de técnicas de IA, incluyendo el aprendizaje automático y el aprendizaje profundo, puede llevar a avances significativos en el diseño, la optimización y el control de turbinas hidrocinéticas. La capacidad de la IA para manejar grandes volúmenes de datos, identificar patrones complejos y realizar optimizaciones no lineales ofrece nuevas oportunidades para mejorar la eficiencia, el rendimiento y la adaptabilidad de estos sistemas energéticos, abriendo caminos para futuras investigaciones y desarrollos en el área.

Los análisis de CFD procesan grandes volúmenes de datos para determinar campos de velocidades, vorticidad, presión y esfuerzos turbulentos en turbinas. También calculan los esfuerzos de corte en las superficies de los álabes, incluyendo sus componentes de arrastre y sustentación. Además, el CFD estudia variables de flujo como velocidad, turbulencia, fuerza y presión. Al mismo tiempo, proporciona resultados de variables geométricas, como los coeficientes de sustentación y arrastre de los álabes de turbina en relación con variaciones en el ángulo de ataque, el espesor y la curvatura de sus perfiles (Marturet et al., 2023).

El apoyo en CFD permite desarrollar estudios de optimización (Li et al. 2023) y obtener rendimientos asociados a coeficientes de potencia y eficiencia, torque y velocidad de rotación de la turbina hidrocínética y fenómenos de cavitación (Marturet et al., 2022), vibraciones, ruido y pérdidas energéticas (Etemadeasl et al., 2024) en turbinas. De tal modo que el manejo de variables de flujo, geométricas y de rendimiento entre otras durante la experimentación con CFD de turbinas hidrocínéticas resulta en un volumen considerable de datos.

Por otra parte, teorema π de Buckingham es una herramienta fundamental en el análisis dimensional de turbinas y su escalamiento con miras al logro de la optimización y mejora del rendimiento (Li et al., 2023). El uso del teorema permite: simplificar ecuaciones asociadas al flujo de fluidos sobre rotores de turbinas, análisis de similitud entre modelos y prototipos, escalamiento de modelos, optimización de geometrías de turbinas, elaboración de curvas características, construcción de funciones objetivo en potenciales energéticos (Surulere et al., 2024) y el desarrollo de modelos empíricos para predecir el comportamiento de turbinas en diferentes condiciones de operación.

La Estadística es una herramienta fundamental para el manejo de datos generados por la CFD en el desarrollo de turbinas hidrocínéticas. Su aplicación abarca varios aspectos clave. En primer lugar, se utiliza en el diseño y optimización de las turbinas. Permite analizar datos experimentales para identificar tendencias en la eficiencia y establecer relaciones que conduzcan a la optimización entre variables. Además, contribuye a la reducción de las incertidumbres inherentes a los modelos numéricos y experimentales propios de la CFD. En segundo lugar, la Estadística es crucial para la evaluación del desempeño en la producción de energía. Esto implica la comparación de modelos numéricos con datos experimentales reales. La verificación y validación de los modelos numéricos son características de los estudios de sensibilidad del mallado del dominio computacional, los cuales buscan un ajuste preciso entre los modelos computacionales y los datos experimentales. Finalmente, la Estadística es indispensable para el desarrollo de modelos predictivos que describan el comportamiento operacional de la turbina. En tal sentido, Marturet (2019) investigó la mejora del rendimiento de turbinas hidrocínéticas Gorlov. Desarrolló un modelo CFD para predecir su rendimiento y empleó análisis de componentes principales para identificar las variables más influyentes: la relación de solidez y la relación de velocidad. Además, creó relaciones semiempíricas para predecir el torque y el coeficiente de la turbina.

Para el desarrollo de turbinas hidrocínéticas, el teorema π de Buckingham y la Estadística son fundamentales. El primero ofrece una base teórica para el análisis dimensional y modelos físicos, mientras que la Estadística permite analizar datos, construir modelos y evaluar la incertidumbre en CFD. Estos enfoques tradicionales han sido cruciales para el diseño y optimización de turbinas, incluidas las de Gorlov.

El campo de la ingeniería de fluidos está experimentando una transformación significativa gracias a la integración de la IA. La IA ofrece múltiples oportunidades para avanzar en esta disciplina. Por ejemplo, permite un modelado de turbulencia mejorado, lo que conduce a simulaciones mucho más precisas. Además, la IA facilita la generación de mallas inteligentes, que tienen la capacidad de adaptarse al flujo, y contribuye a la aceleración de las simulaciones, lo cual es crucial para el diseño y la optimización. También es una

herramienta poderosa en la optimización del diseño en sí mismo. Finalmente, la IA es fundamental para el control de flujo activo, ya que permite el análisis de datos de sensores y la toma de decisiones en tiempo real, así como la detección de anomalías en los sistemas fluidodinámicos.

Jia y Xu (2024) exploraron estrategias óptimas de paralelización para el control de flujo activo basado en aprendizaje por refuerzo profundo en CFD, buscando mejorar la eficiencia computacional en entornos de alto rendimiento. Paralelamente, Amran et al. (2024) propusieron un enfoque híbrido de visión por computadora y aprendizaje automático para la detección robusta de núcleos de vórtices, un elemento fundamental en el análisis de flujos.

Así mismo, Esfahanian, et al. (2024) investigaron el uso de modelos surrogados basados en aprendizaje profundo para la optimización de la forma de turbinas de gas, ofreciendo una alternativa computacionalmente eficiente a las simulaciones tradicionales. Esta tendencia también se observa en el diseño de energías renovables. Al Noman et al. (2022) analizaron las tendencias y el marco del uso de la inteligencia artificial en el diseño de álabes para la próxima generación de turbinas eólicas Savonius, resaltando el potencial de la IA para mejorar su eficiencia.

Una perspectiva general sobre el impacto del aprendizaje por refuerzo profundo en la mecánica de fluidos es presentada por Kim et al. (2024), quienes revisaron sus aplicaciones en control, optimización y automatización. Finalmente, la modelización de flujos cercanos a la pared en CFD, un área tradicionalmente desafiante, también se está transformando con la aplicación del aprendizaje automático, como se discute en el trabajo de Olausson (2024).

La integración de métodos tradicionales como el análisis dimensional y la Estadística con los modelos CFD, junto a la creciente implementación de la IA, está impulsando avances significativos en la modelización, simulación y optimización de flujos de fluidos. Esta sinergia de enfoques potencia el diseño de sistemas de ingeniería más eficientes y sostenibles, incluyendo las turbinas hidrocinéticas. Sin embargo, es crucial reconocer que se necesita más investigación para comprender a fondo los fenómenos físicos y desarrollar modelos aún más precisos, donde la IA jugará un papel central.

Referencias bibliográficas

- Al Noman, A., Tasneem, Z., Sahed, M. F., Muyeen, S. M., Das, S. K., & Alam, F. (2022). Towards next generation Savonius wind turbine: Artificial intelligence in blade design trends and framework. *Renewable and Sustainable Energy Reviews*, 168, 112531.
- Amran Abolholl, H. A., Teschner, T. R., & Moulitsas, I. (2024). A hybrid computer vision and machine learning approach for robust vortex core detection in fluid mechanics applications. *Journal of Computing and Information Science in Engineering*, 24(6).
- Esfahanian, V., Izadi, M. J., Bashi, H., Ansari, M., Tavakoli, A., & Kordi, M. (2024). Aerodynamic shape optimization of gas turbines: a deep learning surrogate model approach. *Structural and Multidisciplinary Optimization*, 67(1), 2.
- Etemadeasl, V., Esmaelnajad, R., Gharlai, K., & Riasi, A. (2024). Application of Entropy Production Theory for Evaluating the Performance of a Gorlov Hydrokinetic Turbine. *Iranian Journal of Science and Technology, Transactions of Mechanical Engineering*, 1-20.

Jayaram, V., & Bavanish, B. (2021). A brief review on the Gorlov helical turbine and its possible impact on power generation in India. *Materials Today: Proceedings*, 37, 3343-3351.

Jia, W., & Xu, H. (2024). Optimal parallelization strategies for active flow control in deep reinforcement learning-based computational fluid dynamics. *Physics of Fluids*, 36(4).

Kim, I., Jeon, Y., Chae, J., & You, D. (2024). Deep reinforcement learning for fluid mechanics: Control, optimization, and automation. *Fluids*, 9(9), 216.

Li, G., Wu, G., Tan, L., & Fan, H. (2023). A Review: Design and Optimization Approaches of the Darrieus Water Turbine. *Sustainability*, 15(14), 11308.

Marturet, G. (2019). *Modelación fluidodinámica de turbinas Gorlov para la mejora de su rendimiento*. Tesis doctoral. Puerto Ordaz: UNEXPO.

https://www.researchgate.net/publication/345356850_Modelacion_fluidodinamica_de_turbinas_Gorlov_para_la_mejora_de_su_rendimiento

Marturet Pérez, G. J., Marturet García, G. E., & Torres Monzón, C. F. (2022). Análisis CFD en Régimen Transitorio para la Determinación de Cavitación en Turbinas Helicoidales Gorlov. *Revista Técnica de la Facultad de Ingeniería de la Universidad del Zulia*, 45(2).

Marturet Pérez, G. J., Marturet García, G. E., Guerra Silva, R. A., Josefina Torres, M., & Torres Monzón, C. F. (2023). Análisis CFD sobre la Influencia del Ángulo de Ataque en el Coeficiente de Potencia de Turbinas Helicoidales Gorlov. *Revista Técnica de la Facultad de Ingeniería de la Universidad del Zulia*, 46.

Olausson, R. (2024). Wall modeled computational fluid dynamics using machine learning. Using CFD coupled machine learning to create wall models for increased LES knowledge for future industrial use. <https://odr.chalmers.se/items/89db12c8-7349-4ab2-b8fe-d633ae3d12bc>

Saini, G., & Saini, R. P. (2019). A review on technology, configurations, and performance of cross-flow hydrokinetic turbines. *International Journal of Energy Research*, 43(13), 6639-6679.

Surulere, S. A., Shatalov, M. Y., & Olayiwola, F. E. (2024). Extensive Study of Modern Approaches Used in Identifying the Buckingham Potential. *International Journal of Applied and Computational Mathematics*, 10(1), 22.