

Resultados Preliminares de la Creación de una Base de Datos de Flujo Óptico en Reactores Electroquímicos: Una Herramienta para el Desarrollo y Evaluación de Algoritmos de Deep Learning

Preliminary Results of the Creation of an Optical Flow Database in Electrochemical Reactors: A Tool for the Development and Evaluation of Deep Learning Algorithms

Daniel A. Gutiérrez-Jiménez¹, Sebastián Salazar-Colores¹, Fernando F. Rivera², José Trinidad López-Maldonado³

¹ Centro de Investigaciones en Óptica (CIO), León 37150, México.

² Centro de Investigación y Desarrollo Tecnológico en Electroquímica (CIDETEQU), Querétaro 76703, México.

³ Universidad Politécnica de Querétaro (UPQ), Querétaro 76240, México.

daniel.gutierrez@cio.mx¹ sebastian.salazar@cio.mx¹

Resumen

En el ámbito de los reactores electroquímicos, la precisión en el cálculo del flujo óptico es esencial para entender con profundidad los fenómenos dinámicos internos. Estos fenómenos son críticos para el diseño y optimización de dichos reactores. En este trabajo son mostrados resultados preliminares de la creación de una base de datos de flujo óptico sintético, específicamente planteada para reactores electroquímicos, generada a través de simulaciones realizadas en Blender. La base de datos tiene como objetivo primordial facilitar el desarrollo de algoritmos de deep learning enfocados en la estimación precisa del flujo óptico y, adicionalmente, servir como punto de referencia para evaluar la eficacia de estos algoritmos. Con esta herramienta, se busca avanzar en el campo de la electroquímica, ofreciendo un recurso valioso que potencialmente puede superar las limitaciones actuales y promover una mayor eficiencia en el diseño y operación de reactores electroquímicos.

Palabras clave: Flujo óptico, Reactores electroquímicos, Simulación en Blender, Bases de datos para deep learning.

Introducción

En aplicaciones industriales y de investigación, los reactores electroquímicos han sido identificados como sistemas complejos donde los fenómenos hidrodinámicos desempeñan un papel fundamental. Estos fenómenos, que determinan la distribución de las sustancias reactivas, están estrechamente relacionados con la eficiencia de los procesos electroquímicos. Técnicas como la velocimetría de imagen de partículas (PIV) (Lagemann, Lagemann, Mukherjee & Schröder, 2021) y la dinámica de fluidos computacional (CFD) (Zawawi, Saleha, Salwa, Hassan, Zahari, Ramli & Muda, 2018) han sido empleadas históricamente para la caracterización de estos sistemas.

Ante la necesidad de herramientas que ofrezcan una caracterización más precisa debido a la complejidad y variabilidad de los flujos en reactores electroquímicos, la importancia de comprender detalladamente estos patrones de flujo se hace evidente (Catañeda, Rivera, Pérez & Nava, 2019). Se reconoce que este entendimiento tiene impactos significativos en la eficiencia y sostenibilidad de los procesos, con repercusiones en términos económicos y de rendimiento a nivel industrial.

En el ámbito actual, se han empleado métodos basados en el cálculo del flujo óptico, como el algoritmo de Gunnar Farneback (López-Maldonado, Salazar-Colores, Piedra & Rivera, 2023), para caracterizar el flujo óptico. A pesar de ser un algoritmo versátil, su naturaleza general a veces no produce resultados óptimos en sistemas específicos como los reactores electroquímicos.

Hoy en día, el aprendizaje profundo es reconocido como una tecnología destacada en visión artificial, especialmente en áreas como el flujo óptico (Mendes, Mendes, Coimbra & Crisóstomo, 2019). Esta tecnología



usa redes neuronales complejas y ha demostrado ser mejor que muchos métodos antiguos en precisión y adaptabilidad. Pero el éxito de estos algoritmos depende mucho de la calidad y cantidad de datos que tienen para entrenarse. Es crucial contar con bases de datos confiables y bien detalladas para desarrollar algoritmos de aprendizaje profundo efectivos. Estas bases no solo ayudan en el entrenamiento, sino que también son esenciales para probar y asegurarse de que los modelos funcionen bien antes de usarlos en situaciones reales.

En la literatura existen distintas bases de datos, tales como Middlebury Flow Dataset, KITTI Optical Flow 2015 del Karlsruhe Institute of Technology y el Toyota Technological Institute at Chicago (Ver Figura 1), sin embargo, estas se centran en aplicaciones como la conducción autónoma y escenas urbanas (*Middlebury College, s.f.*)(Menze & Geiger, 2015).

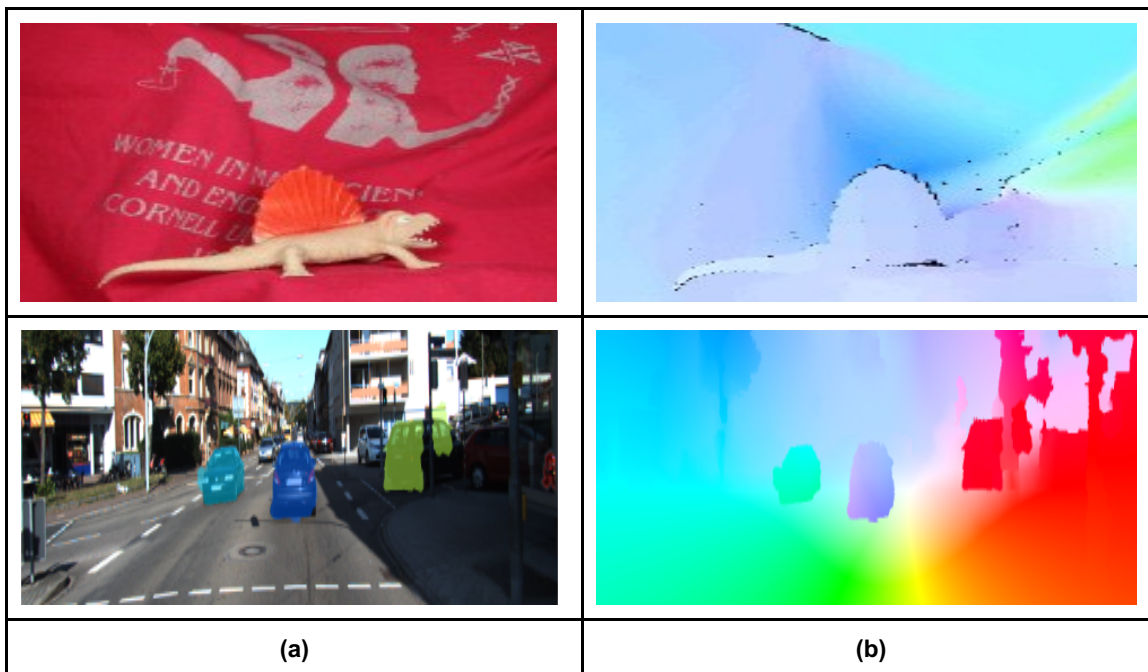


Figura 1. En esta figura, se presentan las imágenes originales de los conjuntos de datos Middlebury Flow y KITTI Optical Flow en la columna (a), mostrando las imágenes antes de calcular el flujo óptico. En la columna (b), se muestran las mismas imágenes con el flujo óptico correspondiente calculado. Estos datos son fundamentales para la evaluación y mejora de algoritmos de flujo óptico en diversas aplicaciones, como la conducción autónoma y la visión por computadora (*Middlebury College, s.f.*) (Menze & Geiger, 2015).
Fuente: (*Middlebury College, s.f.*) (Menze & Geiger, 2015)

Ante estas limitaciones y considerando el potencial del aprendizaje profundo, se propone la creación de una base de datos de flujo óptico específica para estos reactores. Esta nueva base de datos se diseñará para ser un pilar fundamental en el entrenamiento y validación de futuros algoritmos basados en aprendizaje profundo. La generación de estos datos sintéticos pueden ser simuladas en Blender, ya que recientes estudios sugieren que este tipo de bases de datos juegan un rol significativo para el desarrollo de tecnologías que emplean el aprendizaje profundo (Károly & Galambos, 2022), donde se incorpora física muy similar a las reales. Esta estrategia permitirá obtener datos sintéticos en escenarios controlados y reproducibles, lo que adecuadamente refleja la complejidad inherente a los reactores electroquímicos.

En última instancia, esperamos que esta iniciativa no solo mejore la precisión y adaptabilidad de los algoritmos a las particularidades de estos sistemas, sino que también proporcione una herramienta valiosa para avanzar en el campo de la electroquímica y fomentar la innovación en el diseño y operación de los reactores electroquímicos.

El presente artículo se estructura de la siguiente manera: en la sección 2, los Fundamentos teóricos que sustentan la investigación son presentados, en la sección 3 la Metodología empleada para la obtención de

Resultados Preliminares para la creación de la base de datos es detallada; en la sección 3, los Resultados obtenidos serán presentados y discutidos; y en la sección 4, se abordarán las Conclusiones y sugerencias para investigaciones futuras.

Fundamentos teóricos

En esta sección, se abordan los fundamentos teóricos que sustentan la investigación, destacando la importancia de los electrodos de placa plana en procesos electroquímicos y su relevancia en industrias como la química y la farmacéutica. Se exploran herramientas analíticas avanzadas como la Dynamics de Fluidos Computacional (CFD), la Velocimetría de Imagen de Partículas (PIV) y la Visión Artificial basada en Flujo Óptico. También se enfatiza el potencial del flujo óptico para analizar dinámicas en reactores y el emergente rol del aprendizaje profundo en identificar patrones complejos. Finalmente, se destaca la adaptabilidad de Blender, tradicionalmente un software de animación, como herramienta de simulación en este contexto.

1. Electroodos de Placas paralelas en Procesos Electroquímicos

Los electrodos de placa plana desempeñan un papel crítico en múltiples procesos electroquímicos, siendo preferidos por su versatilidad y múltiples ventajas inherentes. Su diseño sencillo facilita un mantenimiento de bajo costo, garantiza una distribución uniforme de potencial y corriente y permite una fácil adaptación a diferentes arquitecturas de electrodos. Además, pueden incorporar separadores en forma de red o mezcladores estáticos estructurados, optimizando así el transporte de masa a la superficie del electrodo. Estos electrodos son fundamentales en la producción de cloro y sosa cáustica, una técnica que transforma el agua salada en estos dos compuestos esenciales. Además, tienen un papel crucial en la manufactura farmacéutica, donde se utilizan en la producción de distintos medicamentos. En el ámbito del tratamiento del agua, son herramientas esenciales para la eliminación de metales pesados, contaminantes orgánicos y patógenos. Además, su utilidad se extiende a la industria de baterías, siendo componentes clave en baterías de plomo-ácido, níquel-cadmio y litio-ion, así como en celdas de combustible (López-Maldonado, Salazar-Colores, Piedra & Rivera, 2023).

Con los avances tecnológicos y las demandas cambiantes de la industria, ha surgido la necesidad de explorar y adaptar diseños de reactores específicos para diferentes procesos electroquímicos. Específicamente, en aquellos reactores que emplean electrodos de placa plana, la implementación de distribuidores de flujo se ha vuelto esencial. Aquí es donde la Dynamics de Fluidos Computacional (CFD) y la Velocimetría de Imagen de Partículas (PIV) y recientemente algoritmos basados en flujo óptico desempeñan un papel crucial.

a. Computational Fluid Dynamics (CFD)

La Dinamica de Fluidos Computacional (CFD) es una rama de la mecánica de fluidos que utiliza algoritmos numéricos y análisis matemático para resolver y analizar problemas asociados con el flujo de fluidos. Mediante el uso de CFD, es posible predecir el comportamiento del flujo, la transferencia de calor, y otras fenomenologías relacionadas en un sistema o proceso determinado (Zawawi, Saleha, Salwa, Hassan, Zahari, Ramli & Muda, 2018).

b. Particle Imaging Velocimetry (PIV)

La Velocimetría por Imágenes de Partículas es una técnica en la mecánica experimental de fluidos que utiliza partículas trazadoras iluminadas por láser para medir las componentes de velocidad en un campo de flujo. Es una técnica óptica no intrusiva que proporciona información detallada sobre los patrones de velocidad en aplicaciones como motores de combustión y estudios de flujo sanguíneo (Lagemann, Lagemann, Mukherjee & Schröder, 2021).

c. Visión Artificial Basada en Flujo Óptico



Recientemente, han surgido estudios que buscan implementar técnicas de visión artificial en la caracterización de procesos electroquímicos. En particular, un trabajo notable ha incorporado un sistema de visión artificial basado en flujo óptico para obtener información detallada sobre el comportamiento del flujo dentro de los reactores (López-Maldonado, Salazar-Colores, Piedra & Rivera, 2023). Esta metodología presenta una nueva dimensión en el análisis de patrones de flujo, combinando las ventajas de técnicas tradicionales como CFD y PIV con capacidades avanzadas de procesamiento de imágenes. Esta integración promete revolucionar la caracterización y optimización de reactores electroquímicos en el futuro cercano.

2. Flujo Óptico

El flujo óptico se define como el patrón de movimiento aparente de intensidades lumínicas entre dos imágenes consecutivas, generalmente derivadas de secuencias temporales. Este movimiento se interpreta a partir de la variación de intensidad de objetos observados en intervalos temporales t_1 y t_2 , con el propósito de determinar trayectorias y velocidades relativas (Sun, Roth & Black, 2010).

a. Algoritmo de Gunnar Farneback:

El panorama de algoritmos para el cálculo del flujo óptico es diverso, destacando la propuesta de Gunnar Farneback. Basándose en aproximaciones polinómicas de la vecindad de los píxeles y mediante series de Taylor, Farneback ofrece una estimación densa del movimiento para cada píxel en el conjunto (Mendes, Mendes, Coimbra & Crisóstomo, 2019). A pesar de su consolidación en el campo, es pertinente considerar que, como toda herramienta de propósito general, puede tener limitaciones en escenarios específicos, como el de reactores electroquímicos, donde la exactitud es primordial. Por lo anterior, recientes avances proponen una transición hacia algoritmos fundamentados en técnicas de deep learning. Estos ofrecen ventajas significativas como representaciones jerárquicas; a diferencia de las técnicas convencionales, los métodos basados en deep learning adquieren automáticamente representaciones en distintos niveles de abstracción, permitiendo identificar patrones complejos y sutilezas en los datos. Estos algoritmos también demuestran mayor adaptabilidad, ya que se entrenan en diversos conjuntos de datos, permitiendo una mejor generalización en escenarios variados. Por último, se benefician de la capacidad de aprendizaje continuo, actualizándose con nuevos datos, lo que mejora su precisión y robustez a lo largo del tiempo.

3. Aprendizaje profundo

El aprendizaje profundo (o deep learning) es una subcategoría de las técnicas de aprendizaje automático que utiliza redes neuronales con tres o más capas. Estas redes neuronales intentan simular el comportamiento del cerebro humano, al menos en un nivel rudimentario para "aprender" de grandes cantidades de datos. Mientras que una red neuronal con una sola capa solo puede hacer aproximaciones lineales, las redes neuronales profundas también pueden hacer aproximaciones no lineales, lo que las hace particularmente poderosas para tareas como la clasificación y predicción en conjuntos de datos complejos y de gran volumen (Dong, Wang & Abbas, 2021).

Requisitos de datos y la importancia de bases de datos específicas

Para que el deep learning sea eficaz, es esencial tener acceso a grandes cantidades de datos. Estos datos deben ser de alta calidad, relevantes y, en lo posible, etiquetados. Cuanto mayor sea la calidad y cantidad del conjunto de datos, más preciso será el modelo de aprendizaje profundo (Dargan, Kumar, Ayyagari & Kumar, 2020). En el contexto de la caracterización de flujos, es crucial que los datos provengan de fuentes fiables, y las bases de datos específicas para aplicaciones fluido dinámicas se convierten en activos valiosos. Estas bases de datos pueden incluir resultados de simulaciones de CFD, datos experimentales de laboratorio, o datos recopilados de operaciones en tiempo real. Las bases de datos específicas permiten a los ingenieros y científicos entrenar modelos de deep learning que están sintonizados específicamente para la tarea en cuestión, ya sea la predicción de patrones de flujo, la identificación de características de vórtices, o cualquier otro aspecto de la dinámica de fluidos.



4. Simulación de flujo en reactores químicos en Blender

Blender, ampliamente reconocido como un software de modelado y animación 3D, ha ganado terreno como una herramienta versátil para simulaciones físicas. Su motor de simulación incorporado permite la reproducción de diversos fenómenos físicos (Flaischlen & Wehinger, 2019), desde simulaciones de partículas y telas hasta dinámicas de fluidos y humo. Su naturaleza de código abierto y la amplia comunidad que lo respalda han potenciado su desarrollo, convirtiéndolo en una opción atractiva para aquellos que buscan alternativas accesibles para la simulación.

Una de las fortalezas de Blender es su capacidad para integrar la física realista en sus simulaciones. Mediante su motor de simulación, los usuarios pueden ajustar parámetros clave que influyen en la física del sistema, como la viscosidad, densidad, y turbulencia, para obtener resultados que se asemejen fielmente a escenarios del mundo real. Aunque inicialmente diseñado para propósitos cinematográficos y de animación, el nivel de detalle y precisión de las simulaciones de Blender ha sido suficiente para aplicaciones más allá del entretenimiento.

En el ámbito de flujo óptico, Blender presenta tanto ventajas como limitaciones. Entre sus ventajas, destaca su accesibilidad y la facilidad para visualizar y renderizar simulaciones, proporcionando una interfaz gráfica intuitiva que es especialmente útil para aquellos menos familiarizados con software de simulación especializado. Sin embargo, en términos de limitaciones, aunque Blender es potente, no fue diseñado primordialmente como una herramienta de investigación científica. Esto puede llevar a que, en escenarios específicos, no ofrezca la precisión o los parámetros avanzados que otros software dedicados a la simulación de fluidos pueden ofrecer.

Metodología Propuesta

La presente metodología describe los pasos necesarios para recrear el flujo de un reactor electroquímico de placas paralelas utilizando el software Blender. Esta simulación tiene como objetivo generar una base de datos sintética que pueda ser utilizada para investigaciones y análisis en el campo de la electroquímica.

Esta simulación se basa en una prueba previa para visualizaciones de flujo para obtener perfiles experimentales de velocidad en un reactor electroquímico de placas paralelas. A continuación se describe la configuración del experimento usado:

Un trazador coloreado (azul de metileno con una concentración de 10 g/L) fue introducido en un volumen de 1 mL, que fue ubicado 5 cm aguas arriba de la entrada del reactor. Un marco transparente fue construido con una lámina de policarbonato para que el flujo en el canal del electrolito del electrolizador de prensa de filtro pudiera ser observado. El reactor electroquímico fue conectado a un sistema hidráulico que estaba compuesto por un depósito de PVC de 20 L y una bomba centrífuga magnética calibrada de 1/15 HP y 3200 RPM. La temperatura del depósito fue mantenida constante a 25 °C. Los experimentos con el trazador fueron grabados mediante una cámara Nikon® D3500 a una tasa de flujo de 1.2 LPM (como se puede ver en la Figura 2 y, mediante técnicas clásicas de visión por computadora, el flujo óptico y un perfil de velocidad fueron obtenidos en estudios anteriores, los cuales fueron comparados con CFD y técnicas clásicas (como se muestra en la Figura 3). Es esencial destacar que, tal como se ilustra en la Figura 3 (c), existe una discrepancia entre el perfil de velocidad generado por la simulación CFD (representado en color azul) y el perfil derivado del método basado en el cálculo del flujo óptico (línea roja). Esta divergencia es precisamente la razón fundamental que impulsó la realización de esta investigación.






Figura 2. Configuración reactor electroquímico. (a) Depósito 1. (b) Depósito 2. (c) Bomba. (d) Válvula. (e) Medidor de flujo. (f) Punto de inyección. (g) Reactor electroquímico. (h) Cámara.
 Fuente: Elaboración propia.

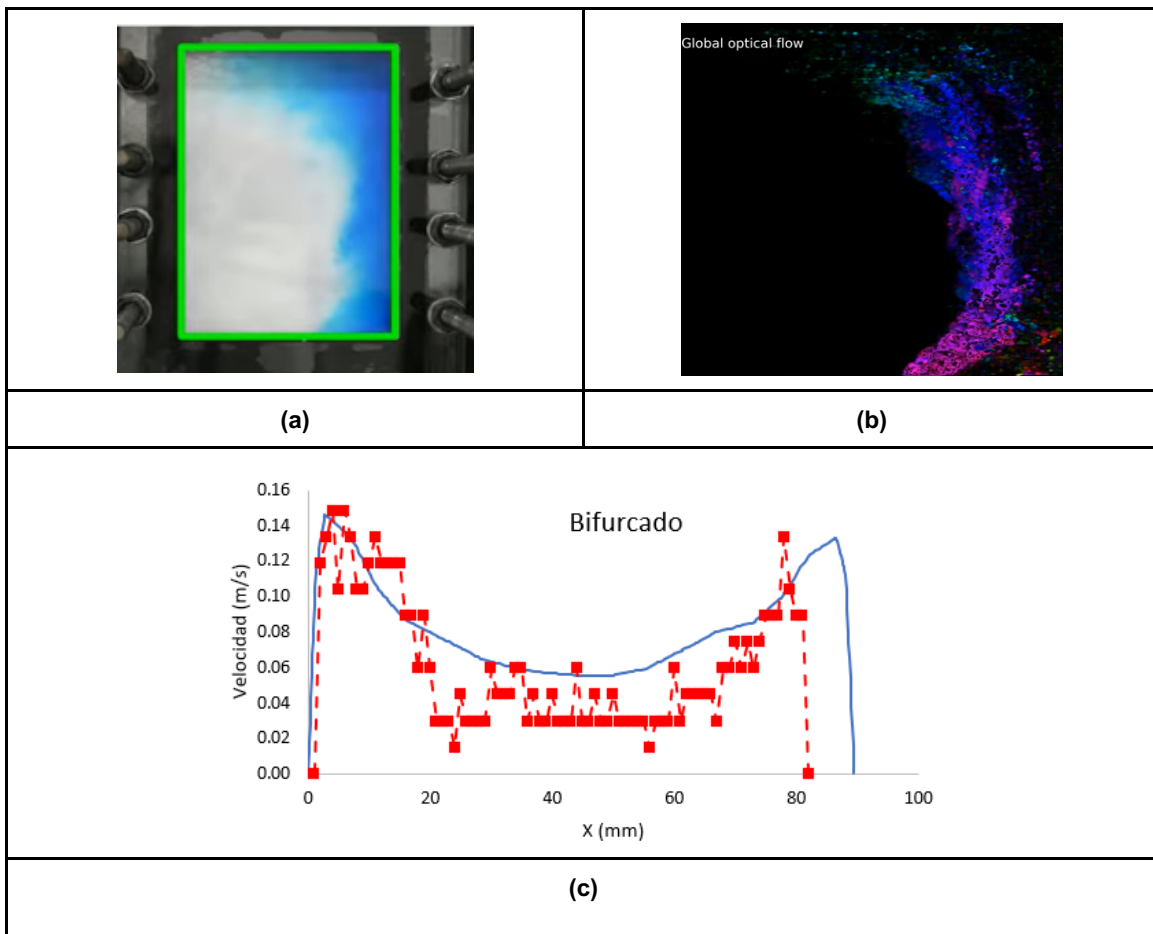


Figura 3. Resultados de estudio previo. (a) video del reactor. (b) Obtención de flujo óptico. (c) Perfil de velocidad CFD (línea azul) contra perfil obtenido con técnicas clásicas.
 Fuente: Elaboración propia.

Configuración del Entorno

La realización de sistemas electroquímicos complejos, como el reactor de placas paralelas, objeto de este estudio, demanda una configuración meticulosa del entorno de simulación, así como una atención rigurosa a los detalles técnicos. A continuación, se detallan los pasos esenciales llevados a cabo para garantizar una adecuada configuración del entorno de simulación.

Instalación de del software de simulación

En este estudio, se empleó el software de modelado y simulación Blender, una herramienta versátil y de código abierto ampliamente reconocida en la comunidad de modelado 3D y simulación de fluidos. Se optó por la versión más reciente disponible en el momento de la investigación, la cual se descargó e instaló desde el sitio oficial de Blender (<https://www.blender.org/>). La elección de esta plataforma se basó en su capacidad para modelar sistemas electroquímicos complejos y simular fluidos con un alto grado de realismo.

Preparación del Hardware

El éxito de las simulaciones computacionales depende en gran medida de la capacidad del hardware para gestionar cargas de trabajo intensivas en términos computacionales. Con el fin de asegurar un entorno de simulación eficiente, se implementaron las siguientes consideraciones:

Configuración del Equipo

Se utilizó una estación de trabajo equipada con un procesador AMD Ryzen 5 5600G con gráficos Radeon, 64 GB de memoria RAM DDR4 a 2666 MHz. Además, se seleccionó el sistema operativo Ubuntu Linux como plataforma de trabajo. Estas elecciones se realizaron con el objetivo de obtener el mejor rendimiento posible en Blender.

Diseño del Modelo 3D y Selección de Parámetros:

Para replicar fielmente el reactor electroquímico de placas paralelas, se utilizó el software de modelado 3D Fusion 360 debido a su capacidad avanzada para diseñar sistemas mecánicos con precisión. El modelo 3D se creó meticulosamente, tomando en consideración las dimensiones y la geometría específicas requeridas para la simulación electroquímica. Cada componente del reactor, desde las placas paralelas hasta los electrodos, fue modelado con detalle para garantizar una representación precisa del sistema real.

Una vez finalizado el diseño en Fusion 360, el modelo se exportó en formato .obj. Esta elección de formato permitió una importación eficiente del modelo tridimensional en el software Blender, asegurando una transición sin problemas entre las plataformas.

(Ver Figura 4) muestra el reactor electroquímico modelado en 3D, proporcionando una representación visual del diseño del sistema.






Figura 4. Modelo de reactor en Fusion 360.
Fuente: Elaboración propia.

Para simular el comportamiento de los fluidos en el reactor, se incorporó la extensión "flip-fluid" en Blender. Esta extensión es reconocida por su capacidad para simular de manera precisa y realista la mezcla de líquidos y los comportamientos del agua en general. La velocidad del fluido se estableció en 0.5208 m/s, un valor cuidadosamente seleccionado para recrear condiciones específicas de flujo en el reactor. Además, se implementó un emisor que dispara un líquido de color azul en un ambiente simulado de agua (Ver Figura 5). Esta configuración permitió una observación detallada y un análisis exhaustivo del comportamiento de la mezcla de líquidos en el reactor.




Figura 5. Se muestra el resultado después de caracterizar el reactor. (a) Montaje de reactor en Blender. (b) Resultado de renderizado con flip-fluid.
Fuente: Elaboración propia.

Para calcular el flujo óptico y automatizar el proceso de renderizado, se empleó Blenderproc2. Esta herramienta proporcionó funcionalidades avanzadas para analizar el flujo óptico y generar datos precisos sobre el movimiento y la interacción de las partículas (Ver Figura 6).




Figura 6. Cálculo de flujo óptico de partículas blenderproc2. (a) Imagen original de partículas en movimiento. (b) Flujo óptico calculado con Blenderproc2.

Fuente: Elaboración propia.

Todas estas elecciones de diseño y configuración se basaron en la experiencia previa en simulaciones reales. La combinación de un modelo 3D detallado, una simulación precisa de fluidos y el cálculo automatizado del flujo óptico, creemos que permitirá obtener resultados confiables y representativos del comportamiento de las

partículas en el reactor de placas paralelas. Estas decisiones metodológicas se tomaron para garantizar la precisión y la coherencia en los resultados obtenidos durante la simulación.

Resultados

Parece ser viable el utilizar Blenderproc2 para calcular el flujo óptico del modelo del reactor, las simulaciones detalladas realizadas con Flip Fluid en Blender proporcionaron una representación visual exhaustiva del comportamiento de los fluidos dentro del sistema. Estas simulaciones arrojaron luz sobre la dinámica de la mezcla de líquidos y las interacciones del fluido en el reactor, proporcionando información crucial sobre los patrones de flujo y la turbulencia dentro del reactor.

Además, se demostró que Blenderproc2 es capaz de manejar el cálculo del flujo óptico utilizando partículas en Blender. Aunque este enfoque no proporciona una solución directa, ofrece una alternativa válida para continuar trabajando en la mezcla de ambas tecnologías y así lograr analizar el flujo óptico basándonos en las simulaciones. Este método puede ser particularmente útil para estudios futuros que se centren en la dinámica de partículas y su comportamiento en sistemas similares.

Conclusiones

Blender ha mostrado promesa como una herramienta efectiva para generar una base de datos detallada sobre el flujo óptico en el reactor. Los resultados obtenidos sugieren un valioso recurso para entender en profundidad el comportamiento del fluido en el sistema estudiado. La meticulosa visualización de la mezcla de líquidos y las interacciones de las partículas proporciona una base sólida para una exploración en profundidad y un análisis cualitativo de las complejas dinámicas del reactor.

Además, la capacidad de utilizar Blenderproc2 para analizar el flujo óptico basándose en las partículas simuladas abre nuevas oportunidades para investigaciones futuras. Este enfoque pionero podría conducir a la creación potencial de una Base de Datos de Flujo Óptico en Reactores Electroquímicos, aunque se necesita una mayor validación. Este estudio establece un estándar para la simulación y análisis del flujo en reactores electroquímicos y sugiere un camino emocionante hacia una comprensión más profunda de estos sistemas complejos. Estos resultados son cruciales no solo para los investigadores en el campo de la electroquímica, sino también para profesionales e ingenieros que buscan mejorar el diseño y la eficiencia de los reactores electroquímicos en aplicaciones industriales y de investigación.

Referencias

- Catañeda, L. F., Rivera, F. F., Pérez, T., & Nava, J. L. (2019). *Mathematical modeling and simulation of the reaction environment in electrochemical reactors*. *Current Opinion in Electrochemistry*, 16, 75-82. <https://doi.org/10.1016/j.coelec.2019.04.025>
- Dargan, S., Kumar, M., Ayyagari, M. R., & Kumar, G. (2020). *A survey of deep learning and its applications: a new paradigm to machine learning*. *Archives of Computational Methods in Engineering*, 27, 1071-1092. <https://doi.org/10.1007/s11831-019-09344-w>
- Dong, S., Wang, P., & Abbas, K. (2021). *A survey on deep learning and its applications*. *Computer Science Review*, 40, 100379. <https://doi.org/10.1016/j.cosrev.2021.100379>
- Flaischlen, S., & Wehinger, G. D. (2019). *Synthetic packed-bed generation for CFD simulations: Blender vs. STAR-CCM+*. *ChemEngineering*, 3(2), 52. <https://doi.org/10.3390/chemengineering3020052>
- Károly, A. I., & Galambos, P. (2022, March). *Automated dataset generation with blender for deep learning-based object segmentation*. *2022 IEEE 20th Jubilee World Symposium on Applied Machine Intelligence and Informatics (SAMI)* (pp. 000329-000334). *IEEE*. <https://doi.org/10.1109/SAMI54271.2022.9780790>



- Lagemann, C., Lagemann, K., Mukherjee, S., & Schröder, W. (2021). Deep recurrent optical flow learning for particle image velocimetry data. *Nature Machine Intelligence*, 3(7), 641-651. <https://doi.org/10.1038/s42256-021-00369-0>
- López-Maldonado, J. T., Salazar-Colores, S., Piedra, S., & Rivera, F. F. (2023). Effect of Flow Distributor Configuration on the Hydrodynamics in a Multipurpose Flow Electrochemical Reactor: Numerical Analysis and Experimental Characterization Employing Digital Image Treatment. *Industrial & Engineering Chemistry Research*, 62(7), 3327-3337. <https://doi.org/10.1021/acs.iecr.2c04306>
- Meinhart, C. D., Wereley, S. T., & Santiago, J. G. (1999). PIV measurements of a microchannel flow. *Experiments in fluids*, 27(5), 414-419. <https://doi.org/10.1007/s003480050366>
- Menze, M., & Geiger, A. (2015). Object scene flow for autonomous vehicles. *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 3061-3070). https://openaccess.thecvf.com/content_cvpr_2015/html/Menze_Object_Scene_Flow_2015_CVPR_paper.html
- Middlebury College. (s.f.). *Flow: Visualizing Facebook*. Middlebury College Computer Vision. <https://vision.middlebury.edu/flow/>.
- Sun, D., Roth, S., & Black, M. J. (2010, June). Secrets of optical flow estimation and their principles. *2010 IEEE computer society conference on computer vision and pattern recognition* (pp. 2432-2439). IEEE. <https://doi.org/10.1109/CVPR.2010.5539939>
- Zawawi, M. H., Saleha, A., Salwa, A., Hassan, N. H., Zahari, N. M., Ramli, M. Z., & Muda, Z. C. (2018, November). A review: Fundamentals of computational fluid dynamics (CFD). *AIP conference proceedings* (Vol. 2030, No. 1). AIP Publishing. <https://doi.org/10.1063/1.5066893>
- Mendes, P. A., Mendes, M., Coimbra, A. P., & Crisóstomo, M. M. (2019, July). Movement detection and moving object distinction based on optical flow. In *Proceedings of the Lecture Notes in Engineering and Computer Science: Proceedings of The World Congress on Engineering*, London, UK (pp. 3-5). https://www.iaeng.org/publication/WCE2019/WCE2019_pp48-53.pdf

