

# ANÁLISIS MEDIANTE REDES NEURONALES ARTIFICIALES DEL EFECTO DE LA INTERFASE CANALES-ELECTRODO EN EL DESEMPEÑO DE CELDAS DE COMBUSTIBLE DE ÓXIDO SÓLIDO

García Páramo Ana Gabriela (1), Elizalde Blancas Francisco (2)

<sup>1</sup>[Licenciatura en Ingeniería en Sistemas Computacionales, Universidad de Guanajuato] | [ag.garciaparamo@ugto.mx]

<sup>2</sup>[Departamento de Ingeniería Mecánica, División de Ingenierías, Campus Irapuato – Salamanca, Universidad de Guanajuato] | [franciscoeb@ugto.mx]

## Resumen

En este trabajo se analizan los datos obtenidos del desempeño de celdas de combustible de óxido sólido mediante simulaciones numéricas computacionalmente costosas, los cuales son procesados mediante redes neuronales artificiales (RNA). Se analizan diferentes geometrías variando sus dimensiones y número de canales, ya que los parámetros geométricos son valores importantes para el desempeño de las celdas de combustible. Las RNA son diseñadas, entrenadas, simuladas y analizadas con la finalidad de obtener valores óptimos y así proponer diseños más eficientes en los cuales se disminuyan las pérdidas por sobrepotenciales óhmicos, de concentración y activación, y así alcanzar la máxima potencia de salida.

## Abstract

In this work, the data obtained from the performance of solid oxide fuel cells are analyzed by computationally expensive numerical simulations, which are processed by means of artificial neural networks (RNA). Different geometries are analyzed by varying their dimensions and number of channels, since the geometric parameters are important values for the performance of the fuel cells. RNAs are designed, trained, simulated and analyzed with the aim of obtaining optimum values and thus proposing more efficient designs in which the losses due to ohmic, concentration and activation overpotentials are reduced, thus achieving maximum output power.

### Palabras Clave

Simulaciones; Sobre potencial; Entrenamiento; Optimización; Desempeño

## INTRODUCCIÓN

### Redes Neuronales Artificiales

En 1943, se propuso el primer modelado de una red neuronal, los pioneros en este tema fueron los investigadores Warren McCulloch y Walter Pitts. Años más tarde, se construyó la máquina neuronal perceptrón por Frank Rosenblatt [1], [2].

Una red neuronal artificial (RNA) es un método computacional que se basa en los procesos biológicos del cerebro para resolver problemas que son complicados para los seres humanos. Una RNA se adapta a cualquier tipo de problema donde falta algún modelo o ecuación matemática, su entrada puede ser ruido, una imagen, temperatura, voltaje, cualquier tipo de información. El principal propósito de una RNA es extraer, clasificar, procesar e identificar algún tipo de información que se encuentre oculta en los datos o valores de la entrada [3].

En la Figura 1 se muestran los elementos de una red neuronal artificial:

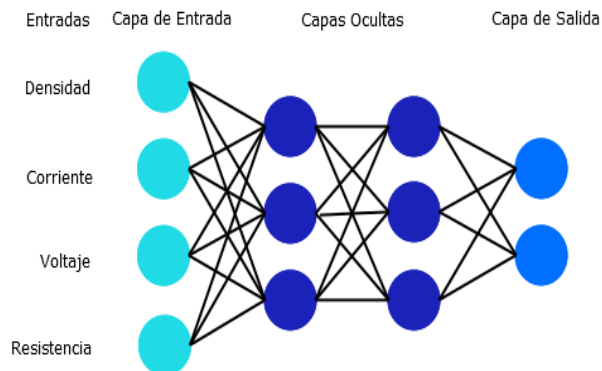


FIGURA 1: Diagrama de una red neuronal artificial.

Las entradas externas (datos) son aplicadas a las neuronas de la primera capa, se van procesando los datos a través de las neuronas de las capas ocultas y la capa de salida arroja los resultados. Cada neurona está conectada a otra utilizando un peso  $w$ , si es positivo se habla de una excitación y si es negativo de una inhibición. El bias es una entrada fija a cada neurona con valor de 1, esto permite a la neurona aumentar su flexibilidad de aprendizaje. La función de activación actualiza los

nuevos niveles (uno tras de otro) basándose en la entrada de una unidad y en la activación anterior a la actual. Las funciones de activación más comunes son la tangente hiperbólica y la función sigmoide. La función de entrenamiento es un proceso durante el cual los pesos se ajustan para alcanzar una meta deseada. Para evaluar la calidad del comportamiento de una red neuronal, el error cuadrático medio (mse) se utiliza con fines comparativos, se calcula entre la salida real de la red y el objetivo.

### Celdas de Combustible de Óxido Sólido

En 1839, William Grove realizó el primer experimento de una celda de combustible en el cual hidrolizó agua y separó el hidrógeno y el oxígeno dando paso a una pequeña corriente en el sistema [4].

Una celda de combustible de óxido sólido (SOFC) está compuesta por los siguientes componentes: ánodo, cátodo, electrolito y dos colectores de corriente. Este tipo de dispositivo convierte la energía química del combustible en energía eléctrica [5], [4].

Existen diversos tipos de celdas de combustible, la principal diferencia entre ellas está dada por el tipo de electrolito que se usa en cada una de ellas, lo cual provoca un cambio en las condiciones de operación como las reacciones que suceden en el ánodo y cátodo, así como el rango de temperatura a la cual puede operar.




FIGURA 2: Vista frontal de un canal de la celda de combustible [5].

La Figura 2 muestra la vista frontal de los elementos que conforman una celda de combustible [5].

Por tanto, con las descripciones anteriores a cerca de nuestros temas de estudio y análisis, el trabajo que se desarrolla tiene como objetivo hacer uso de las redes neuronales artificiales desde su diseño hasta su optimización con el fin de obtener datos que se encuentren ocultos y realizar mejoras en los diseños de las celdas de combustible de óxido sólido. Es necesario mencionar que las redes neuronales no hacen uso de las ecuaciones con las cuales se obtuvieron los datos a entrenar. Se decide hacer uso del método de entrenamiento de retropropagación hacia adelante y el cálculo del error cuadrático medio para realizar las evaluaciones correspondientes.

## MATERIALES Y MÉTODOS

Se simularon 8 redes neuronales, cada una con relación a una geometría diferente de la celda. En la Tabla 1 se muestran algunas características geométricas de cada una de ellas:

**TABLA 1: Características geométricas de los casos analizados en las redes neuronales.**

Caso	Nº. de canales	Dimensiones de los canales (ancho x alto) [mm <sup>2</sup> ]	Af (Area del fluido) [mm <sup>2</sup> ]	$\theta$
1	9	3x1	2700	0.54
2	9	2x1	1800	0.36
3	9	1x1	900	0.18
4	6.5	6x1	3900	0.78
5	18	1x1	1800	0.36
6	10	1.8x1	1800	0.36
7	25	1x1	2500	0.50
8	35.5	1x1	3550	0.71

El valor de  $\theta$  representa la razón entre el área en la interfase canal-electrodo y el área activa.

Con relación al desarrollo de este proyecto, se hizo uso de la siguiente metodología para la implementación de las redes neuronales artificiales:

- Se construyó el conjunto de entrenamiento, en este caso los datos de entrada y los valores objetivo fueron los resultados obtenidos en simulaciones de un software de CFD (Computational Fluids Dynamics).
- Se creó el conjunto de validación para evaluar qué tan bien se compara la red neuronal con otros posibles casos.
- La red se diseñó con 21 valores de entradas diferentes y con su bias respectivo, 10 neuronas en la capa oculta y en la capa de salida 21, los pesos entre cada conexión neuronal fueron aleatorios y la función de transferencia elegida fue la tangente hiperbólica.
- En el entrenamiento de las redes se utilizaron para todos los casos los mismos parámetros y se empleó el método de retropropagación hacia adelante en el cual fluye la información desde las entradas hacia las salidas extendiéndose por todas las unidades de las capas con conexiones de retroalimentación para lograr un estado estable de activación.
- Se revisó el entrenamiento, para lo cual se calculó el error cuadrático medio con fines comparativos y necesario para ajustar los pesos de la red.
- Se realizó la validación de los resultados finales y calculó nuevamente el error cuadrático medio con el fin de encontrar las salidas más óptimas.

Para el diseño y simulación se utilizó el software Matlab.

## RESULTADOS Y DISCUSIÓN

Los resultados mostrados a continuación se han obtenido haciendo un análisis entre los valores obtenidos en las simulaciones de CFD y los obtenidos con las redes neuronales. La comparación se hizo con los casos que son similares ya sea en geometría o desempeño, así los factores más importantes nos permiten encontrar la configuración de la celda de combustible que proporciona un mejor desempeño.




FIGURA 3: Voltaje y densidad de potencia para los 8 casos analizados, valores obtenidos en la simulación con RNA.




FIGURA 4: Sobrepotencial óhmico de los 8 casos simulados con RNA.

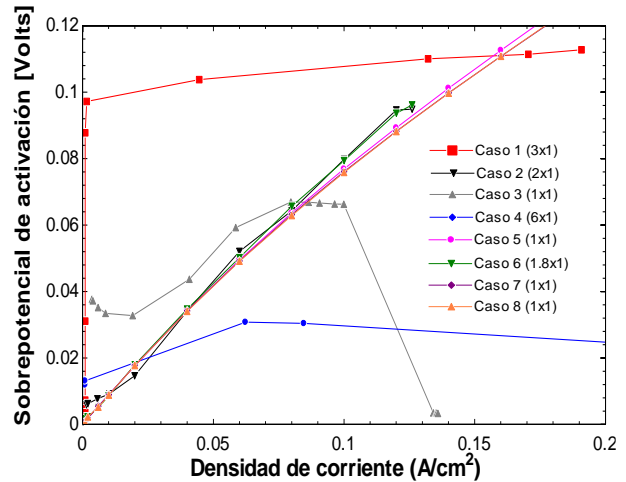


FIGURA 5: Sobrepotencial de activación de los 8 casos simulados con RNA.

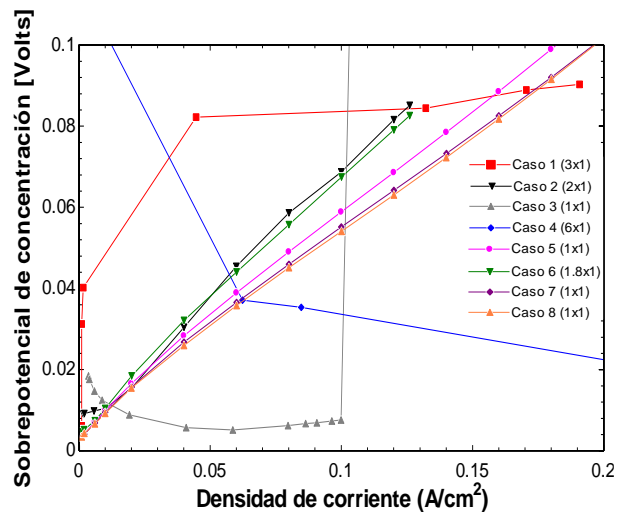


FIGURA 6: Sobrepotencial de concentración de los 8 casos simulados con RNA.

Se aprecia que varios casos tienen un comportamiento muy similar en densidad de potencia, pero otros difieren mucho con la simulación en redes neuronales. Tanto en los valores reales como en los obtenidos en la simulación, se aprecia en la Figura 3 que el mejor desempeño se ha obtenido en la configuración del caso 5 (graficado en color rosa).

Analizando los casos 1, 2 y 3 que tienen el mismo número de canales (9 canales) pero con diferente ancho de canal y valor de  $\theta$ , se observa que las

pérdidas óhmicas y por concentración tienden a disminuir cuando los canales son menos anchos y  $\theta$  es menor, como se puede apreciar en las Figuras 4 y 6. Estos resultados son similares en comportamiento a los obtenidos con los valores de las simulaciones en CFD.

Los casos 2, 5 y 6 comparten el mismo valor de  $\theta$  pero con diferente ancho de canal y número de canales. Las pérdidas óhmicas mostradas en la Figura 4, son muy similares, pero con una cierta diferencia ya que van aumentando si el ancho del canal crece y si el número de canales disminuye, en los valores obtenidos en las simulaciones de CFD se comporta de la misma manera.

Para los casos con mismo ancho de canal que son el 5, 7 y 8, las pérdidas óhmicas y por concentración siguen la tendencia de que a menor valor de  $\theta$  menor son sus pérdidas, el caso 3 comparte el mismo ancho de canal, pero no tiene un comportamiento similar.

Las pérdidas por activación en el análisis real no son analizadas debido a que la variación entre los casos es despreciable, sin embargo, en nuestra simulación de redes neuronales los casos 1, 3 y 4 no arrojaron resultados aceptables.

## CONCLUSIONES

Como se puede observar en el análisis realizado, las diferencias que existen entre los resultados obtenidos con las redes neuronales y los valores reales, algunos casos difieren mucho en su comportamiento, pero otros son muy parecidos.

Se concluye en términos del parámetro  $\theta$ , que si es mayor a 0.5 o menor a 0.18 el desempeño de la celda comienza a disminuir. La geometría con el mejor desempeño es el caso 5 ya que tiene la máxima potencia de salida.

El método de entrenamiento de retropropagación hacia adelante permitió hacer una excelente aproximación a los valores reales ya que se obtiene un error muy pequeño, los casos en los que difieren los resultados podemos concluir que es necesario realizar un entrenamiento con más datos para que tenga una aproximación más cercana.

Adicionalmente, se propone para trabajos futuros la implementación de otras funciones de

activación, así como de métodos de entrenamiento, también el uso de otros valores de  $\theta$  y de nuevos casos donde cambie la geometría de estos.

## AGRADECIMIENTOS

Agradezco de manera muy especial a mi asesor el Dr. Francisco Elizalde Blancas que, durante la realización de mi proyecto, fue un gran apoyo por su orientación, paciencia, dedicación y tiempo.

## REFERENCIAS

[1] Ponce, P. (2011). *Inteligencia Artificial con aplicaciones a la ingeniería*. México. D.F.: Alfaomega.

[2] Ledesma, S., Belman-Flores, J.M. & Barroso-Maldonado, J.M. (2015). *Analysis and modeling of a variable speed reciprocating compressor using ANN*. International Journal of Refrigeration, 59, 190–197.

[3] Russell, S. & Norvig, P. (2008). *Inteligencia Artificial: Un Enfoque Moderno*. Madrid: Pearson Prentice Hall.

[4] Larminie, J. & Dicks, A. (2003). *Fuel cell system explained*. England: WILEY.

[5] Moreno, J. (2012). *Efecto de la relación interfaz canal-electrodo en las celdas de combustible de óxido sólido* (Tesis de licenciatura). Universidad de Guanajuato, Guanajuato, México.