

Sistema híbrido inteligente para la predicción de tensión de una pila de combustible basada en hidrógeno

José-Luis Casteleiro-Roca^{a,*}, Antonio Javier Barragán^b, Francisca Segura^b, José Luis Calvo-Rolle^a, José Manuel Andújar^b

^aUniversity of A Coruña; Department of Industrial Engineering

^bUniversidad de Huelva; Department of Electronic Engineering, Computer Systems and Automatic

Resumen

Por razones de sostenibilidad y estrategia energética, entre otras, existe en la actualidad una tendencia clara hacia el uso de nuevas formas de obtención, almacenamiento y gestión de energía, más eficientes y con un carácter eminentemente sostenible. Con este fin, se está investigando sobre sistemas de almacenamiento de energía; de los que uno de los más prometedores, en lo que a capacidad y movilidad se refiere, es el basado en hidrógeno. En el presente trabajo se obtiene un modelo para predecir el comportamiento dinámico de una pila de combustible alimentada por hidrógeno, lo cual permitirá mejorar su control entre otras aplicaciones. Las variables usadas en esta investigación se han extraído de un banco de pruebas real, donde se monitoriza una pila de combustible mientras se producen variaciones en una carga programable conectada a la salida de la misma. Para realizar este modelado se opta por estudiar la implementación de un modelo híbrido basado en técnicas de agrupamiento y, posteriormente, técnicas inteligentes de regresión con redes neuronales artificiales sobre cada uno de los grupos. La propuesta se ha probado con dos conjuntos de datos de validación, consiguiendo resultados altamente satisfactorios.

Palabras Clave:

Almacenamiento de energía, Pila de combustible, Hidrógeno, K-Means, ANN

Intelligent hybrid system for the prediction of the voltage-current characteristic curve of a hydrogen-based fuel cell

Abstract

Due to some reasons like sustainability and energy strategy, there is a clear trend using new ways to obtain energy, more efficient and, usually, renewables. In addition, with other different objectives, many researchs are being carried out on energy storage systems; one of the most promising, in terms of capacity and mobility, is hydrogen-based. In the present work a model is obtained to predict the dynamic behavior of a hydrogen fuel cell, which will improve its control. The variables used in this research have been extracted from a test bench, where a fuel cell is monitored under several load conditions with a programmable load connected to its output. To perform this model, a hybrid intelligent model was chosen. This kind of models use clustering techniques to divide the data set and, after that, intelligent regression algorithm with artificial neural networks are used for each group. The proposal has been tested with two validation data set, obtaining highly satisfactory results.

Keywords:

Energy storage, Fuel Cell, Hydrogen, K-Means, ANN

1. Introducción

Los problemas derivados de la contaminación y el cambio climático, cada vez más preocupantes para la sociedad, han llevado a buscar fuentes de energía más limpias que las utilizadas tradicionalmente. Una de las tecnologías más prometedoras pa-

ra la hibridación de energías basadas en fuentes renovables es la que se basa en el hidrógeno; ya que es posible su generación mediante electrolizadores y su almacenamiento. Posteriormente, con este gas, es absolutamente factible la generación de energía eléctrica mediante pilas de combustible (Vivas et al.,

*Autor para correspondencia: jose.luis.casteleiro@udc.es

2018). En este sentido, los sistemas basados en este tipo de dispositivos son una fuente de energía que surgen como una opción esperanzadora debido a: su elevado rendimiento, alta fiabilidad en aplicaciones estables, y pequeña incidencia ambiental; además de su gran usabilidad en aplicaciones espaciales y automotrices (Andújar and Segura, 2009).

Una pila de combustible es un sistema complejo que consiste en una conexión en serie de celdas individuales (un *stack*), donde la corriente eléctrica es producida por una reacción electroquímica, junto con todos los sistemas necesarios para su funcionamiento; esto es: filtros y sistemas que acondicionan los gases involucrados en la reacción (H_2 y O_2), un sistema de refrigeración y, por supuesto, un sistema de control (De las Heras et al., 2018a). En comparación con otras tecnologías limpias, como la generación eólica o fotovoltaica, las pilas de combustible no requieren una ubicación específica para obtener un mayor rendimiento. Además, estos dispositivos son muy respetuosos con el medio ambiente, ya que el resultado de la reacción, en el caso de las pilas de hidrógeno, es simplemente agua. Las pilas de combustible de membrana de intercambio de protones (PEMFC) ofrecen una alta densidad energética y una serie de ventajas, como su bajo volumen y peso en comparación con otras tecnologías. Las pilas PEMFC funcionan a bajas temperaturas (50°C–100 °C), característica que les permite arrancar rápidamente (requieren menos tiempo de calentamiento), lo que redundará en un menor desgaste de los componentes del sistema y, por tanto, en una mayor durabilidad. Las PEMFC están disponibles comercialmente en una amplia gama de potencias (desde pocos Watios hasta varios MW), permitiendo su uso en un gran número de aplicaciones (Andújar and Segura, 2009). Por ejemplo, en aplicaciones estacionarias, las pilas de combustible pueden conectarse a la red eléctrica (Moreira and da Silva, 2009), instalarse como generadores separados (Kirubakaran et al., 2009), u operar en vertederos y plantas de tratamiento de aguas residuales (Paska et al., 2009). Su uso también es interesante en aplicaciones de transporte, debido a la escasez de combustibles fósiles y sus escasos efectos contaminantes (Bertoluzzo and Buja, 2011; De las Heras et al., 2018b), o sobre otro tipo de estaciones móviles (Ross, 2003).

Una pila de combustible se comporta dinámicamente como un sistema no lineal que genera potencia eléctrica no regulada mediante una reacción electroquímica. Por tanto, el uso eficiente de la energía requiere de su regulación (Andújar et al., 2011; Segura et al., 2011). De esta forma, para la aplicación formal de estrategias de control sobre una pila de combustible es muy importante disponer de un modelo de su comportamiento dinámico (Amphlett et al., 1995, 1996; Famouri and Gemmen, 2003; Kim et al., 1995; Van Bussel et al., 1998; Vivas et al., 2018). En (Hou et al., 2011) se analiza la respuesta de un *stack* frente a escalones de corriente, midiendo la tasa de variación del voltaje, su valor inicial, el tiempo para alcanzar el estado estacionario y el factor de resistencia dinámica. Los resultados de esta investigación muestran que la respuesta dinámica de la tensión del *stack* es diferente frente a aumentos y disminuciones de la corriente (Ziougou et al., 2011), lo que debe tenerse en cuenta a la hora de establecer un patrón de prueba para obtener datos de la pila de combustible.

Es importante poder predecir el comportamiento de las pilas de combustible para un uso eficiente de las mismas, por lo

que es deseable obtener un modelo preciso antes de diseñar una estrategia de control. El desarrollo del modelo de un sistema es una parte fundamental de su estudio, sin embargo, no siempre se dispone de suficiente información para obtener un modelo matemático aceptable; en estos casos se debe recurrir a técnicas de modelado basadas en datos de entrada-salida (Barragán et al., 2014; López-Baldán et al., 2002). En sistemas de control este proceso es aún más crítico, ya que se requiere un modelo lo más preciso posible, tanto para realizar análisis en el sistema (Barragán et al., 2015; Gordillo et al., 1997), como para diseñar un controlador adecuado y eficiente (Fontanet et al., 2016; Irigoyen and nano, 2013; Márquez et al., 2009).

Una de las formas más eficaces de mejorar el comportamiento de un sistema de control, es poder predecir la evolución de las variables con la suficiente antelación, de tal manera que permita tomar mejores decisiones. Si se dispone de un conjunto de datos de las variables de funcionamiento del sistema, es posible el empleo de técnicas de regresión. En este sentido, los algoritmos de análisis de regresión múltiple son usados en diferentes y numerosas aplicaciones (Ghanghermeh et al., 2013; Calvo-Rolle et al., 2015, 2014; Baruque et al., 2019). Pese a que, por norma general, no ofrecen una muy buena precisión, son muchos los trabajos y aplicaciones en los que se han empleado estas técnicas (Calvo-Rolle et al., 2015; Casteleiro-Roca et al., 2015; Jove et al., 2018b). Con el objetivo de mejorar la predicción, como paso previo a la aplicación de técnicas de regresión, se pueden aplicar técnicas de agrupamiento sobre la muestra de la que se disponga. De este modo, se separan los datos en subconjuntos, de manera que los grupos resultantes posean características en común. Son muchas las aplicaciones que ofrecen buenos resultados gracias a esta metodología (Jove et al., 2018c; Machón-González et al., 2010; Jove et al., 2018a).

Teniendo en cuenta lo expuesto, en este trabajo se presenta un modelo de regresión para calcular el valor de la tensión de salida de una pila de combustible. El modelo que se propone es un modelo híbrido inteligente, aplicando inicialmente técnicas de agrupamiento como paso previo a la regresión propiamente dicha. Concretamente, se utilizará un modelo híbrido basado en redes neuronales artificiales (ANN) (García et al., 2013; Calvo-Rolle et al., 2013; García et al., 2014; Quintián et al., 2014; Quintian Pardo et al., 2012) ya que éstas permiten obtener un modelo relativamente simple para recrear con precisión sistemas no lineales (Alaiz Moretón et al., 2011; Rolle et al., 2011).

Este trabajo está organizado de la siguiente manera. Después de esta introducción se explicará el caso de estudio, donde se describirá el sistema usado para la toma de datos. Posteriormente se presentará el modelo propuesto, incluyendo la descripción de las técnicas que se usarán, así como el procesado previo de los datos. En la sección de resultados se explicarán con detalle los modelos obtenidos, así como la validación de los modelos finales. Para terminar este trabajo, se expondrán algunas conclusiones y posibles trabajos futuros.

2. Caso de estudio

2.1. Pila de combustible

Una celda de combustible de una pila PEMFC aislada, consiste en una capa de electrolito en contacto con un ánodo y un cátodo a cada uno de los lados, ver figura 1. Una pila de

combustible PEMFC produce energía electroquímica cuando el hidrógeno pasa a través del ánodo, y un gas rico en oxígeno (o aire) pasa a través del cátodo, con un electrolito entre el ánodo y el cátodo que permita el intercambio de carga eléctrica (iones) (Andújar et al., 2008). La disociación de las moléculas de hidrógeno produce el flujo de iones a través del electrolito y una corriente eléctrica a través de un circuito externo. El único residuo generado por este proceso es agua pura. Una sola celda de combustible produce aproximadamente 1,2 V bajo condiciones normales de operación. Por lo tanto, para la creación de sistemas de mayor potencia, las células se deben conectar en serie, formando una pila o *stack*.




Figura 1: Diagrama de una pila de combustible.

2.2. Sistema de laboratorio

Los datos utilizados para la realización de los modelos de este artículo han sido obtenidos mediante distintas pruebas de laboratorio con una pila tipo PEMFC refrigerada por aire. Más concretamente, una pila FCgen-1020AVS de Ballard (Ballard, 2018). Este *stack* fue construido con 80 células BAM4G de base polimérica (Mehta and Cooper, 2003), cuya membrana es una lámina de Nafion 111. El ánodo y el cátodo son de carbono poroso, con un catalizador a base de platino y platino-rutenio (Ralph et al., 1997). La pila fue ensamblada con placas de grafito, intercaladas entre las finales de aluminio mediante compresión. La pila FCgen-1020AVS está diseñada para proporcionar hasta 3,4 kW de potencia eléctrica estable no regulada, con 45,33 V y 75 A. Este *stack* está refrigerado por aire y se utiliza una configuración *dead-ended*, por lo que no requiere humidificación externa del aire ni del hidrógeno. La presión de entrada de hidrógeno puede variar de 1,16 a 1,56 bares. El subsistema oxidante y enfriamiento fue construido según las instrucciones del fabricante (Ballard, 2009). El sistema se completa con el funcionamiento los dispositivos individuales que lo componen: el *stack*, el subsistema de oxidación y refrigeración, el subsistema eléctrico y la implementación del Balance de Planta (BoP). El esquema del sistema de laboratorio se muestra en la figura 2, y una imagen real del laboratorio en la figura 3. Este sistema se explica de forma detallada en (Segura and Andújar, 2015).

2.3. Extracción de datos

Para realizar las pruebas sobre el sistema se utilizó una carga electrónica programable Amrel PLA5K-120-1200. Para registrar todos los datos del sistema de celdas de combustible y almacenar los resultados de las pruebas, se implementó el sistema de monitorización descrito en (Segura and Andújar, 2015) y

(Segura et al., 2017). En (Li et al., 2011) se establece un modelo térmico detallado, basado en ecuaciones diferenciales según las ecuaciones de conservación de masa y energía, para una pila PEMFC de 16 células. En este trabajo también se demuestran los efectos de la temperatura sobre el funcionamiento de la pila. Para evitar estos efectos de funcionamiento, el BoP incluye un sistema de control de temperatura para garantizar que la pila se mantiene en su valor óptimo. Además, es necesario tener en cuenta que el hidrógeno debe ser evacuado periódicamente a la atmósfera y reemplazado por hidrógeno fresco mediante un proceso de purga de acuerdo con el manual del fabricante (Ballard, 2009).




Figura 2: Stack y BoP para integrar la pila de combustible.




Figura 3: Implementación de laboratorio para probar la pila de combustible

3. Modelo propuesto

El modelo propuesto en este trabajo se muestra de manera general en la figura 4, donde las entradas son la corriente, la temperatura y el voltaje medidos por el BoP, y la salida el valor futuro del voltaje. Con el objetivo de tener en cuenta la dinámica del proceso, se han incluido varias entradas con valores del instante previo de las variables de entrada.




Figura 4: Esquema básico del modelo

En la figura 5 se muestra el esquema básico interno del modelo general, con la indicación de los retardos para los instantes anteriores de las variables mencionadas como entradas al modelo híbrido propuesto. Si se hablara de las señales en tiempo discreto, las entradas del Modelo híbrido serían $I(k)$, $I(k - 1)$, $T(k)$, $T(k - 1)$, $V(k)$ y $V(k - 1)$; mientras que la salida sería $V(k + 1)$.

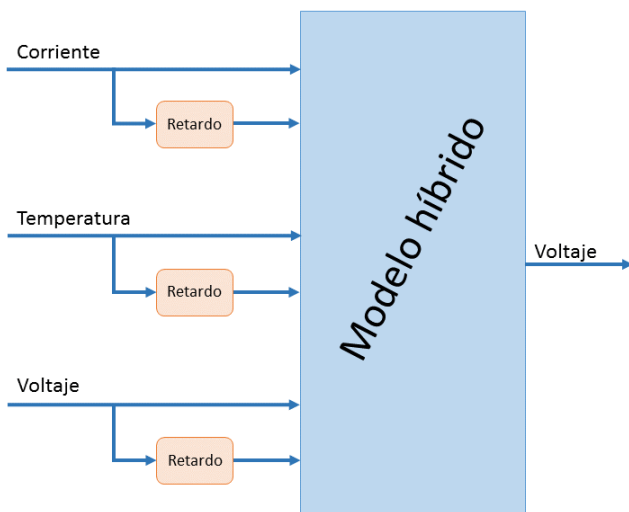


Figura 5: Propuesta del modelo de predicción del valor de corriente

En la figura 6 se puede ver la estructura interna del *Modelo híbrido* de la figura 5. Dada la respuesta no lineal del sistema objeto de estudio, para la implementación del modelo híbrido se emplean técnicas de agrupamiento, con el objetivo de dividir el conjunto de datos empleado en grupos con características similares. A continuación se crearon diferentes modelos de regresión para cada grupo, con el objetivo de conseguir una mejor aproximación y, consecuentemente, un mayor rendimiento del modelo en todo el intervalo de operación.

El número de grupos se obtiene realizando un barrido con diferentes configuraciones híbridas (variando el número de grupos), y comprobando la aproximación de los modelos de regresión para cada una de las topologías. La figura 6 representa un modelo híbrido general, con n grupos y en consecuencia n modelos con sus parámetros específicos en cada caso.

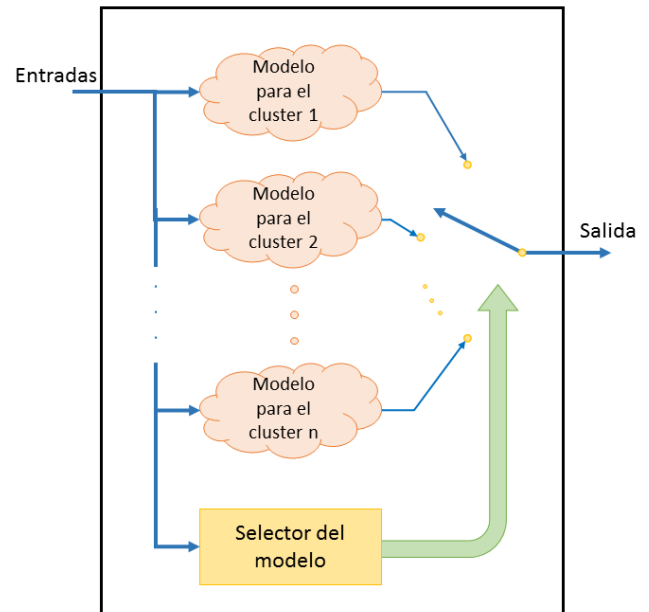


Figura 6: Esquema interno del modelo híbrido.

Para la creación del modelo híbrido, el proceso general de modelado se podría dividir en los siguientes pasos:

1. Fase de agrupamiento.
2. Fase de modelado mediante regresión para cada grupo creado.
3. Selección de los mejores modelos de regresión para cada grupo.
4. Selección de la mejor topología para el modelo híbrido definitivo.

Para la fase de agrupamiento, se ha usado el algoritmo *K-Means* con el objetivo de obtener grupos del conjunto de datos inicial que posean características similares (Casteleiro-Roca et al., 2017). Durante la fase de modelado de regresión, efectuada sobre cada uno de los grupos obtenidos, se emplea *K-Fold* con el fin de lograr una aproximación más real en la medición del rendimiento del modelo (Casteleiro-Roca et al., 2018, 2019).

En la figura 7 se muestra el cálculo del error empleando *K-Fold*. El conjunto de datos de cada grupo se divide K veces, entrenando K modelos con la misma configuración y, posteriormente, se calcula el error para esa configuración con todos los datos del grupo.

Tal y como se muestra en la figura 7, para cada modelo, los valores de los errores entre la medida predicha y la medida real de la salida, son almacenados. Cuando el proceso de validación finaliza, todos los datos almacenados para un grupo específico son empleados para probar el modelo, y por tanto poder calcular su rendimiento. Además, cuando hayan sido probadas todas las posibles configuraciones de los modelos, en términos de regresión, se escoge el mejor resultado obtenido para cada grupo, que tendrá el error más bajo alcanzado. Se ha de determinar el número de grupos para la definición de la topología del modelo híbrido. Esta elección se efectúa basada en el error global, considerando la cantidad de muestras para todos los agrupamientos, y estimando un error ponderado. La mejor configuración

para el modelo híbrido será la que posea un mejor comportamiento global.




Figura 7: Entrenamiento mediante K-Fold & selección del conjunto de datos de ensayo

3.1. El algoritmo K-Means

El método K-Means se utiliza para crear un determinado número de grupos, o *clusters*, a partir de un conjunto de datos sin etiquetar. La idea es ubicar un número concreto de centroides en el hiperespacio, de tal modo que aquellos datos que tengan características similares estarán próximos a un mismo centroide y representarán un grupo o *cluster* de datos (MacQueen, 1967; Moody and Darken, 1989). Una vez finalizado el entrenamiento, y estando por tanto los centroides ubicados de forma correcta en el hiperespacio, cada nueva muestra que llega se compara con los grupos definidos en la fase de aprendizaje. Ese nuevo dato se asociará al grupo cuyo centroide esté más cerca en términos de distancia, normalmente la distancia euclídea (Orallo et al., 2004). Este algoritmo posee una fase inicial de entrenamiento, en la que es necesario conocer el número de grupos en los que se dividirá el conjunto de datos del que se dispone. Esta fase podría ser relativamente lenta, dependiendo del número óptimo de grupos, así como del tamaño de los datos; sin embargo, una vez finalizada la fase de entrenamiento, la asignación del grupo de los nuevos datos es muy rápida (Viñuela and León, 2004).

La ubicación inicial de los centroides se escoge al azar. Seguidamente se varía su ubicación, hasta alcanzar la mayor distancia entre ellos, en base al siguiente procedimiento:

- Cada muestra se asocia al centroide más cercano y se incluye en una lista específica.
- Después de probar todas las muestras y ser asociadas a la lista del centroide correspondiente, se dispondrá de un listado de muestras etiquetadas.
- La ubicación del centroide se recalcula obteniendo el centro del conjunto de muestras que se le han asociado.

- El procedimiento se repite hasta que los centroides ya no sufren desplazamiento en los sucesivos cálculos.

3.2. Redes Neuronales Artificiales

Una Red Neuronal Artificial, del inglés *Artificial Neural Network (ANN)*, es un algoritmo inteligente que emplea pequeñas unidades de procesamiento denominadas neuronas. Estas neuronas están interconectadas entre sí a través de enlaces, y cada una calcula una función teniendo en cuenta las diferentes entradas. Todas las entradas a cada neurona tienen su peso asignado, y el resultado de la suma de todas éstas, se introduce a una función de activación (Galipienso et al., 2003; Alique et al., 2000). Las principales características específicas de las ANNs es que pueden aprender y generalizar casos de estudio (Hilera González and Martínez Hernando, 2000). Las ANNs son sistemas inteligentes adaptativos que pueden realizar ciertas funciones a través de su entrenamiento. Internamente crean su propia representación del problema con el entrenamiento y responden de acuerdo a ciertas situaciones, aunque no hayan aprendido esa situación específicamente. Por tanto, las ANNs pueden generalizar a partir de casos anteriores a otros nuevos (Harston and Pap, 2014).

La función de activación define el nuevo estado, o salida de la neurona, como el nivel de excitación (del Brío and Molina, 2006). El grado de activación de la neurona artificial, por lo general, puede variar entre un intervalo concreto (normalmente $[0, 1]$ o $[-1, 1]$). Este valor indica el estado de la neurona: inactiva (0 o -1), activa (1) o un estado intermedio entre estos límites. La topología, o arquitectura, de una ANN está determinada por la organización de las neuronas, la disposición entre ellas y sus conexiones. Esta arquitectura depende de cuatro parámetros principales: el número de capas en el sistema, el número de neuronas de cada capa, la conectividad entre las neuronas y las funciones de activación (López and Fernández, 2008).

La estructura básica de interconexión de neuronas es el Perceptrón Multicapa. Este tipo de ANN está organizado en varias capas: entrada, intermedia u oculta, y salida. Una capa es un conjunto de neuronas cuya información de entrada proviene de la misma fuente: las entradas de la ANN para la capa de entrada, o la capa anterior para las capas restantes. La salida de las neuronas de la misma capa también tiene el mismo destino: la siguiente capa o la salida de la ANN (en el caso de la capa de salida). Normalmente, las neuronas de la capa de salida utilizan funciones de activación especiales dependiendo del uso de la ANN; para regresión, la típica es la función lineal.

3.3. Procesamiento de datos

El conjunto de datos en esta investigación se recopiló utilizando el sistema de BoP descrito en la sección 2. Con este equipo, se recogieron muestras de dos días diferentes. De estas pruebas se registraron un total de 774391 muestras, y después de descartar las mediciones incorrectas, el conjunto de datos se redujo a 774385 muestras. Dado que el modelo emplea valores de estados anteriores, fue necesario eliminar las muestras que no disponían de todos los valores de entrada para modelar.

A pesar de que inicialmente se han obtenido 774379 muestras válidas, tan solo 1/5 parte de ellas se usaron para entrenar el modelo híbrido. Los datos empleados se seleccionaron al azar para asegurar la generalización del modelo. Por tanto, se han usado un total de 154873 muestras en la fase de modelado.

Asimismo, para la validación final del modelo híbrido obtenido, se han usado las muestras de otras pruebas diferentes. Concretamente han sido 4832 las muestras que no se utilizaron en la fase de modelado. Estos nuevos datos se utilizaron en la fase de validación, y corresponden a dos pruebas diferentes (1489 muestras en la primera y 3343 en la segunda).

4. Resultados

Los resultados de este trabajo se dividirán en tres partes diferenciadas: la clasificación, el modelado y la validación.

4.1. Resultados de clasificación

Los grupos se han creado utilizando el algoritmo K-Means descrito en el punto anterior. Se han creado un total de 9 sistemas híbridos con diferente número de grupos (entre 2 y 9), dado que inicialmente no se conoce el número óptimo de grupos para el sistema. El algoritmo se ha entrenado con una inicialización aleatoria de los centroides, y se ha repetido el entrenamiento 20 veces para asegurar la elección de los mejores centroides finales. El número de muestras utilizadas en la fase de modelado para cada uno de los grupos se puede ver en la tabla 1.

Tabla 1: N° de muestras en cada grupo creado

	Grupo 1	Grupo 2	Grupo 3	Grupo 4	Grupo 5	Grupo 6	Grupo 7	Grupo 8	Grupo 9	Grupo 10
Global	154875									
Híbrido 2	75293	79582								
Híbrido 3	47566	51159	56150							
Híbrido 4	12459	35107	51159	56150						
Híbrido 5	12459	28288	28685	35104	50339					
Híbrido 6	12459	22342	27783	28388	28799	35104				
Híbrido 7	266	12459	22342	27863	28042	28799	35104			
Híbrido 8	266	4875	10292	22342	27863	28043	28799	32396		
Híbrido 9	266	2602	4834	8211	22342	27863	28042	28799	31916	
Híbrido 10	266	2095	2602	5933	8211	22342	27856	28048	28723	28799

4.2. Resultados del modelado

Las redes neuronales utilizadas se han configurado con una sola capa oculta. La capa de entrada tiene 6 entradas, dos por cada variable (Corriente, Temperatura y Voltaje), su valor actual y en su estado anterior; mientras que en la última capa sólo se tiene una salida, el valor de el voltaje resultante del modelo de predicción. Para la selección de la mejor topología para cada red neuronal, se han probado varias para cada grupo. En las diferentes configuraciones se varió el número de neuronas en la capa oculta entre 1 y 15; utilizando siempre como función de activación la de tipo Tangente-Sigmoidal. Para la capa de salida, se eligió la función de activación lineal, ya que es la que se suele usar para regresión como ya se ha mencionado.

Para el entrenamiento de las ANNs se utilizó el algoritmo de optimización Levenberg-Marquardt; y para finalizar el entrenamiento se utilizó el método del gradiente descendente utilizando el Error Cuadrático Medio, del inglés *Mean Squared Error (MSE)*. Este método de optimización se utiliza para resolver problemas no lineales; en este caso, la obtención de los mejores parámetros de ajuste de las redes neuronales. Como se trata de un método iterativo, el método del gradiente descendente es el que selecciona el momento en el que detener las iteraciones al detectar un mínimo en la función objetivo. Las mejores topologías de ANNs para cada grupo se pueden ver en la tabla 2.

Tabla 2: Configuración del modelo de regresión de cada grupo

	Grupo 1	Grupo 2	Grupo 3	Grupo 4	Grupo 5	Grupo 6	Grupo 7	Grupo 8	Grupo 9	Grupo 10
Global	ANN11									
Híbrido 2	ANN11	ANN13								
Híbrido 3	ANN14	ANN14	ANN12							
Híbrido 4	ANN14	ANN12	ANN11	ANN11						
Híbrido 5	ANN11	ANN12	ANN14	ANN11	ANN11					
Híbrido 6	ANN13	ANN11	ANN12	ANN11	ANN14	ANN15				
Híbrido 7	ANN11	ANN13	ANN11	ANN12	ANN14	ANN11	ANN15			
Híbrido 8	ANN11	ANN11	ANN12	ANN12	ANN13	ANN11	ANN13	ANN14		
Híbrido 9	ANN11	ANN14	ANN12	ANN12	ANN11	ANN12	ANN11	ANN14	ANN11	
Híbrido 10	ANN11	ANN11	ANN13	ANN11	ANN11	ANN12	ANN11	ANN13	ANN13	ANN14

En la tabla 3 se pueden ver los valores de MSE obtenidos en cada grupo utilizando la técnica de validación cruzada K-Fold

como se ha mencionado anteriormente.

Tabla 3: MSE para cada grupo individual de los modelos híbridos obtenidos

	Grupo 1	Grupo 2	Grupo 3	Grupo 4	Grupo 5	Grupo 6	Grupo 7	Grupo 8	Grupo 9	Grupo 10
Global	0,0016									
Híbrido 2	0,0008	0,0022								
Híbrido 3	0,0008	0,0045	0,0008							
Híbrido 4	0,0000	0,0012	0,0593	0,0008						
Híbrido 5	0,0000	0,0010	0,0113	0,0011	0,0023					
Híbrido 6	0,0000	0,0006	0,0023	0,0009	0,0109	0,0010				
Híbrido 7	0,0000	0,0000	0,0006	0,0115	0,0010	0,0066	0,0013			
Híbrido 8	0,0000	0,0000	0,0000	0,0007	0,0021	0,0016	0,0062	0,0012		
Híbrido 9	0,0000	0,0001	0,0000	0,0000	0,0010	0,0028	0,0010	0,0091	0,0012	
Híbrido 10	0,0000	0,0000	0,0001	0,0000	0,0000	0,0006	0,0022	0,0011	0,0016	0,0070

Para calcular la mejor configuración para el modelo híbrido se ha tenido en cuenta el número de muestras en cada grupo.

En la tabla 4 se muestra el valor del error en términos de MSE ponderado para los modelos híbridos.

Tabla 4: Error cuadrático medio para cada configuración híbrida

	Global	Modelo híbrido (modelos locales)								
		2	3	4	5	6	7	8	9	10
MSE	0,0016	0,0015	0,0020	0,0202	0,0033	0,0029	0,0039	0,0022	0,0027	0,0023

4.3. Procedimiento de validación

Se han utilizado dos conjuntos de datos independientes para realizar el proceso de validación de los modelos. La primera

prueba se puede ver en la figura 8, donde el voltaje real medido está representado con una línea azul punteada, y el predicho por el modelo con una línea verde continua.




Figura 8: Prueba 1 de validación

Para la segunda prueba, se utiliza un conjunto de datos de una prueba típica para celdas de combustible. En esta prueba, el voltaje de salida aumenta progresivamente hasta el valor máximo de diseño de la celda, y luego se vuelve a disminuir. En la

figura 9 se muestran tanto los valores reales como los predichos por el modelo para el voltaje de salida. Al igual que en la anterior, los datos reales con una línea azul punteada, y los predichos con una línea verde continua.




Figura 9: Prueba 2 de validación

Para cada una de las pruebas de validación se han calculado diferentes medidas de error. Se pueden ver resumidas en la tabla 5, donde se muestra el error cuadrático medio (MSE),

el error cuadrático medio normalizado (NMSE), el error medio absoluto (MAE) y el error medio absoluto porcentual (MAPE).

Tabla 5: Errores obtenidos en las pruebas de validación

	MSE	NMSE	MAE	MAPE
Prueba de validación 1	0,3944	0,0188	0,0688	0,1179
Prueba de validación 2	0,1154	0,0013	0,0668	0,1375

5. Conclusiones y trabajos futuros

En este trabajo se ha desarrollado un modelo de predicción para el voltaje de salida de una celda de combustible. Con él, se predice el valor del voltaje un instante posterior al momento de la predicción. Conocer el valor de las variables con antelación permite que los sistemas de control puedan ser más eficientes. En este caso, por ejemplo, el modelo desarrollado permitiría anticipar el control de la celda de combustible ante futuras variaciones.

Se seleccionó un modelo híbrido al tratarse de un sistema no lineal, y después de las fases de modelado y validación se comprobó que los mejores resultados se han obtenido con una configuración de 2 grupos, con un MSE final de 0,0015. Durante las pruebas de validación, cuya estructura dispone de dos redes neuronales con 11 y 13 neuronas en la capa oculta respectivamente, se obtuvieron unos valores de error medio porcentual menores del 0,15 % en las dos pruebas.

Como trabajos futuros se planteará tanto el estudio una mejor forma de medir el error de los modelos híbridos; como la aplicación de este tipo de modelo creado en un bucle de control real para comprobar si se puede mejorar el resultado. Además,

se tratará de comparar la aplicación de la topología híbrida obtenida en este trabajo con modelos cualitativos basados en reglas; así como su posible aplicación en tareas de detección de fallos, o de creación de sensores virtuales.

Agradecimientos

Los autores de este trabajo quieren agradecer el soporte en materia de financiación del Ministerio de Economía, Industria y Competitividad del Gobierno de España a través del proyecto H2SMART- μ GRID (DPI2017-85540-R).

Referencias

Alaiz Moretón, H., Calvo Rolle, J., García, I., Alonso Alvarez, A., 2011. Formalization and practical implementation of a conceptual model for PID controller tuning. *Asian Journal of Control* 13 (6), 773–784.

Alique, A., Haber, R. E., Haber, R. H., Ros, S., Gonzalez, C., 2000. A neural network-based model for the prediction of cutting force in milling process. A progress study on a real case. In: *Intelligent Control, 2000. Proceedings of the 2000 IEEE International Symposium on*. pp. 121–125. DOI: 10.1109/ISIC.2000.882910

- Amphlett, J. C., Baumert, R. M., Mann, R. F., Peppley, B. A., Roberge, P. R., Harris, T. J., 1995. Performance modeling of the Ballard Mark IV solid polymer electrolyte fuel cell i. Mechanistic model development. *Journal of the Electrochemical Society* 142 (1), 1–8.
DOI: 10.1149/1.2043866
- Amphlett, J. C., Mann, R. F., Peppley, B. A., Roberge, P. R., Rodrigues, A., 1996. A model predicting transient responses of proton exchange membrane fuel cells. *Journal of Power Sources* 61 (1–2), 183–188.
DOI: 10.1016/S0378-7753(96)02360-9
- Andújar, J. M., Segura, F., 2009. Fuel cells: History and updating. A walk along two centuries. *Renewable and Sustainable Energy Reviews* 13 (9), 2309–2322.
DOI: 10.1016/j.rser.2009.03.015
- Andújar, J. M., Segura, F., Durán, E., Rentería, L. A., 2011. Optimal interface based on power electronics in distributed generation systems for fuel cells. *Renewable Energy* 36 (11), 2759–2770.
DOI: 10.1016/j.renene.2011.04.005
- Andújar, J. M., Segura, F., Vasallo, M. J., 2008. A suitable model plant for control of the set fuel cell–DC/DC converter. *Renewable Energy* 33 (4), 813–826.
DOI: 10.1016/j.renene.2007.04.013
- Ballard, 2009. FCgenTM-1020ACS/FCvelocityTM-1020ACS Fuel Cell Stack. Ballard Product Manual and Integration Guide. Document Number MAN5100192-0GS.
- Ballard, 2018. FCgen1020-ACS fuel cell from Ballard Power Systems.
URL: <http://www.ballard.com/docs/default-source/backup-power-documents/fcgen-1020acs.pdf>
- Barragán, A. J., Al-Hadithi, B. M., Andújar, J. M., Jiménez, A., 2015. Formal methodology for analyzing the dynamic behavior of nonlinear systems using fuzzy logic. *Revista Iberoamericana de Automática e Informática Industrial (RIAI)* 12 (4), 434–445.
- Barragán, A. J., Al-Hadithi, B. M., Jiménez, A., Andújar, J. M., 2014. A general methodology for online TS fuzzy modeling by the extended kalman filter. *Applied Soft Computing* 18 (0), 277–289.
DOI: 10.1016/j.asoc.2013.09.005
- Baruque, B., Porras, S., Jove, E., Calvo-Rolle, J. L., 2019. Geothermal heat exchanger energy prediction based on time series and monitoring sensors optimization. *Energy* 171, 49–60.
DOI: 10.1016/j.energy.2018.12.207
- Bertoluzzo, M., Buja, G., 2011. Development of electric propulsion systems for light electric vehicles. *Industrial Informatics, IEEE Transactions on* 7 (3), 428–435.
DOI: 10.1109/TII.2011.2158840
- Calvo-Rolle, J. L., Casteleiro-Roca, J. L., Quintián, H., del Carmen Meizoso-Lopez, M., 2013. A hybrid intelligent system for PID controller using in a steel rolling process. *Expert Systems with Applications* 40 (13), 5188–5196.
DOI: 10.1016/j.eswa.2013.03.013
- Calvo-Rolle, J. L., Fontenla-Romero, O., Pérez-Sánchez, B., Guijarro-Berdinas, B., 2014. Adaptive inverse control using an online learning algorithm for neural networks. *Informatica* 25 (3), 401–414.
DOI: 10.15388/Informatica.2014.20
- Calvo-Rolle, J. L., Quintian-Pardo, H., Corchado, E., del Carmen Meizoso-López, M., García, R. F., 2015. Simplified method based on an intelligent model to obtain the extinction angle of the current for a single-phase half wave controlled rectifier with resistive and inductive load. *Journal of Applied Logic* 13 (1), 37–47.
DOI: 10.1016/j.jal.2014.11.010
- Casteleiro-Roca, J.-L., Barragán, A. J., Segura, F., Calvo-Rolle, J. L., Andújar, J. M., 2019. Fuel cell output current prediction with a hybrid intelligent system. *Complexity* 2019.
- Casteleiro-Roca, J. L., Calvo-Rolle, J. L., Meizoso-López, M.-C., Piñón-Pazos, A., Rodríguez-Gómez, B. A., 2015. Bio-inspired model of ground temperature behavior on the horizontal geothermal exchanger of an installation based on a heat pump. *Neurocomputing* 150, 90–98.
- Casteleiro-Roca, J.-L., Jove, E., Gonzalez-Cava, J. M., Pérez, J. A. M., Calvo-Rolle, J. L., Alvarez, F. B., 2018. Hybrid model for the ANI index prediction using remifentanyl drug and EMG signal. *Neural Computing and Applications*, 1–10.
- Casteleiro-Roca, J.-L., Jove, E., Sánchez-Lasheras, F., Méndez-Pérez, J.-A., Calvo-Rolle, J.-L., de Cos Juez, F. J., 2017. Power cell SOC modelling for intelligent virtual sensor implementation. *Journal of Sensors* 2017.
- De las Heras, A., Vivas, F., Segura, F., Andújar, J., 2018a. From the cell to the stack. a chronological walk through the techniques to manufacture the pefcs core. *Renewable and Sustainable Energy Reviews* 96, 29–45.
DOI: 10.1016/j.rser.2018.07.036
- De las Heras, A., Vivas, F., Segura, F., Redondo, M., Andújar, J., 2018b. Air-cooled fuel cells: Keys to design and build the oxidant/cooling system. *Renewable Energy* 125, 1–20.
DOI: 10.1016/j.renene.2018.02.077
- del Brío, B., Molina, A., 2006. Redes neuronales y sistemas borrosos. Ra-Ma.
- Famouri, P., Gemmen, R., 2003. Electrochemical circuit model of a PEM fuel cell. In: *Power Engineering Society General Meeting, 2003, IEEE*. Vol. 3. pp. 1436–1440.
DOI: 10.1109/PES.2003.1267364
- Fontanet, J. G. G., Cervantes, A. L., Ortiz, I. B., 2016. Alternatives of control for a furuta's pendulum. *Revista Iberoamericana de Automática e Informática Industrial RIAI* 13 (4), 410–420.
DOI: 10.1016/j.riai.2016.05.008
- Galipienso, M., Quevedo, M., Pardo, O., Ruiz, F., Ortega, M., 2003. Inteligencia artificial. Modelos, técnicas y áreas de aplicación. Editorial Paraninfo.
- García, R. F., Rolle, J. L. C., Castelo, J. P., Gomez, M. R., 2014. On the monitoring task of solar thermal fluid transfer systems using NN based models and rule based techniques. *Engineering Applications of Artificial Intelligence* 27 (0), 129–136.
DOI: 10.1016/j.engappai.2013.06.011
- García, R. F., Rolle, J. L. C., Gomez, M. R., Catoira, A. D., 2013. Expert condition monitoring on hydrostatic self-levitating bearings. *Expert Systems with Applications* 40 (8), 2975–2984.
DOI: 10.1016/j.eswa.2012.12.013
- Ghanghermeh, A., Roshan, G., Orosa, J. A., Calvo-Rolle, J. L., Costa, A. M., 2013. New climatic indicators for improving urban sprawl: A case study of tehran city. *Entropy* 15 (3), 999–1013.
DOI: 10.3390/e15030999
- Gordillo, F., Aracil, J., Alamo, T., 1997. Determining limit cycles in fuzzy control systems. In: *IEEE International Conference on Fuzzy Systems*. Vol. 1. pp. 193–198.
DOI: 10.1109/FUZZY.1997.616367
- Harston, A. M. C., Pap, R., 2014. *Handbook of Neural Computing Applications*. Elsevier Science.
- Hilera González, J. R., Martínez Hernando, V. J., 2000. *Redes neuronales artificiales: fundamentos, modelos y aplicaciones*. Ra-Ma.
- Hou, Y., Yang, Z., Fang, X., 2011. An experimental study on the dynamic process of PEM fuel cell stack voltage. *Renewable Energy* 36 (1), 325–329.
DOI: 10.1016/j.renene.2010.06.046
- Irigoyen, E., nano, G. M., 2013. A NARX neural network model for enhancing cardiovascular rehabilitation therapies. *Neurocomputing* 109, 9–15.
DOI: 10.1016/j.neucom.2012.07.031
- Jove, E., Antonio Lopez-Vazquez, J., Isabel Fernandez-Ibanez, M., Casteleiro-Roca, J.-L., Luis Calvo-Rolle, J., 2018a. Hybrid intelligent system to predict the individual academic performance of engineering students. *INTERNATIONAL JOURNAL OF ENGINEERING EDUCATION* 34 (3), 895–904.
- Jove, E., Blanco-Rodríguez, P., Casteleiro-Roca, J. L., Moreno-Arboleda, J., López-Vázquez, J. A., de Cos Juez, F. J., Calvo-Rolle, J. L., 2018b. Attempts prediction by missing data imputation in engineering degree. In: *International Joint Conference SOCO'17-CISIS'17-ICEUTE'17 León, Spain, September 6–8, 2017, Proceeding*. Springer International Publishing, Cham, pp. 167–176.
- Jove, E., Gonzalez-Cava, J. M., Casteleiro-Roca, J.-L., Méndez-Pérez, J.-A., Antonio Rebozo-Morales, J., Javier Pérez-Castelo, F., Javier de Cos Juez, F., Luis Calvo-Rolle, J., 2018c. Modelling the hypnotic patient response in general anaesthesia using intelligent models. *Logic Journal of the IGPL* 00 (0), 1–13.
DOI: 10.1093/jigpal/jzy032
- Kim, J., Lee, S.-M., Srinivasan, S., Chamberlin, C. E., 1995. Modeling of proton exchange membrane fuel cell performance with an empirical equation. *Journal of the Electrochemical Society* 142 (8), 2670–2674.
DOI: 10.1149/1.2050072
- Kirubakaran, A., Jain, S., Nema, R., 2009. A review on fuel cell technologies and power electronic interface. *Renewable and Sustainable Energy Reviews* 13 (9), 2430–2440.
DOI: 10.1016/j.rser.2009.04.004
- Li, X., Deng, Z.-H., Wei, D., Xu, C.-S., Cao, G.-Y., 2011. Parameter optimization of thermal-model-oriented control law for pem fuel cell stack via novel genetic algorithm. *Energy Conversion and Management* 52 (11), 3290–3300.
DOI: 10.1016/j.enconman.2011.05.012
- López, R., Fernández, J., 2008. *Las Redes Neuronales Artificiales*. Netbiblo.
- López-Baldán, M. J., García-Cerezo, A., Cejudo, J. M., Romero, A., 2002.

- Fuzzy modeling of a thermal solar plant. *International Journal of Intelligent Systems* 17 (4), 369–379.
DOI: 10.1002/int.10026
- Machón-González, I., López-García, H., Calvo-Rolle, J. L., 2010. A hybrid batch som-ng algorithm. In: *Neural Networks (IJCNN), The 2010 International Joint Conference on*. pp. 1–5.
- MacQueen, J., 1967. Some methods for classification and analysis of multivariate observations. In: *Proceedings of the Fifth Berkeley Symposium on Mathematical Statistics and Probability, Volume 1: Statistics*. pp. 281–297.
- Márquez, J. M. A., Piña, A. J. B., Arias, M. E. G., 2009. A general and formal methodology for designing stable nonlinear fuzzy control systems. *IEEE Transactions on Fuzzy Systems* 17 (5), 1081–1091.
DOI: 10.1109/TFUZZ.2009.2021984
- Mehta, V., Cooper, J., 2003. Review and analysis of pem fuel cell design and manufacturing. *Journal of Power Sources* 114 (1), 32–53.
DOI: 10.1016/S0378-7753(02)00542-6
- Moody, J., Darken, C., 1989. Fast learning in networks of locally-tuned processing units. *Neural Computation* 1 (2), 281–294.
DOI: 10.1162/neco.1989.1.2.281
- Moreira, M. V., da Silva, G. E., 2009. A practical model for evaluating the performance of proton exchange membrane fuel cells. *Renewable Energy* 34 (7), 1734–1741.
DOI: 10.1016/j.renene.2009.01.002
- Orallo, J., Quintana, M., Ramírez, C., 2004. *Introducción a la minería de datos*. Editorial Alhambra S.A.
- Paska, J., Biczal, P., Klos, M., 2009. Hybrid power systems - an effective way of utilising primary energy sources. *Renewable Energy* 34 (11), 2414–2421.
DOI: 10.1016/j.renene.2009.02.018
- Quintán, H., Calvo-Rolle, J. L., Corchado, E., 2014. A hybrid regression system based on local models for solar energy prediction. *Informatica* 25 (2), 265–282.
- Quintan Pardo, H., Calvo Rolle, J. L., Fontenla Romero, O., 2012. Application of a low cost commercial robot in tasks of tracking of objects. *Dyna* 79 (175), 24–33.
- Ralph, T., Hards, G., Keating, J., Campbell, S., Wilkinson, D., Davis, M., St-Pierre, J., Johnson, M., 1997. Low cost electrodes for proton exchange membrane fuel cells: Performance in single cells and ballard stacks. *Journal of the Electrochemical Society* 144 (11), 3845–3857.
DOI: 10.1149/1.1838101
- Rolle, J., Gonzalez, I., Garcia, H., 2011. Neuro-robust controller for non-linear systems. *Dyna* 86 (3), 308–317.
DOI: 10.6036/3949
- Ross, D., 2003. Power struggle [power supplies for portable equipment]. *IEE Review* 49 (7), 34–38.
DOI: 10.1049/ir:20030705
- Segura, F., Andújar, J., 2015. Modular PEM fuel cell SCADA & simulator system. *Resources* 4 (3), 692–712.
DOI: 10.3390/resources4030692
- Segura, F., Andújar, J. M., Durán, E., 2011. Analog current control techniques for power control in PEM fuel-cell hybrid systems: A critical review and a practical application. *IEEE Transactions on Industrial Electronics* 58 (4), 1171–1184.
DOI: 10.1109/TIE.2010.2049710
- Segura, F., Andújar, J., 2015. Step by step development of a real fuel cell system. design, implementation, control and monitoring. *International Journal of Hydrogen Energy* 40 (15), 5496–5508.
DOI: 10.1016/j.ijhydene.2015.01.178
- Segura, F., Bartolucci, V., Andújar, J., 2017. Hardware/software data acquisition system for real time cell temperature monitoring in air-cooled polymer electrolyte fuel cells. *Sensors (Switzerland)* 17 (7).
DOI: 10.3390/s17071600
- Van Bussel, H., Koene, F., Mallant, R. K., 1998. Dynamic model of solid polymer fuel cell water management. *Journal of Power Sources* 71 (1–2), 218–222.
DOI: 10.1016/S0378-7753(97)02744-4
- Viñuela, P., León, I., 2004. *Redes de neuronas artificiales: un enfoque práctico*. Pearson Educación - Prentice Hall.
- Vivas, F., De las Heras, A., Segura, F., Andújar, J., 2018. A review of energy management strategies for renewable hybrid energy systems with hydrogen backup. *Renewable and Sustainable Energy Reviews* 82, 126–155.
DOI: 10.1016/j.rser.2017.09.014
- Ziogou, C., Voutetakis, S., Papadopoulou, S., Georgiadis, M., 2011. Modeling, simulation and experimental validation of a pem fuel cell system. *Computers and Chemical Engineering* 35 (9), 1886–1900.
DOI: 10.1016/j.compchemeng.2011.03.013