

Jornadas de Automática

Aprendizaje de la señal de control para un electrolizador tipo PEM

Becerra-Mora, Y.^{a,c,*}, Chicaiza, W. D.^a, Barros-Queiroz, J. S.^{a,b}, Acosta J. A.^a, Escaño, J. M.^a

^aDpto. de Ingeniería de Sistemas y Automática, Universidad de Sevilla, Camino de los Descubrimientos s/n., 41092 Sevilla, España.

^bDepartamento de Engenharia Elétrica, Universidade Federal do Ceará (UFC), Fortaleza, CE, Brasil.

^cCorporación Unificada Nacional, Dept. of Electronics Engineering, Bogotá, Colombia

To cite this article: Becerra-Mora, Y., Chicaiza, W. D., Barros-Queiroz, J. S., Acosta J. A., Escaño, J. M. 2024. Control Signal Learning for a PEM Electrolyser. Jornadas de Automática, 45. <https://doi.org/10.17979/ja-cea.2024.45.10892>

Resumen

Este trabajo propone el aprendizaje de una señal de control para un electrolizador tipo PEM, considerando variables de entrada y salida del sistema como la corriente eléctrica suministrada por una fuente fotovoltaica, la temperatura ambiente y la energía disipada por el caudal del sistema de refrigeración acoplado al electrolizador. Los datos de corriente eléctrica y temperatura ambiente son medidos por el sistema. Por otro lado, los datos de energía disipada por el caudal del sistema de refrigeración fueron obtenidos a partir de simulaciones de un controlador de temperatura que utiliza la técnica de Control Predictivo Basado en Modelos. Se proponen dos técnicas de aprendizaje: Gaussian Mixture Model / Gaussian Mixture Regression y un modelo NeuroFuzzy. Los resultados de las simulaciones demuestran que las técnicas de aprendizaje modelaron con precisión el comportamiento de la señal de control en el electrolizador.

Palabras clave: Electrolizador PEM, Modelos de Mezcla Gaussianas, Regresión de Mezcla Gaussiana, Neuro-Borroso, Aprendizaje

Control Signal Learning for a PEM Electrolyser

Abstract

This work proposes a signal control learning for a PEM electrolyser, considering system input and output variables such as electrical current supplied by a photovoltaic source, ambient temperature, and the energy dissipation by the flow rate of the cooling system coupled to the electrolyser. The electric current and ambient temperature data are measured by the system. On the other hand, the energy dissipation data by the cooling system flow rate were obtained from simulations of a temperature controller that uses the Model Predictive Control technique. Two learning techniques are proposed: Gaussian Mixture Model and Gaussian Mixture Regression, and NeuroFuzzy model. Simulation results demonstrate that the learning techniques accurately modeled the control signal in the electrolyser.

Keywords: Electrolyser PEM, Gaussian Mixture Model, Gaussian Mixture Regression, Neuro-Fuzzy, Learning

1. Introducción

La transición energética es un paso fundamental en la lucha contra el cambio climático y en la búsqueda de un futuro sostenible. Esta transición implica la sustitución de fuentes de energía basadas en combustibles fósiles por fuentes renovables, como la solar, eólica y el hidrógeno verde. La impor-

tancia de esta transición ha sido reconocida en acuerdos internacionales, como el Acuerdo de París, adoptado en 2015, que tiene como objetivo limitar el aumento de la temperatura global a muy por debajo de los 2 °C con respecto a los niveles preindustriales (United Nations Framework Convention on Climate Change (UNFCCC), 2015). Además, la Unión Europea y otros países han lanzado estrategias específicas, como la

*Autor para correspondencia: yeyson.becerra@cun.edu.co
Attribution-NonCommercial-ShareAlike 4.0 International (CC BY-NC-SA 4.0)

Hoja de Ruta del Hidrógeno del Ministerio para la Transición Ecológica y el Reto Demográfico (MITERD) (2020) en España, que delinean el papel crucial del hidrógeno verde en la descarbonización de la economía.

Los electrolizadores desempeñan un papel vital en la producción de hidrógeno verde, utilizando la electrólisis del agua para generar hidrógeno sin emisiones de carbono cuando se alimentan con electricidad proveniente de fuentes renovables (Carmo et al., 2013). Entre los diferentes tipos de electrolizadores, los de membrana de intercambio de protones (PEM) se destacan por su eficiencia y capacidad para operar en altas densidades de corriente, lo que los hace especialmente adecuados para la integración con este tipo de energía, que puede ser intermitente. La producción de hidrógeno verde mediante electrolizadores PEM no solo contribuye a la reducción de las emisiones de gases de efecto invernadero, sino que también ofrece una solución viable para el almacenamiento de energía renovable y la estabilización de la red eléctrica. Lo que hace que esta tecnología sea más favorable para conectarse a una generación renovable es su capacidad para producir hidrógeno de alta pureza de manera eficiente y su rápida respuesta a las variaciones de carga. Sin embargo, tiene desventajas, como el costo relativamente alto debido al uso de catalizadores de metales nobles y la sensibilidad a la calidad del agua utilizada.

Un desafío significativo para los electrolizadores PEM es el sobrecalentamiento cuando se alimentan con fuentes renovables. La intermitencia de estas fuentes puede causar variaciones rápidas en la cantidad de energía suministrada al electrolizador, lo que resulta en ciclos de carga y descarga que generan calor adicional. Además, la operación en altas densidades de corriente para maximizar la producción de hidrógeno contribuye al aumento de la temperatura interna. Este calentamiento puede comprometer la eficiencia y la vida útil del electrolizador, acelerando el desgaste de los materiales de la membrana y los electrodos, y reduciendo la eficiencia electroquímica (Molina et al., 2024).

Para mitigar estos problemas, la implementación de un sistema de control de temperatura es crucial. Uno de los métodos más efectivos es la integración de un sistema de refrigeración. Este sistema, considerado uno de los componentes auxiliares del electrolizador, elimina el calor excesivo, mantiene la temperatura dentro de un rango ideal y previene el sobrecalentamiento. La circulación de un fluido refrigerante a través del electrolizador absorbe el calor generado durante la operación y lo disipa hacia el ambiente externo, garantizando un funcionamiento eficiente y prolongando la durabilidad del equipo.

La integración de un sistema de control de temperatura es esencial para el funcionamiento eficiente y duradero de los electrolizadores tipo PEM cuando se alimentan con fuentes de energía renovable (Ogumerem and Pistikopoulos, 2020; Keller et al., 2022). Esto no solo garantiza la producción constante de hidrógeno de alta pureza, sino que también protege el equipo contra los efectos adversos del sobrecalentamiento, asegurando así una operación más confiable y económica a largo plazo.

En los casos en donde se desconoce el modelo matemático del sistema e inclusive la señal de control con la cual se regula la variable manipulada, métodos de aprendizaje tales como GMM/GMR (Cohn et al., 1996) o sistemas de inferencia borrosa (Suganthi et al., 2015), permiten construir estimaciones

a partir de las mediciones realizadas en el sistema.

Con el fin de regular la temperatura de salida en el electrolizador, este trabajo propone estimar una señal de control a partir de las entradas y salidas del sistema.

El resto del artículo se estructura de la siguiente manera. En la Sección 2 se presenta el caso de estudio, así como una breve descripción del sistema. En la sección 3, se presentan los métodos de aprendizaje utilizados. En la sección 4, se describen los experimentos realizados con cada uno de los métodos propuestos y un análisis de sus resultados. Finalmente, en la sección 5, se resume los principales aportes del estudio y las propuestas de trabajos futuros.

2. Caso de estudio

El electrolizador es un sistema compuesto por dos electrodos conductores de corriente eléctrica, ánodo y cátodo, separados por un electrolito. La electrólisis del agua ocurre cuando se aplica una diferencia de potencial entre los electrodos, iniciando una reacción exotérmica de oxidación-reducción en su interior, es decir, la energía eléctrica se transforma en energía química. Esta reacción promueve la ruptura de la molécula de agua en oxígeno e hidrógeno. Cuando la energía utilizada en este proceso es suministrada por fuentes renovables, el hidrógeno producido se denomina hidrógeno verde.




Figura 1: Vista frontal del electrolizador

El electrolizador (véase Fig. 1) se puede definir según ciertas características relacionadas con la temperatura, la presión y el tipo de electrolito. Según el tipo de electrolito, se puede clasificar como alcalino, de membrana de intercambio de protones (PEM) y de óxido sólido (SOE).

En este estudio se utilizó el electrolizador PEM, ya que, según la literatura (El-Shafie, 2023; Benghanem et al., 2024), es el tipo más recomendable para conectarse a fuentes de energía renovables. Debido a su capacidad de operar con altas densidades de corriente, es ideal para manejar las intermitencias y la variabilidad de la generación.

Por otro lado, su electrolito está compuesto por una membrana formada por metales nobles, como el platino, lo que encarece su costo de fabricación y requiere una alta inversión. Otra desventaja de esta tecnología está relacionada con su vida útil, que es menor en comparación con la del electrolizador alcalino. Esta vida útil puede verse aún más comprometida cuando este tipo de electrolizador se somete a altas temperaturas, lo que provoca la degradación de la membrana y reduce la eficiencia del sistema.

De esta forma, el control de la temperatura del electrolizador se vuelve imprescindible. A través de este sistema de control, es posible asegurar un rango de temperatura de operación segura, garantizando una mayor eficiencia del sistema, con una mayor producción de hidrógeno, y una menor degradación de la membrana, prolongando la vida útil del dispositivo.

El controlador de temperatura para el electrolizador está basado en el modelo térmico presentado en (Mora and Bordons, 2022) el cual describe el balance energético del sistema a través de (1):

$$\frac{dT_{el}}{dt} = \frac{1}{C_t} (\dot{Q}_{gen} - \dot{Q}_{loss} - \dot{Q}_{cool}) \quad (1a)$$

$$\dot{Q}_{gen} = n_c I_{el} (V_{el} - V_{tm}) \quad (1b)$$

$$\dot{Q}_{loss} = \frac{1}{R_t} (T_{el} - T_{amb}) \quad (1c)$$

donde T_{el} es la temperatura del electrolizador (K), C_t es la capacidad térmica de la pila (J/K), \dot{Q}_{gen} es el calor generado en el sistema debido a las irreversibilidades o sobretensiones del proceso (W), \dot{Q}_{loss} es el calor que se pierde por interacción con el entorno por convección y radiación (W), \dot{Q}_{cool} es el calor disipado por el sistema de refrigeración (W), n_c es el número de celdas, I_{el} es la corriente aplicada al electrolizador, V_{el} es el voltaje aplicado al electrolizador desde el modelo electroquímico, V_{tm} es el termonutral voltaje, R_t es la resistencia térmica y T_{amb} es la temperatura ambiente. Reemplazando las Ecuaciones (1b) y (1c) en (1a), se obtiene:

$$\frac{dT_{el}}{dt} = \frac{1}{C_t} [n_c I_{el} (V_{el} - V_{tm}) - \frac{1}{R_t} (T_{el} - T_{amb}) - \dot{Q}_{cool}] \quad (2)$$

Pasando todo al lado izquierdo de la Ecuación (2), queda:

$$f(T_{el}, \dot{T}_{el}, I_{el}, T_{amb}, \dot{Q}_{cool}) = 0 \quad (3)$$

Resultando una ecuación diferencial no lineal de primer orden (3) que depende del estado/salida y sus derivadas (T_{el}, \dot{T}_{el}), perturbaciones (I_{el}, T_{amb}) y la acción de entrada o control (\dot{Q}_{cool}).

El control predictivo basado en modelo (Camacho and Bordons, 1999) ha demostrado ser una de las estrategias que mejor desempeño ha logrado en la industria de procesos. Linealizando la ecuación (3) en el entorno de un punto de trabajo, definido por una temperatura deseada T_{ref} , se puede formular el control predictivo como:

$$\min_{\dot{Q}_{cool}} \left\{ J(\dot{Q}_{cool}) = \delta \sum_{i=1}^{N_p} (T_{ref}(t+i) - T_{el}(t+i|t))^2 + \lambda \sum_{i=1}^{N_u} \dot{Q}_{cool}(t+i) \right\}$$

s. a.

$$\dot{Q}_{cool} \leq \dot{Q}$$

donde N_p, N_u son los horizontes de predicción y control, respectivamente, δ, λ , factores de ponderación, para el ajuste del controlador y \dot{Q} el límite máximo del caudal.

El cálculo de la acción de control, implica resolver un problema de optimización con restricciones, en tiempo real, lo cual, puede llevar un tiempo elevado en un controlador lógico programable. La motivación de este trabajo es la obtención de la señal de control mediante modelos de aprendizaje que sí puedan ser implementados en controladores industriales.

2.1. Datos empleados en el estudio

El tiempo de simulación corresponde a 86400 segundos, lo que equivale a valores de un día en concreto (24h). Las mediciones realizadas en cada una de las variables del estudio fueron tomadas cada segundo.

Los datos de perturbaciones (I_{el}, T_{amb}), fueron medidos y recogidos a lo largo de las distintas estaciones del año en la ciudad de Sevilla (España). Así, la variable T_{amb} tiene 5 estados distintos (otoño, invierno, primavera, verano y verano caliente), mientras que I_{el} presenta 2 estados (despejado y nublado). Véase Figuras 2 y 3 respectivamente; además notase el comportamiento no lineal de estas perturbaciones hacia el sistema

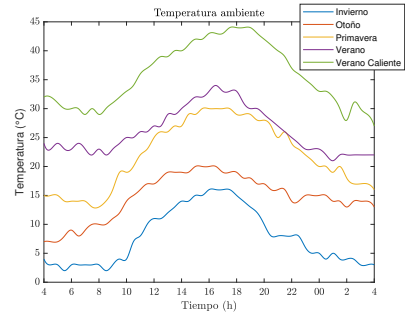


Figura 2: Temperatura ambiente (T_{amb}).

El comportamiento de I_{el} proviene del sistema fotovoltaico, mostrando la influencia de la irradiancia solar sobre esta variable.

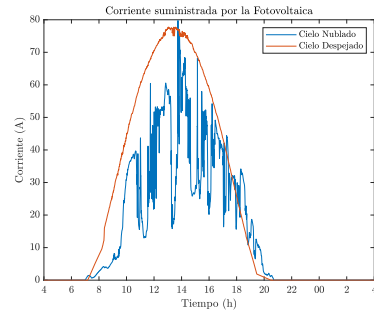


Figura 3: Corriente electrolizador (I_{el}).

El enfoque de aprendizaje propuesto (véase Figura 4) toma datos de las entradas y salida del electrolizador tipo PEM, este conjunto de datos es ingresado a los métodos de aprendizaje para obtener una serie de parámetros que permita estimar, junto a las entradas del sistema, la señal de control resultante \hat{Q}_{el} (estimación de \dot{Q}_{cool}).



Figura 4: Enfoque de aprendizaje.

3. Métodos de aprendizaje

En esta sección se presentan los métodos empleados para aprender una señal de control que permita estabilizar la temperatura del electrolizador tipo PEM a una referencia de 30 °C. Por un lado se utiliza GMM/GMR, para aprender y estimar la salida del sistema; por otro lado, se utiliza un modelo NF que ajusta los parámetros de sus capas en base a datos de operación de la planta.

En estos métodos es necesario definir las entradas y salidas del sistema, para este estudio las entradas son T_{amb} , T_{el} y I_{el} ; mientras que la salida en este caso es \hat{Q}_{cool} (señal de control). Se propone aprender la señal de control a partir de las mediciones (entradas/salida) realizadas en el electrolizador tipo PEM, bajo diversas condiciones tanto en la temperatura ambiente como en la corriente suministrada por la fuente fotovoltaica.

3.1. Estimación de la señal de control con Gaussian Mixture Model y Gaussian Mixture Regression

Métodos de aprendizaje no supervisado como el GMM permiten la clasificación de los datos sin tener que etiquetarla. Este método requiere definir un número de funciones Gaussianas K para devolver la media μ_k , la varianza Σ_k y la probabilidad a priori π_k de cada una de estas. Para inicializar estos parámetros se puede utilizar el algoritmo K-means, posteriormente se utiliza el algoritmo de maximización de la esperanza (EM) para encontrar los parámetros óptimos.

$$\mu_k = \begin{bmatrix} \mu_k^I \\ \mu_k^O \end{bmatrix}, \quad \Sigma_k = \begin{bmatrix} \Sigma_k^I & \Sigma_k^{IO} \\ \Sigma_k^{OI} & \Sigma_k^O \end{bmatrix} \quad (4)$$

Los subíndices $I = \{T_{amb}, T_{el}, I_{el}\}^T$ y $O = \{\hat{Q}_{cool}\}^T$ corresponden a las entradas y salida del sistema respectivamente. Cuanto más compleja sea la dinámica que se intenta aprender, mayor número de Gaussianas se deben utilizar. El conjunto de datos en el cual se basa el aprendizaje del sistema, esta dado por las entradas y salida mencionadas previamente. La estimación de la señal de control \hat{Q}_{el} , la cual es la salida del sistema en este caso, se obtiene a través de los parámetros encontrados en el GMM y de emplear la siguiente ecuación que describe al GMR

$$\hat{Q}_{el} = \sum_{k=1}^K h_k(I) \left(\mu_k^O + \frac{\Sigma_k^{OI}}{\Sigma_k^O} (I - \mu_k^I) \right), \quad h_k(I) = \frac{\pi_k P(I|k)}{\sum_{j=1}^K \pi_j P(I|j)} \quad (5)$$

donde h_k es un término no lineal (Bishop, 2006), $P(I|k)$ es una función de densidad de probabilidad que se encuentra definida por la distribución normal Gaussiana e I representa la matriz que contiene las entradas.




Figura 5: Diagrama de bloques del sistema.

3.2. Estimación de la señal de control a través de un modelo NeuroFuzzy

El modelo NeuroFuzzy es una técnica que se engloba dentro de las diversas técnicas de Inteligencia Artificial, es muy aplicada para capturar el comportamiento no lineal en distintos sistemas. Esta técnica se basa en un Sistema Neuro-Borroso Adaptativo, estructurado en una red de cinco capas (Jang, 1993). Aprovecha la capacidad de aprendizaje y la estructura relacional de las Redes Neuronales Artificiales junto con el mecanismo de toma de decisiones de Logica Borrosa. Puede construir un mapa de entrada-salida basado en el conocimiento humano en forma de reglas difusas “if-then”, lo que permite manejar datos de entrada imprecisos.

$$\text{IF } T_{amb} \text{ is } A_{1j} \text{ and } I_{el} \text{ is } B_{2j} \text{ and } T_{el} \text{ is } C_{3j} \\ \text{THEN : } \hat{Q}_j(x) = g_{0j} + g_{1j}T_{amb} + g_{2j}I_{el} + g_{3j}T_{el}$$

La red neuronal borrosa utiliza los conjuntos de datos de entrenamiento y validación, en el proceso de aprendizaje, con el fin de capturar el comportamiento no lineal de la variable elegida como salida, en este caso (\hat{Q}_{cool}). Con estos datos, la red ajusta los parámetros antecedentes y consecuentes que conforman las reglas borrosas del sistema de inferencia borroso (FIS) resultante. Los parámetros antecedentes lo conforman las medias (c) y desviación típica (σ) de las funciones de pertenencia Gaussiana de cada conjunto borroso (A_{1j} , B_{2j} , C_{3j}) mientras que los parámetros consecuentes (g_{0j} , g_{1j} , g_{2j} , g_{3j}), son los coeficientes de cada función polinómica de primer orden, que viene definida por el número de reglas que tendrá el FIS (Jang, 1993).

El resultado final del FIS es la media ponderada de cada resultado de la regla, donde (\bar{w}) es la relación entre la fuerza de disparo de la regla j -ésima y la suma de las fuerzas de disparo de todas las reglas.

$$\hat{Q}_{el} = \sum_j \bar{w}_j \hat{Q}_j \quad (6)$$

4. Experimentos

Para corroborar la eficiencia del controlador aprendido, se han llevado a cabo una serie de experimentos que permiten comparar la temperatura de salida del electrolizador T_{el} a partir de una señal de control real, \hat{Q}_{cool} , y la aprendida, \hat{Q}_{el} , (véase Figura 5). El aprendizaje se realiza a partir de los datos obtenidos de la T_{amb} en las distintas estaciones del año (primavera, verano, verano-caliente, otoño e invierno), de la I_{el} generada a partir de una fuente fotovoltaica (despejado o nublado) y de la señal de control \hat{Q}_{cool} que regula T_{el} , haciendo que esta no supere los 30 °C.

Los casos considerados para la construcción del conjunto de datos son: primavera despejado, primavera nublado, verano despejado, verano nublado, verano-caliente despejado, verano-caliente nublado, otoño despejado, otoño nublado, invierno despejado e invierno nublado. Cada caso contiene 86400 muestras para cada una de las variables descritas previamente.

Una vez realizado el aprendizaje de la señal de control \hat{Q}_{el} , esta se valida en 4 escenarios distintos (primavera nublado, verano despejado, otoño nublado e invierno despejado). Las condiciones iniciales de las cuales parte la T_{el} para cada una de las estaciones son: primavera (15°C), verano (24°C), verano-caliente (32°C), otoño (7°C) e invierno (4°C).

4.1. Enfoque GMM/GMR

Como se describió previamente, estos algoritmos requieren definir un número de funciones Gaussianas K que permitan ajustarse a los datos que se intentan aprender, entre mayor sea el tamaño del conjunto de datos y más complejas sean las dinámicas que se intentan aprender, mayor número de Gaussianas se deben utilizar. Para el caso que se presenta en este trabajo, se ha seleccionado un $K = 10$ ya que con valores de K menores, la señal de control no se aprende tan bien.

Inicialmente GMM aprende del conjunto de datos que se tiene, generando en su salida matrices de media $\mu_k \in \mathbb{R}^{4 \times 10}$, matrices de varianza $\Sigma_k \in \mathbb{R}^{4 \times 4 \times 10}$ y vectores de probabilidades a priori $\pi_k \in \mathbb{R}^{1 \times 10}$. A este punto, los datos han sido aprendidos y agrupados en cada una de las Gaussianas.

Una vez obtenidos los parámetros devueltos por el GMM, se procede a estimar la señal de control \hat{Q}_{el} a partir de las entradas propuestas (T_{amb} , I_{el} , T_{el}) con GMR. Recordar que T_{el} se emplea como una entrada más en este proceso de aprendizaje/estimación.

4.2. Enfoque NeuroFuzzy

El proceso de aprendizaje de la red neuro borrosa, utiliza como entradas el conjunto de variables de entrada-salida (I , O) descritas anteriormente. Antes de ingresar al proceso donde se ajustan los parámetros antecedentes y consecuentes de la red, se aplica un método de agrupación sustractiva (SC). En este paso previo, se ha aplicado un rango de influencia (IR) de la agrupación de 0.7, con el cual se obtiene un número de regla ($j = 4$), que a su vez define el número de funciones de pertenencia (MFs) Gaussianas que contendrá cada conjunto borroso ($F_{ij} \subseteq \{A_{ij}, B_{ij}, C_{ij}\}$), donde i representa la entrada i -ésima del sistema. El IR seleccionado determina la distancia dentro de la cual cada punto de datos influirá en la formación de clústeres. Este valor de 0.7 generalmente resulta en clústeres de tamaño moderado, lo cual equilibra la cantidad de reglas difusas generadas que busca alcanzar un compromiso entre la complejidad y la precisión del modelo.

Tabla 1: Parámetros obtenidos durante el proceso de aprendizaje

Parámetros antecedentes						
MFs						
Inputs	T_{amb}		I_{el}		T_{el}	
	A_{ij}	c_{ij}	B_{ij}	c_{ij}	C_{ij}	c_{ij}
j	σ_{ij}	c_{ij}	σ_{ij}	c_{ij}	σ_{ij}	c_{ij}
1	0.1757	0.4015	0.1480	0.0837	0.1751	0.6439
2	0.2428	0.1618	0.1681	0.0012	0.2345	0.2188
3	0.0797	0.8033	0.3561	0.0728	0.2412	0.8730
4	0.0797	0.7981	0.1437	0.9505	0.1582	0.9975
Parámetros consecuentes						
\hat{Q}_{el}						
j	g_{0j}	g_{1j}	g_{2j}	g_{3j}		
1	-0.0052	-0.0196	-0.0079	0.0234		
2	-0.0003	0.0074	0.0023	-0.0029		
3	-0.4658	1.5152	0.4370	-0.5912		
4	0.2759	1.5467	0.6619	-1.4976		

Posteriormente, ya en el proceso de aprendizaje, se emplea un método de aprendizaje híbrido que emplea el

descenso de gradiente para ajustar las medias (c_{ij}) y las desviaciones típicas σ_{ij} de las Gaussianas de cada conjunto borroso (A_{ij} , B_{ij} , C_{ij}). Mientras que los coeficientes (g_{0j} , g_{1j} , g_{2j} , g_{3j}) de cada función polinómica de primer orden (cuatro en total), se adaptan mediante mínimos cuadrados.

Los parámetros antecedentes y consecuentes se ajustan en base a los datos elegidos de entrada-salida en cada época o barrido. La Tabla 1 muestra los parámetros resultantes tras finalizar el proceso de aprendizaje.

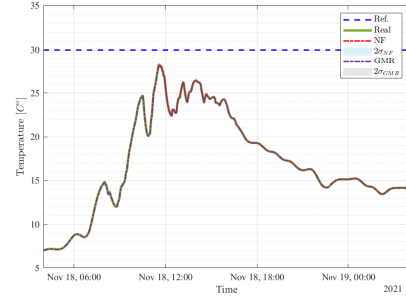


Figura 6: Caso otoño nublado




Figura 7: Caso invierno despejado




Figura 8: Caso primavera nublado




Figura 9: Caso verano despejado

Tabla 2: Índices de error obtenidos al evaluar cada modelo en diferentes días

Índices		Model Output							
		Soleado verano		Soleado invierno		Nublado primavera		Nublado otoño	
		GMR	NF	GMR	NF	GMR	NF	GMR	NF
\bar{e}	[°C]	0.026	0.047	0.003	-0.003	-0.014	0.037	0.009	25.421e-6
σ_e	[°C]	0.230	0.193	0.021	0.064	0.522	0.496	0.022	0.141e-3
$RMS E$	[°C]	0.232	0.198	0.021	0.064	0.522	0.497	0.025	0.144e-3
R^2	-	0.995	0.997	1.0	1.0	0.992	0.993	1.0	1.0

4.3. Análisis de resultados

En los casos seleccionados para la validación de la señal de control aprendida \hat{Q}_{el} , se compara la temperatura del electrolizador en función de la respuesta real de la señal de control, de la respuesta aprendida a partir de GMM/GMR y de la respuesta aprendida a partir del modelo NF; además se presenta un intervalo de confianza del 95 % que permite calcular la desviación estandar de las estimaciones de cada método de aprendizaje (véase Figura 6 - Figura 9). Cualitativamente se puede observar que el sistema ha tenido un buen aprendizaje, debido a que todas las curvas se mantienen por debajo de la referencia o fluctuando en torno a ella (30°C).

Cuantitativamente, se utilizaron cuatro índices de error para comparar la salida de ambos modelos con los datos de salida predichos reales: la media de error aritmético (\bar{e}), la desviación estándar de error (σ_e), la raíz del error cuadrático medio ($RMS E$) y el coeficiente de determinación ¹ R^2 . Los índices de error vienen dados por las ecuaciones descritas en (7).

$$\bar{e} = \frac{\sum_{i=1}^N (x_{i,j} - \hat{x}_{i,j})}{N}, \quad \sigma_e = \sqrt{\frac{\sum_{i=1}^N (e_{i,j} - \bar{e})^2}{N}}$$

$$RMS E = \sqrt{\frac{\sum_{i=1}^N (x_{i,j} - \hat{x}_{i,j})^2}{N}}, \quad R^2 = 1 - \frac{\sum_{i=1}^N (x_{i,j} - \hat{x}_{i,j})^2}{\sum_{i=1}^N (x_{i,j} - \bar{x}_{i,j})^2} \quad (7)$$

donde N representa el número de muestras en el conjunto de validación, $x_{i,j}$ es la salida real y $\hat{x}_{i,j}$ es la salida de la variable predicha obtenida por cada modelo y $\bar{x}_{i,j}$ es la media de los datos observados.

Según la Tabla 2 se puede apreciar que los modelos obtenidos explican más del 99 % de la variación en la salida a través de las entradas; además, el error encontrado entre la señal real y las estimadas se encuentra por debajo del 1 %.

5. Conclusiones

En este estudio se han presentado dos métodos para el aprendizaje de una señal de control que regula la temperatura de salida en un electrolizador tipo PEM. Se puede corroborar con ambos métodos que la señal de control se aprende correctamente, impidiendo que el sistema alcance temperaturas superiores a los 30°C.

Si bien, con estos primeros resultados se evidencia la viabilidad de aprender una señal de control a partir de los datos, para futuros trabajos se propone un aprendizaje más ambicioso que permita desarrollar un controlador inteligente para diversas referencias. Además, se está trabajando en obtener modelos no lineales basados en Gaussianas para el electrolizador

tipo PEM que permitan implementar un controlador no lineal basado en datos.

Agradecimientos

La publicación es parte del proyecto PID2022-142069OB-I00, financiado por MCIN/AEI/10.13039/501100011033/FEDER, UE. Igualmente, se agradece el apoyo recibido de la agencia de financiación brasileña CAPES (Brasil) [88887.636100/2021-00, 88881.892669/2023-01], al Proyecto 2024/00000362 del VII Plan Propio de Investigación y Transferencia de la Universidad de Sevilla, y al Programa Nacional de Formación Doctoral (Minciencias-Colombia 885-2020).

Referencias

- Benghanem, M., Almohamadi, H., Haddad, S., Mellit, A., Chettibi, N., 2024. The effect of voltage and electrode types on hydrogen production powered by photovoltaic system using alkaline and pem electrolyzers. *International Journal of Hydrogen Energy* 57, 625–636.
- Bishop, C., 2006. *Patter Recognition and Machine Learning*. Springer New York, NY.
- Camacho, E. F., Bordons, C. (Eds.), 1999. *Model predictive control*. Springer-Verlag, Berlin Heidelberg.
- Carmo, M., Fritz, D. L., Mergel, J., Stolten, D., 2013. A comprehensive review on pem water electrolysis. *International Journal of Hydrogen Energy* 38, 4901–4934.
- Cohn, D. A., Ghahramani, Z., Jordan, M. I., 1996. Active learning with statistical models. *Journal of Artificial Intelligence Research* 4, 129–145.
- El-Shafie, M., 2023. Hydrogen production by water electrolysis technologies: A review. *Results in Engineering* 20, 101426.
- Jang, J.-S., 1993. Anfis: adaptive-network-based fuzzy inference system. *IEEE Transactions on Systems, Man, and Cybernetics* 23 (3), 665–685.
- Keller, R., Rauls, E., Hehemann, M., Müller, M., Carmo, M., 2022. An adaptive model-based feedforward temperature control of a 100 kw pem electrolyzer. *Control Engineering Practice* 120, 104992.
- Ministerio para la Transición Ecológica y el Reto Demográfico (MITERD), 2020. Hoja de ruta del hidrógeno: Una apuesta por el hidrógeno renovable. Vicepresidencia Cuarta del Gobierno de España, disponible em: https://www.miteco.gob.es/content/dam/miteco/es/ministerio/planes-estrategias/hidrogeno/hojarutahidrogenorenovable_tcm30-525000.PDF.
- Molina, P., Rios, C., de Leon, C. M., Brey, J., 2024. Heat management system design and implementation in a pem water electrolyser. *International Journal of Hydrogen Energy*.
- Mora, M., Bordons, C., 2022. Desarrollo y validación experimental del modelo dinámico de un electrolizador pem de 1kw para su integración con generación renovable. *XLIII Jornadas de Automática: libro de actas*, 560–567.
- Ogumerem, G. S., Pistikopoulos, E. N., 2020. Parametric optimization and control for a smart proton exchange membrane water electrolysis (pemwe) system. *Journal of Process Control* 91, 37–49.
- Suganthi, L., Iniyan, S., Samuel, A. A., 2015. Applications of fuzzy logic in renewable energy systems – a review. *Renewable and Sustainable Energy Reviews* 48, 585–607.
- United Nations Framework Convention on Climate Change (UNFCCC), 2015. Paris agreement. https://unfccc.int/files/meetings/paris_nov_2015/application/pdf/paris_agreement_spanish_.pdf, accessed: 2024-05-30.

¹ R^2 es un número entre 0 y 1, que mide lo bien que un modelo estadístico predice un resultado. Si $R^2 = 0$, el modelo no describe los resultados, si $0 < R^2 < 1$, el modelo predice parcialmente los resultados, y si $R^2 = 1$, el modelo predice perfectamente los resultados.