

Modelado difuso y control PDC de un sistema de generación de energía basado en un motor de combustión interna con un generador eléctrico

Christian Reyes^a, Julio C. Ramos-Fernandez^b, Eduardo S. Espinoza^{a,c,*}, Rogelio Lozano^a

^aCentro de Investigación y de Estudios Avanzados del Instituto Politécnico Nacional, 07360, Ciudad de México, México.

^bUniversidad Politécnica de Pachuca, 43830, Hidalgo, México

^cConsejo Nacional de Humanidades, Ciencias y Tecnologías, 03940, Ciudad de México, México.

To cite this article: Reyes, C., Ramos-Fernandez, J., Espinoza, E. S., Lozano, R., 2025. Fuzzy modeling and PDC control of a power generation system based on an internal combustion engine with an electric generator. Revista Iberoamericana de Automática e Informática Industrial 22, 13-20. <https://doi.org/10.4995/riai.2024.21616>

Resumen

En este trabajo, se utiliza una estrategia difusa del tipo Takagi-Sugeno (T-S), con parámetros del modelo y control optimizados, aplicado a un sistema de generación de energía (SGE) compuesto por un motor de combustión interna (MCI) acoplado a un generador eléctrico. Con esta estrategia se evita derivar un modelo matemático mediante balance de energía con la termodinámica y el generador eléctrico en su representación no lineal. Primero, se identifica un modelo matemático no lineal para el sistema eléctrico de potencia con datos experimentales de entrada-salida utilizando el algoritmo difuso c-means en las premisas y el consecuente en espacio de estado. Luego, utilizando el algoritmo de enjambre de partículas (PSO), se identifica el parámetro óptimo difuso y se encuentran los polos óptimos del sistema que permiten seleccionar las ganancias del controlador. Dicho controlador está basado en la estrategia de compensación distribuida en paralelo (PDC), en la que para cada consecuente del modelo difuso T-S, se sintoniza un controlador de realimentación de estado. Así mismo, se utilizan desigualdades matriciales lineales (LMI) para demostrar la estabilidad del sistema. Por último, para validar la efectividad de las estrategias propuestas, se realizan pruebas experimentales del SGE usando un motor sin escobillas como carga, haciendo variar el consumo eléctrico.

Palabras clave: Sistema difuso, Takagi-Sugeno, Generación de energía.

Fuzzy modeling and PDC control of a power generation system based on an internal combustion engine with an electric generator

Abstract

In this work, a Takagi-Sugeno (T-S) type fuzzy strategy is used, with optimized model and control parameters, applied to a power generating system composed of an internal combustion engine (ICE) coupled to an electric generator. This strategy avoids deriving a mathematical model by means of energy balance with thermodynamics and the electric generator in its nonlinear representation. First, a nonlinear mathematical model for the electrical power system is identified using the fuzzy c-means algorithm in the premises and the consequent in state space, with experimental input-output data. Then, using the particle swarm algorithm (PSO), the optimal fuzzy parameter is identified and to find the optimal poles of the system for the controller gains. Then, using the parallel distributed compensation (PDC) strategy, for each consequent of the T-S fuzzy model, a state feedback controller is tuned. Also, linear matrix inequalities (LMI) are used to demonstrate the stability of the system. Finally, in order to validate the proposed strategies, experimental physical tests are performed with a brushless motor as load, varying the power consumption.

Keywords: Fuzzy system, Takagi-Sugeno, Energy generation.

*Autor para correspondencia: eduardo.espinoza@cinvestav.mx

1. Introducción

En los últimos años se han desarrollado diferentes tipos de sistemas móviles de generación de energía eléctrica dada la necesidad de contar con mejores fuentes de energía en vehículos autónomos (tales como aplicaciones hacia la aeronáutica Boggero et al. (2019)), ya sea para alimentar sus motores y dispositivos electrónicos, cargar sus baterías, o más aún, para aumentar su tiempo de autonomía.

Los sistemas de generación de energía eléctrica basados en el uso de motores de combustión interna (MCI) en combinación con un motor generador, son ampliamente utilizados en la industria, aplicaciones comerciales y de la vida cotidiana, debido a su gran disponibilidad en el mercado, con bajo mantenimiento y operación en condiciones severas del medio ambiente. Sin embargo, el bajo aprovechamiento energético de los MCI reduce la eficiencia del sistema de generación de energía eléctrica, por lo que recientemente, se han desarrollado diferentes investigaciones que buscan mejorar los resultados de este tipo de sistemas de generación de energía (Lieh et al. (2011)). Dichas investigaciones incluyen el desarrollo de nuevos combustibles y sistemas de cámaras de explosión con nuevos materiales para la operación de los MCI, generadores eléctricos con nuevos materiales más eficientes, arquitecturas para maximizar la eficiencia del combustible (Zacone et al. (2021)) y sistemas de regulación de voltaje y potencia con algoritmos de control con técnicas híbridas de identificación y control automático.

Para efficientizar dichos sistemas, se han abordado diferentes estrategias tales como el uso de innovadoras técnicas de control (Aliramezani et al. (2022); Gao et al. (2021)), o el estudio del compartimiento de sistemas de generación de energía eléctrica con diferentes topologías de redes neuronales artificiales para predecir y ser eficientes las complicadas características de varios tipos de motores con diferentes combustibles (Bhatt and Shrivastava (2022)). Similarmente, la optimización de los sistemas de generación de energía eléctrica se analiza en (Shen et al. (2020)).

No obstante, la mayoría de las técnicas de control utilizadas para la regulación de voltaje, requieren de un modelo matemático del MCI acoplado mecánicamente al generador eléctrico, en consecuencia la interrelación de los modelos matemáticos, con sus implicaciones en la identificación de sus parámetros. Para lo cual, se hace uso de una descripción no lineal, así como la combinación del primer principio de la termodinámica, leyes físicas y datos en estado estacionario del flujo de aire en masa del motor, obtenidos empíricamente (Yang et al. (2022)), lo que resulta en imprecisiones y por otra parte arquitecturas matemáticas de modelos complejos para ser utilizados para derivar técnicas de control automático. De igual forma, los modelos matemáticos existentes para describir las dinámicas de motores eléctricos (Zafar et al. (2021)), están basados en una serie de experimentos para obtener los parámetros de los modelos, lo cual resulta en un proceso costoso.

1.1. Trabajos Relacionados

En (Aliramezani et al. (2022)) los autores presentan una técnica basada en aprendizaje automático para el modelado y control aplicado a un MCI, donde muestran la naturaleza de robustez obtenida con esta técnica de modelado, la cual permite compensar variaciones en la carga eléctrica y cuyo enfoque

garantiza la estabilidad del MCI. En esta técnica de la inteligencia artificial, se requieren cantidades importantes de datos para lograr un buen modelo, además de ser una caja negra, en el sentido de la interpretación de los parámetros y la arquitectura matemática. Lo anterior hace contraste con los modelos y controladores difusos, tales como los sistemas lingüístico Mamdani, donde un experto en el sistema físico, es quien dicta la base de reglas de operación, que no son óptimas, pero están basadas en la experiencia humana. Por otra parte, existe la técnica de modelado y control difuso propuesta por Takagi-Sugeno (T-S), la cual se puede complementar con algoritmos de identificación de parámetros óptimos, así como con diferentes técnicas de control. En el modelo difuso Mamdani, tanto el antecedente como el consecuente son proposiciones difusas, que las eligen los expertos del sistema a modelar o en apañamiento de un experto en modelado difuso, mientras que en el modelado difuso T-S, el antecedente es una proposición difusa y el consecuente es una función matemática, la cual que puede tener una arquitectura en espacio de estado polinomial (Babuška (1998)). Esto, representa una fortaleza para el modelado de sistemas complejos y el control basado en submodelos representados en espacio de estados, como el que se trata en este proyecto de investigación. En (Zhang et al. (2018)), los autores presentan una estrategia de control y gestión de energía basada en lógica difusa para vehículos aéreos no tripulados, en la que desarrollaron un conjunto de reglas difusas para el control, dividiendo efectivamente la potencia entre las dos fuentes de energía: generador eléctrico y MCI.

En la actualidad, existen diferentes trabajos sobre la selección del valor del parámetro difuso m . Por ejemplo, en (Bezdek (2013)) proponen bajo su experiencia un rango de $1.1 \leq m \leq 5$. En tanto en (Bezdek (1993)), los autores encontraron que el valor de m debe ser superior a $n/(n-2)$ (donde n es el número total de objetos de datos en el conjunto de datos) visto desde la perspectiva de la convergencia del algoritmo. Mientras que en (Wu (2012)), se propuso una nueva directriz para la selección de m basada en un análisis robusto de fuzzy c-means, y se sugirió definir a m en un rango de [1.5-4]. En (Zhou et al. (2014)), los autores proponen un método para la selección del valor óptimo m , donde se utilizan cuatro índices de validez de cluster, mostrando que el intervalo óptimo de m es de [2.5-3].

En (Manjarrez et al. (2023)), se aborda el problema de la estimación de la energía utilizando la técnica difusa de T-S, cuyas premisas fueron desarrolladas utilizando el algoritmo de fuzzy c-means y los consecuentes utilizando polinomios lineales, mientras que el parámetro m utilizado en el algoritmo de fuzzy c-means, fue encontrado mediante optimización por enjambre de partículas (PSO, por sus siglas en inglés). En (Shrivastava and Khan (2018)), los autores analizan la utilización de técnicas de soft computing basadas en el algoritmo de clasificación difusa c-means y la estructura de reglas difusas del tipo T-S en investigaciones desarrolladas en el campo de MCI para la generación de energía eléctrica alterna.

En (You et al. (2022)) se establece un modelo de control de red con retardo de tiempo para predecir la salida del sistema de control. Para resolver el problema de que el algoritmo metaheurístico de PSO es propenso a caer en la optimalidad local, proponen una fórmula de ajuste no lineal de los parámetros del algoritmo PSO basada en el número de iteraciones y utilizan el

algoritmo T-S para llegar a la solución global óptima. En (Shouran and Alseid (2022)) los autores emplearon la estructura de control lógico difuso para el control de frecuencia de carga en un sistema eléctrico interconectado de doble área, además del método PSO para mejorar su rendimiento.

En el presente trabajo de investigación se utilizó la técnica propuesta por Takagi-Sugeno y Tanaka para la identificación de un sistema de generación de energía basado en un esquema de motor de combustión interna-generador controlado mediante una estrategia difusa óptima que permite regular el voltaje generado por el sistema. Con dicha estrategia, se busca evitar la necesidad de derivar un modelo matemático complejo, es decir, no se requiere hacer un estudio de todas las características del MCI, como lo son sus propiedades termodinámicas. Como se mostró anteriormente, el algoritmo PSO con lógica difusa ya ha sido previamente utilizado en diferentes tipos de aplicaciones, sin embargo, en este trabajo se plantea utilizarlos para sistemas de generación de energía basados en un MCI a partir de una función objetivo propuesta de datos de entrada y salida con la que se optimiza tanto el parámetro m del algoritmo fuzzy c-means, como los polos del algoritmo de control empleado.

1.2. Contribuciones Principales

El objetivo de esta investigación busca contribuir como un apoyo a la docencia en análisis y síntesis de sistemas difusos, así como para la identificación de un modelo matemático para un sistema de generación de energía reduciendo el costo computacional para la obtención de los parámetros del controlador. Las contribuciones principales del presente trabajo de investigación, se describen a continuación:

- i). Utilizando únicamente los datos de entrada-salida correspondientes a la señal PWM enviada a la unidad de carburación del MCI y la señal de voltaje analógica obtenida del proceso de generación eléctrica, se desarrolla y se implementa una estrategia que permite identificar, fuera de línea, un modelo difuso del tipo T-S del sistema de generación, con los consecuentes de cuatro reglas difusas en espacio de estado. Dicho modelo está compuesto por cuatro submodelos lineales, que representan el funcionamiento entrada-salida en el espacio de aprendizaje.
- ii). Para la obtención del modelo difuso, los consecuentes se determinan con la técnica de agrupamiento de datos difusos (clustering), en específico, el algoritmo de fuzzy c-means, que hace una búsqueda óptima de las premisas de las reglas difusas. En esta técnica, un problema abierto es determinar el parámetro difuso m , que permite hacer una clasificación de los datos en grupos con afinidad difusa. En este trabajo se propone usar el algoritmo PSO para elegir el mejor valor del parámetro difuso m , dentro del espacio de búsqueda. Es decir, con el mejor valor de m , se clasifican los datos de aprendizaje de las premisas de las reglas difusas, con mejor similitud, lo que hace que se obtenga una mejor interpretación y menor error de aproximación del modelo difuso.
- iii). Se propone un controlador paralelo distribuido (PDC) cuyas ganancias son obtenidas por el método de asignación de polos, que en conjunto con los parámetros de los modelos en espacio de estado de cada submodelo y los mejores

polos, obtenidos similarmente usando el algoritmo PSO, logran que el sistema en lazo cerrado sea global asintóticamente estable. Esta técnica de control basada en el modelo difuso T-S, utiliza las premisas de las reglas y cambia los consecuentes por la ley de control, correspondientes a las retro de estado (Wang and Tanaka (2004)).

El resto del artículo está organizado de la siguiente manera: en la Sección 2, se presenta la descripción del sistema de generación de energía. En la Sección 3 se muestra el algoritmo de modelado difuso T-S con las premisas en forma de clustering y consecuentes lineales, así como la construcción del sistema difuso, aplicado al sistema de generación eléctrica y se describe la utilización del método de PSO. En la Sección 4 se muestra el controlador PDC para la regulación del voltaje del sistema. Finalmente, en la Sección 5 se muestran las conclusiones obtenidas de este trabajo de investigación.

2. Sistema de Generación de Energía

Para el desarrollo de la plataforma experimental, se usó una configuración en serie para el sistema de generación en la que el MCI impulsa el generador eléctrico (Benevieri et al. (2021)). La energía eléctrica que se genera se suministra a un motor eléctrico sin escobillas, el cual se utiliza como carga para identificar un modelo difuso del sistema de generación de energía y en consecuencia se diseña un controlador difuso para regular el voltaje de generación. En la Figura 1 se muestra la plataforma experimental, mientras que el diagrama de conexiones del SGE se presenta en la Figura 2.




Figura 1: Componentes de la plataforma experimental.

El SGE mostrado en la Figura 2 se compone de una tarjeta myRIO-1900 de National Instruments utilizada para la adquisición y procesamiento de datos. Donde $r(k)$ es la referencia deseada, $u(k)$ la señal de PWM1, $e(k)$ es el error del sistema, $V_G(k)$ es el voltaje generado y k_r es la ganancia de precompensación. Tanto el motor generador como el motor de carga eléctrica son motores sin escobillas U12 II (120KV), mientras que el controlador electrónico de velocidad (ESC) es un Flame HV de 100 Amperes, todos ellos de T-Motor. El servomotor es el DS3230MG de 30 kg/cm. El rectificador de diodos trifásico es de 100 amperes y 1600 volts. Mientras que el MCI utilizado es el modelo Stihl-2MIX, el cual es un motor monocilíndrico de 1.1 HP / 0.8 kW y 22.2 cm³, cuyo funcionamiento es de 2 tiempos.

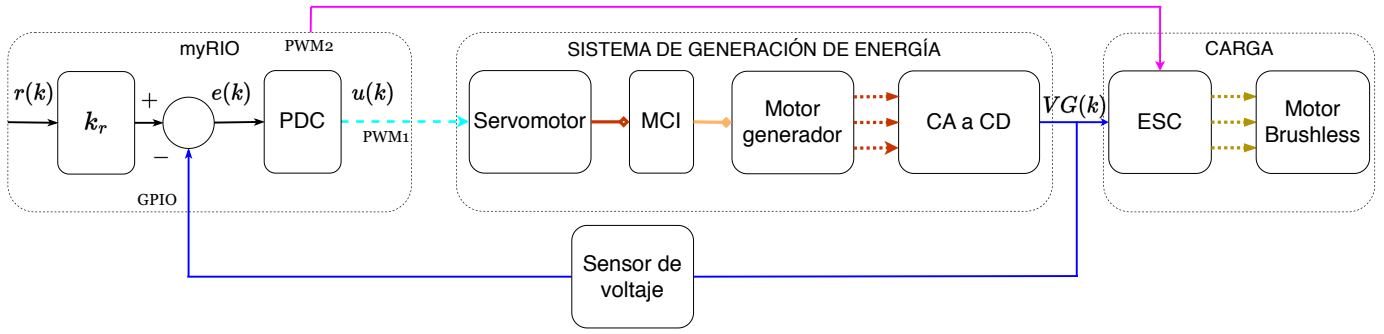


Figura 2: Diagrama de conexiones del sistema de generación de energía.

3. Modelado Difuso T-S

El método de clustering o nubes de datos, para el diseño de sistemas difusos, consiste en agrupar los datos en subconjuntos basados en similitudes entre ellos. La técnica de agrupación de c-means y el algoritmo de mínimos cuadrados, es una forma de identificación difusa para entrenar modelos difusos del tipo T-S. El método de vecindad mas cercana o clustering, se usa para entrenar sistemas difusos, agrupando los datos de entrada-salida de un sistema que se desea identificar, los cuales son representados por centros de clustering o prototipos de funciones de pertenencia (Wang (1999)).

El algoritmo iterativo de fuzzy c-means, se usa para encontrar los grados de membresía $\mu_{ik} \in [0, 1]$ y los centros de agrupamiento c_i , que son los prototipos de las funciones de pertenencia.

La función objetivo para determinar los centros de cluster es definida como:

$$J(U, c) = \sum_{i=1}^c \sum_{k=1}^N (\mu_{ik})^m \|z_k - c_i\|_I^2 \quad (1)$$

donde $m > 1$ es el parámetro de diseño difuso a definir, N es el número de datos entrada-salida para efectuar el aprendizaje, c es el número de clusters, $z = \{z_1, z_2, \dots, z_N\}$ es la matriz de aprendizaje, que puede ser una matriz con elementos de series de tiempo, $U = [\mu_{ik}]$ es la matriz de particiones difusa, con $i = 1, 2, \dots, c$ y $k = 1, 2, \dots, N$, mientras que $c = [c_1, c_2, \dots, c_c]$ es el vector de centros a identificar. Las distancias Euclidianas de cada muestra de los datos a clasificar, respecto de los centros, se calculan como:

$$D_{ikI}^2 = \|z_k - c_i\|_I^2 = (z_k - c_i)^T I (z_k - c_i). \quad (2)$$

donde I es la matriz identidad. La solución de la función objetivo (1) para las funciones de pertenencia de cada cluster esta dada por (3) y (4) de forma iterativa:

$$\mu_{ik} = \frac{1}{\sum_{j=1}^c \left(\frac{D_{ikI}}{D_{jkI}}\right)^{2/(m-1)}} \quad (3)$$

$$c_i = \frac{\sum_{k=1}^N (\mu_{ik})^m z_k}{\sum_{k=1}^N (\mu_{ik})^m} \quad (4)$$

donde μ_{ik} es el valor de pertenencia del i -ésimo cluster en la k -ésima muestra, con $1 \leq i \leq c$, $1 \leq k \leq N$.

La construcción del modelo difuso T-S a partir de datos experimentales se resolvió en dos pasos: 1) la identificación de la estructura y 2) la estimación de parámetros (Takagi and Sugeno (1985)). En el paso de identificación de la estructura, se determinaron las variables antecedente y consecuente del modelo. A partir de secuencias en el tiempo de los datos disponibles, se construyó la matriz $X \in \mathbb{R}^{N \times n}$ dada como:

$$X = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1n} \\ x_{21} & x_{22} & \dots & x_{2n} \\ \vdots & \vdots & \dots & \vdots \\ x_{N1} & x_{N2} & \dots & x_{Nn} \end{bmatrix} \quad (5)$$

y el vector de salida $Y \in \mathbb{R}^{N \times 1}$ dado por:

$$Y = [y_1, \dots, y_N]^T \quad (6)$$

el cual se desea aproximar con la ecuación lineal:

$$\hat{y} = \theta X \quad (7)$$

donde n es el número de vectores o estados y θ son los parámetros consecuentes lineales a identificar. Mediante la solución del algoritmo de mínimos cuadrados (8), se realiza la identificación de los parámetros consecuentes lineales θ_i para cada i -ésima regla usando:

$$\theta_i = [X^T \Gamma_i X]^{-1} X^T \Gamma_i Y \quad (8)$$

Se define la matriz $\Gamma_i = \text{diag}(\mu_{ik}) \in \mathbb{R}^{N \times N}$, la cual contiene en su diagonal principal los valores de disparo normalizados de la i -ésima regla difusa, que le da una ponderación debido a los valores de pertenencia a cada regla ($i = 1, \dots, c$) y cada instante ($k = 1, \dots, N$).

Se consideró un modelo difuso T-S con i reglas R_i , en el que cada i -ésima regla la premisa está representada por un centro de cluster. En este trabajo de investigación, se propone un modelo en espacio de estados en tiempo discreto, dado por: (Wang and Tanaka (2004):

$$R_i : \text{Si } z_k \text{ está en } c_i \text{ entonces } \begin{cases} x^i(k+1) = A_i x(k) + B_i u(k) \\ y^i(k) = C_i x(k) \end{cases} \quad (9)$$

donde $x^i(k+1)$ es el vector de estados en el instante $(k+1)$, $A_i \in \mathbb{R}^{n \times n}$ es la matriz de estado del sistema, $x(k) \in \mathbb{R}^n$ es el vector de estados en el instante (k) , $B_i \in \mathbb{R}^{n \times m}$ es la matriz de entrada del sistema, $C_i \in \mathbb{R}^{q \times n}$ es la matriz de salida, $u(k) \in \mathbb{R}^m$ es el vector de entrada del sistema y $y^i(k) \in \mathbb{R}^q$ es el vector de salida. La salida global de la base de reglas difusas, es la suma ponderada por los valores de disparo de las reglas difusas,

que se determina por medio de la defuzificación de los pesos ponderados, como se indica en (Xie et al. (2019)), dada como:

$$x(k + 1) = \sum_{i=1}^R \sum_{j=1}^R h_i(z(k))h_j(z(k)) \{A_i x(k) + B_j u(k)\} \quad (10)$$

donde w_i son los grados de activación y h_i denota el peso de la i -ésima regla calculado a partir de las funciones de pertenencia en la premisa

$$w_i(z(k)) = \prod_{i=1}^N \mu_{ik}(z(k)) \quad (11)$$

$$h_i(z(k)) = \frac{w_i(z(k))}{\sum_{i=1}^R w_i(z(k))} \quad (12)$$

3.1. Identificación difusa de un sistema de segundo orden

Es bien sabido que cualquier técnica de identificación de sistemas en tiempo real es comúnmente afectada por incertidumbres y errores de identificación. De hecho, si se realizan múltiples ejecuciones de un proceso de identificación aplicado a exactamente el mismo modelo, terminaríamos obteniendo resultados similares pero ligeramente diferentes (Rubio et al. (2019)). Por esta razón, decidimos utilizar lógica difusa para determinar un modelo que fuese lo suficientemente aproximado al sistema físico y que nos permitiera realizar regulación del voltaje deseado a pesar de los errores e incertidumbres inherentes.

Dado que el eje central del modelado con lógica difusa, radica en la base de conocimiento del sistema a modelar, nos basamos en la observación del funcionamiento del sistema de generación de energía eléctrica de este trabajo de investigación y las mediciones experimentales de la entrada-salida, para proponer cuatro reglas difusas. De esta forma, la agrupación de las dinámicas de operación del generador de energía se dividió en cuatro clusters, usando los datos de aprendizaje $Z = [VG(k - 1) \quad VG(k) \quad PWM1(k)]$. Dichos valores corresponden a la serie de tiempo de las mediciones del voltaje del generador eléctrico y la excitación PWM1, las cuales son respectivamente, en la identificación de los estados, x_1 , x_2 y la señal de control $u(k)$ mostrada en la Figura 2.

Los centros de los prototipos de las funciones de pertenencia fueron determinados usando el algoritmo de c-means. En la Tabla 1 se presentan las coordenadas de los centroides de los cuatro clusters obtenidos usando el software Matlab.

Tabla 1: Valores de las coordenadas para cada centroide.

Centroides	x_1	x_2	u
1	41.4878	41.6192	0.6732
2	39.8547	39.4982	0.9438
3	40.6281	40.5098	0.4467
4	38.3561	38.3242	0.3565

Se propusieron cuatro clusters, y sus correspondientes reglas difusas. La metodología utilizada para definir el número de clusters se basó en el comportamiento de las regiones de operación del MCI. Dichas regiones mostraron tener un comportamiento no lineal debido al tipo de actuador (servomotor)

utilizado en el cuerpo de aceleración del MCI. Esto se debe a zonas muertas causadas tanto por el retardo de tiempo existente al encender el motor, como a la cantidad de pasos del servomotor. La Figura 3 muestra el comportamiento de los cuatro clusters de datos adquiridos para la identificación del sistema.




Figura 3: Ubicación de los clusters y centroides del sistema.

La estructura en espacio de estado que se propone para cada una de las cuatro reglas no considera todos los efectos que actúan en el sistema, pero sirve bien para el propósito del presente trabajo de investigación, está dada de la siguiente forma:

$$\begin{bmatrix} x_1^i(k+1) \\ x_2^i(k+1) \end{bmatrix} = \underbrace{\begin{bmatrix} 0 & 1 \\ a_2^i & a_1^i \end{bmatrix}}_{A_i} \begin{bmatrix} x_1(k) \\ x_2(k) \end{bmatrix} + \underbrace{\begin{bmatrix} 0 \\ b^i \end{bmatrix}}_{B_i} u(k)$$

$$y^i(k) = \underbrace{\begin{bmatrix} 0 & 1 \end{bmatrix}}_{C_i} \begin{bmatrix} x_1(k) \\ x_2(k) \end{bmatrix} \quad (13)$$

donde a_1^i , a_2^i y b^i son los parámetros lineales que se identifican con el algoritmo de mínimos cuadrados ponderados (8). La Tabla 2 muestra los valores obtenidos de A_i y B_i para los cuatro subsistemas discretos identificados, es decir, para las cuatro reglas difusas, las cuales están dadas por la ecuación (9).

Tabla 2: Valores obtenidos para A_i y B_i .

A_1		B_1		A_3		B_3	
0	1	0	0	0	1	0	0
0.1466	-0.0997	64.4829	0.1347	-0.0990	65.2492		
A_2		B_2		A_4		B_4	
0	1	0	0	0	1	0	0
0.1911	-0.1065	59.7786	0.1614	-0.1053	63.2293		

3.2. Optimización del parámetro difuso m

Para mejorar la aproximación de la base de reglas difusas TS con los datos de aprendizaje entrada-salida, se propone usar el algoritmo PSO para la búsqueda óptima del parámetro m del algoritmo difuso c-means. Por otra parte también se utiliza el algoritmo PSO para la selección óptima de los polos del sistema en lazo cerrado de las reglas difusas de (9), con una estructura de control por retro de estado para cada una de las reglas difusas. En esta búsqueda de los mejores parámetros dentro del espacio de aprendizaje con las mediciones de entrada-salida,

se utilizó el algoritmo PSO, como se muestra en (Wang et al. (2018); Eberhart and Kennedy (1995)).

La función de costo que se utiliza en el algoritmo PSO es el MSE, con la medición de voltaje del generador y la salida del modelo difuso identificado de la siguiente forma:

$$\text{MSE} = \sqrt{\frac{\sum_{k=1}^N (VG(k) - x_2(k))^2}{N}} \quad (14)$$

donde $VG(k)$ es el valor de la salida del sistema físico y $x_2(k)$ es la salida (variable de estado) del sistema identificado a través del modelado difuso. El MSE es elegido como función de costo para optimizar el parámetro m , que se muestra en (3).

La Tabla 3 muestra los valores utilizados en el algoritmo PSO, así como las cotas de búsqueda asignadas al parámetro m y el valor óptimo de m .

Tabla 3: Parámetros utilizados en el algoritmo PSO y valor obtenido del parámetro m .

Valor óptimo m	Cotas	No. de partículas	Coficiente de inercia ω	ς_1, ς_2	No. de iter.
2.9786	1.1, 3	300	0.0917	0.5959	50

Para obtener el valor de las constantes ς_1 y ς_2 se calcula el parámetro ξ :

$$\xi = \frac{2\kappa}{|2 - \phi - \sqrt{\phi^2 - 4\phi}|} \quad (15)$$

donde $\phi = \phi_1 + \phi_2$. Los constantes ϕ_1 y ϕ_2 están acotadas como $\phi \geq 4$ y $0 \leq \kappa \leq 1$, cuyos valores son definidos en (Clerc and Kennedy (2002)) para el algoritmo de PSO. Por lo que ς_1 y ς_2 se obtienen como:

$$\begin{aligned} \varsigma_1 &= \xi\phi_1 \\ \varsigma_2 &= \xi\phi_2 \end{aligned} \quad (16)$$

3.3. Optimización de los polos del sistema en lazo cerrado

Para el proceso de optimización de los polos del sistema en lazo cerrado, se propone acotar los límites de búsqueda en el rango $[0.01, 0.9]$, de manera que los polos que se obtengan, estén sobre el eje real dentro del círculo unitario. La función objetivo utilizada es (17), donde $r(k)$ es la referencia del voltaje deseado y $x_2(k)$ es la variable de estado, que aproxima de forma difusa el voltaje generado en lazo cerrado:

$$\text{MSE} = \sqrt{\frac{\sum_{k=1}^N (r(k) - x_2(k))^2}{N}} \quad (17)$$

La Tabla 4 muestra los valores utilizados en el algoritmo PSO, así como los valores obtenidos para los polos en lazo cerrado.

Tabla 4: Parámetros utilizados en el algoritmo PSO y valores obtenidos para los polos p_i

Polos óptimos	Cotas	No. de partículas	Coficiente de inercia ω	ς_1, ς_2	No. de iter.
0.22, 0.89	0.01, 0.9	300	0.3820	0.9549	50

4. Control Difuso PDC

Para lograr la estabilización del sistema T-S, se utilizó la técnica de control basada en el compensador paralelo distribuido. En esta estrategia de control, el consecuente de cada regla difusa del modelo (9), se sustituye por una ley de control con la forma de retro de estado lineal (Lilly (2010); Wang and Tanaka (2004)). En el enfoque PDC con asignación de polos, se proponen los valores propios de $(A_i - B_i K_i)$. El consecuente para cada regla difusa del PDC esta dado por:

$$u_i(k) = -K_i x(k) \quad (18)$$

La salida global del PDC, es decir, la agregación difusa de todas las reglas de control, tiene la siguiente forma:

$$u(k) = \sum_{i=1}^R h_i(z(k)) u_i(k) \quad (19)$$

donde K_i es el vector de ganancias de la i -ésima regla mostradas en la Tabla 5 y $k_r = 2.29$ es una ganancia de precompensación, mostrada en la Figura 2, la cual es encontrada mediante el Teorema del Valor Final, analizando el valor en estado estacionario de la señal de error $e(k)$ ante una entrada escalón $r(k)$ (Chen (2012)). Para la obtención de las ganancias del PDC, se utilizó el método por asignación de polos, los cuales fueron obtenidos por el algoritmo PSO.

Tabla 5: Valores de las ganancias de cada submodelo.

Ganancias	Valores
K_1	-0.0103, -0.0015
K_2	-0.0103, -0.0017
K_3	-0.0103, -0.0015
K_4	-0.0104, -0.0018

La estabilidad del sistema difuso global en lazo cerrado con el controlador PDC difuso se comprueba mediante el **Teorema 1**, como se muestra en (Lilly (2010)). Para tal efecto, se sustituye (19) en (10) con la forma de doble sumatoria. El modelo difuso esta compuesto por cuatro reglas, así como cuatro reglas para el controlador PDC, lo que hace un total de 16 combinaciones de los modelos y sus controladores difusos.

Teorema 1. Tanaka and Sugeno (1992); Tanaka and Sano (1994); Wang et al. (1996)) *El equilibrio del sistema discreto difuso (10), es globalmente asintóticamente estable, si existe una matriz P definida positiva, tal que cumpla la desigualdad cuadrática de Lyapunov:*

$$(A_i - B_i K_j)^T P (A_i - B_i K_j) - P < 0, \quad i, j = 1, 2, \dots, c \quad (20)$$

es decir, tiene que existir una matriz P común definida positiva para todos los subsistemas.

La condición de estabilidad del Teorema 1 es expresada en LMI's. Usando el Toolbox de Matlab LMI Control, se obtuvo a la matriz P dada por:

$$P = \begin{bmatrix} 0.5257 & -0.0015 \\ -0.0015 & 0.0033 \end{bmatrix} \quad (21)$$

la cual es simétrica y definida positiva, con lo que se cumple con las desigualdades (20), y se concluye que el sistema es globalmente asintóticamente estable.

Para probar la ley de control PDC difusa, se perturbó el sistema físico con una carga inductiva (motor brushless). A esta carga eléctrica se le aplicaron diferentes valores de referencia, a través de la señal PWM2 mediante un controlador electrónico de velocidad como se muestra en la Figura 2, con la intención de someter al controlador difuso a la variación de diferentes potencias de consumo por una carga dinámica no lineal.

La Figura 4 muestra resultados experimentales con la planta física del SGE. Se presenta el voltaje obtenido mediante la prueba física y el resultante del modelo identificado usando una serie de escalones de voltajes de referencia de 42, 58.5 y 65 volts, ante diferentes valores de la carga.

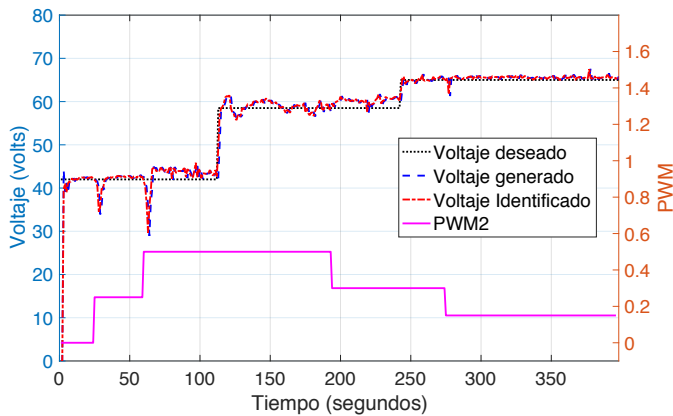


Figura 4: Prueba experimental de regulación a diferentes voltaje del SGE, ante distintos valores aplicados a la carga en la planta física.

Mientras que la Figura 5 muestra resultados experimentales del voltaje obtenido mediante la prueba física y el obtenido del modelo identificado usando un voltaje de referencia fijo de 39 volts, ante variaciones en la carga. Esto debido a que se desea analizar el desempeño del SGE en las condiciones en las que éste sera utilizado, remplazando baterías de Litio-polímero, las cuales deben de mantener su voltaje dentro de un rango de operación con una variación no mayor a 0.8 volts por celda.

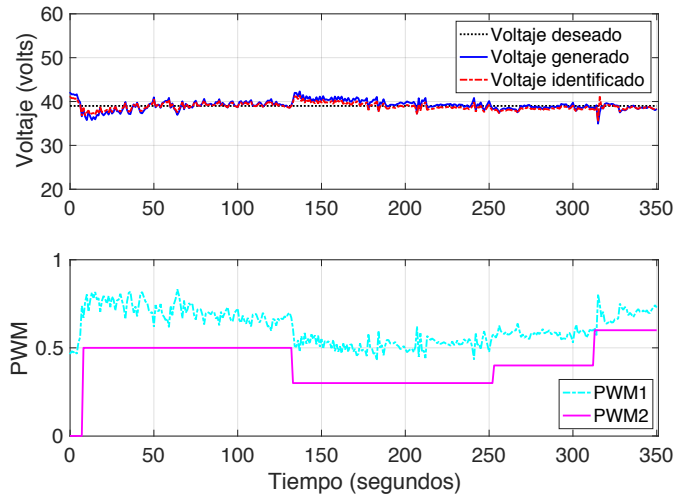


Figura 5: Prueba experimental de regulación de voltaje constante del SGE, ante distintos valores aplicados a la carga en la planta física.

En la Figura 4 y en la Figura 5 se aprecia que el controlador difuso PDC, regula el voltaje en la prueba física al valor del voltaje de referencia. El seguimiento del modelo difuso del sistema de generación de energía en lazo cerrado en tiempo real logra índices de error aceptable, aún cuando el SGE está sometido a ruido en el voltaje generado, zonas muertas naturales del actuador de control en el cuerpo de aceleración (servomotor del carburador) y perturbaciones eléctricas no lineales con variación dinámica (carga).

La Tabla 6 presentan los índices de desempeño ISE (Integral del error al cuadrado), IAE (Integral del valor absoluto del error) e ITAE (Integral del valor absoluto del error multiplicado por el tiempo). Se muestran los índices del error entre la referencia y el voltaje generado (VG), así como de la referencia y el voltaje identificado (VI). A partir del análisis de los índices de error obtenidos es posible determinar que, tanto el voltaje identificado mantiene un índice de error similar al del voltaje generado, lo cual garantiza la efectividad del proceso de identificación.

Tabla 6: Índices de error del voltaje generado y del voltaje identificado. Donde $N = 350$ es el número total de muestras, $T_s = 1$ segundo es el tiempo de muestreo y $e(k)$ es el error de seguimiento de la salida del sistema.

	ISE	IAE	ITAE
	$\sum_{k=0}^N e^2(k) T_s$	$\sum_{k=0}^N e(k) T_s$	$\sum_{k=0}^N k e(k) T_s$
VG	477.32	305.36	4.2304e+04
VI	264.45	239.03	3.8147e+04

5. Conclusiones

La metodología aquí descrita basada en el uso del algoritmo de c-means, el controlador PDC y el algoritmo metaheurístico de optimización PSO demostraron ser capaces de modelar, identificar y controlar en tiempo real un sistema complejo, lo cual se validó mediante pruebas experimentales sobre un generador de energía basado en un motor de combustión interna y un motor sin escobillas aplicado como generador eléctrico.

Utilizando datos experimentales entrada-salida de la planta, la estrategia de optimización basada en el algoritmo PSO, permitió determinar el parámetro difuso m óptimo del algoritmo c-means, así como la selección óptima de los polos del sistema de control en lazo cerrado para los consecuentes de cada regla difusa.

La identificación de un modelo difuso, para el sistema de generación de energía a partir de datos de entrada y de salida, evita la necesidad de derivar e identificar un modelo matemático por técnicas convencionales, lo cual representa un gran reto debido a la complejidad del sistema completo, el cual está compuesto por un motor de combustión interna, un generador eléctrico acoplado mecánicamente y una carga eléctrica con un regulador electrónico de velocidad, con presencia de zonas muertas, ruido en la generación del voltaje y no linealidades en la carga eléctrica.

Agradecimientos

Este trabajo fue financiado por el Consejo Nacional de Humanidades, Ciencias y Tecnologías, México, a través del Proyecto: LaNaVEx.

Referencias

- Aliramezani, M., Koch, C. R., Shahbakhti, M., 2022. Modeling, diagnostics, optimization, and control of internal combustion engines via modern machine learning techniques: A review and future directions. *Progress in Energy and Combustion Science* 88, 100967.
DOI: 10.1016/j.pecs.2021.100967
- Babuška, R., 1998. *Fuzzy modeling for control*. Springer Dordrecht.
DOI: 10.1007/978-94-011-4868-9
- Benevieri, A., Carbone, L., Cosso, S., Kumar, K., Marchesoni, M., Passalacqua, M., Vaccaro, L., 2021. Series architecture on hybrid electric vehicles: A review. *Energies* 14 (22), 7672.
DOI: 10.3390/en14227672
- Bezdek, J. C., 1993. A physical interpretation of fuzzy isodata. In: *Readings in Fuzzy Sets for Intelligent Systems*. Elsevier, pp. 615–616.
DOI: 10.1016/B978-1-4832-1450-4.50065-1
- Bezdek, J. C., 2013. *Pattern recognition with fuzzy objective function algorithms*. Springer Science & Business Media.
- Bhatt, A. N., Shrivastava, N., 2022. Application of artificial neural network for internal combustion engines: A state of the art review. *Archives of Computational Methods in Engineering* 29 (2), 897–919.
DOI: 10.1007/s11831-021-09596-5
- Boggero, L., Corpino, S., De Martin, A., Evangelista, G., Fioriti, M., Sorli, M., 2019. A virtual test bench of a parallel hybrid propulsion system for uavs. *Aerospace* 6 (7), 77.
DOI: 10.3390/aerospace6070077
- Chen, C.-T., 2012. *Linear Systems Theory and Design*. Oxford University Press.
- Clerc, M., Kennedy, J., 2002. The particle swarm-explosion, stability, and convergence in a multidimensional complex space. *IEEE transactions on Evolutionary Computation* 6 (1), 58–73.
DOI: 10.1109/4235.985692
- Eberhart, R., Kennedy, J., 1995. A new optimizer using particle swarm theory. In: *MHS'95. Proceedings of the sixth international symposium on micro machine and human science*. IEEE, pp. 39–43.
DOI: 10.1109/MHS.1995.494215
- Gao, J., Chang, T.-C., Yao, R., 2021. An adaptive intelligent system to minimize energy use for a parallel hybrid electric vehicle. *Microsystem Technologies* 27, 1483–1496.
- Lieh, J., Spahr, E., Behbahani, A., Hoying, J., 2011. Design of hybrid propulsion systems for unmanned aerial vehicles. In: *47th AIAA/ASME/SAE/ASEE Joint Propulsion Conference & Exhibit*. p. 6146.
DOI: 10.2514/6.2011-6146
- Lilly, J. H., 2010. *Fuzzy control and identification*. John Wiley & Sons.
DOI: 10.1002/9780470874240
- Manjarrez, L. H., Ramos-Fernández, J. C., Espinoza, E. S., Lozano, R., 2023. Estimation of energy consumption and flight time margin for a uav mission based on fuzzy systems. *Technologies* 11 (1), 12.
DOI: 10.3390/technologies11010012
- Rubio, I., Guijarro, G., García, L., Hespanha, J., Xie, J., 2019. Translational model identification and robust control for the parrot mambo uas. In: *Proceedings of the IEEE GLOBECOM 2019 Workshop on Computing-Centric Drone Networks*. IEEE, pp. 1–6.
DOI: 10.1109/GCWkshps45667.2019.9024528
- Shen, Y., Cui, P., Wang, X., Han, X., Wang, Y.-X., 2020. Variable structure battery-based fuel cell hybrid power system and its incremental fuzzy logic energy management strategy. *International Journal of Hydrogen Energy* 45 (21), 12130–12142.
DOI: 10.1016/j.ijhydene.2020.02.083
- Shouran, M., Alsseid, A., 2022. Particle swarm optimization algorithm-tuned fuzzy cascade fractional order pi-fractional order pd for frequency regulation of dual-area power system. *Processes* 10 (3), 477.
DOI: 10.3390/pr10030477
- Shrivastava, N., Khan, Z. M., 2018. Application of soft computing in the field of internal combustion engines: a review. *Archives of Computational Methods in Engineering* 25 (3), 707–726.
DOI: 10.1007/s11831-017-9212-9
- Takagi, T., Sugeno, M., 1985. Fuzzy identification of systems and its applications to modeling and control. *IEEE transactions on systems, man, and cybernetics* (1), 116–132.
DOI: 10.1109/TSMC.1985.6313399
- Tanaka, K., Sano, M., 1994. A robust stabilization problem of fuzzy control systems and its application to backing up control of a truck-trailer. *IEEE Transactions on Fuzzy systems* 2 (2), 119–134.
DOI: 10.1109/91.277961
- Tanaka, K., Sugeno, M., 1992. Stability analysis and design of fuzzy control systems. *Fuzzy sets and systems* 45 (2), 135–156.
DOI: 10.1016/0165-0114(92)90113-I
- Wang, D., Tan, D., Liu, L., 2018. Particle swarm optimization algorithm: an overview. *Soft computing* 22 (2), 387–408.
DOI: 10.1007/s00500-016-2474-6
- Wang, H. O., Tanaka, K., 2004. *Fuzzy control systems design and analysis: A linear matrix inequality approach*. John Wiley & Sons.
DOI: 10.1002/0471224596
- Wang, H. O., Tanaka, K., Griffin, M. F., 1996. An approach to fuzzy control of nonlinear systems: Stability and design issues. *IEEE transactions on fuzzy systems* 4 (1), 14–23.
DOI: 10.1109/91.481841
- Wang, L.-X., 1999. *A course in fuzzy systems*. Prentice-Hall press, USA.
- Wu, K.-L., 2012. Analysis of parameter selections for fuzzy c-means. *Pattern Recognition* 45 (1), 407–415.
DOI: 10.1016/j.patcog.2011.07.012
- Xie, Y., Savvaris, A., Tsourdos, A., 2019. Fuzzy logic based equivalent consumption optimization of a hybrid electric propulsion system for unmanned aerial vehicles. *Aerospace Science and Technology* 85, 13–23.
DOI: 10.3923/ijbc.2010.190.202
- Yang, Z., Konovalov, D., Radchenko, M., Radchenko, R., Kobalava, H., Radchenko, A., Kornienko, V., 2022. Analysis of efficiency of thermopressor application for internal combustion engine. *Energies* 15 (6), 2250.
DOI: 10.3390/en15062250
- You, D., Lei, Y., Liu, S., Zhang, Y., Zhang, M., 2022. Networked control system based on pso-rbf neural network time-delay prediction model. *Applied Sciences* 13 (1), 536.
DOI: 10.3390/app13010536
- Zaccone, R., Campora, U., Martelli, M., 2021. Optimisation of a diesel-electric ship propulsion and power generation system using a genetic algorithm. *Journal of Marine Science and Engineering* 9 (6), 587.
- Zafar, Z. U. A., Ali, N., Tunç, C., 2021. Mathematical modeling and analysis of fractional-order brushless dc motor. *Advances in Difference Equations* 2021, 1–25.
DOI: 10.1186/s13662-021-03587-3
- Zhang, X., Liu, L., Dai, Y., 2018. Fuzzy state machine energy management strategy for hybrid electric uavs with pv/fuel cell/battery power system. *International Journal of Aerospace Engineering* 2018.
DOI: 10.1155/2018/2852941
- Zhou, K., Fu, C., Yang, S., 2014. Fuzziness parameter selection in fuzzy c-means: The perspective of cluster validation. *Science China Information Sciences* 57, 1–8.
DOI: 10.1007/s11432-014-5146-0