



**CENTRO DE INVESTIGACIÓN Y DE ESTUDIOS  
AVANZADOS DEL INSTITUTO POLITÉCNICO NACIONAL**

**UNIDAD ZACATENCO**

**PROGRAMA DE SISTEMAS AUTÓNOMOS DE NAVEGACIÓN AÉREA Y SUBMARINA**

**“Desarrollo de un Modelo Difuso y Regulación de Voltaje de un Sistema de Generación  
de Energía Eléctrica”**

**TESIS**

que presenta:

**M. en M. Christian Gerardo Reyes Montiel**

para obtener el grado de:

**DOCTOR EN CIENCIAS**

**EN SISTEMAS AUTÓNOMOS DE NAVEGACIÓN AÉREA Y SUBMARINA**

Directores de la Tesis:

**Dr. Eduardo Steed Espinoza Quesada**

**Dr. Rogelio Lozano Leal**

Ciudad de México

Julio, 2024



# Dedicatoria

---

Dedico ésta tesis a mis padres por apoyarme en mi educación y crecimiento profesional, los cuales me han ayudado a seguir adelante durante los momentos difíciles. Al igual a mis hermanos y amistades por el alejamiento durante esta etapa.

## **IN MEMORIAM**

En honor a mi papá, aunque no este físicamente, sigue guiándome a sacar adelante todos obstáculos que se presenten.



# Agradecimientos

---

A mis padres y hermanos por apoyarme, por darme fuerzas y por ser una presencia en mi vida personal y profesional. Les agradezco su apoyo incondicional a lo largo de mis estudios de posgrado.

A mi director de tesis el Dr. Eduardo Steed Espinoza Quesada por sus consejos, brindarme sus conocimientos, ser un mentor en este trabajo de tesis y apoyarme ante todo en mi formación doctoral.

A mi codirector de tesis el Dr. Rogelio Lozano Leal por proporcionarme sus conocimientos para la realización de este proyecto, darme consejos ante toda dificultad que se presentaba y apoyarme durante este trabajo.

A mis profesores Dr. Filiberto Muñoz Palacios, Dr. Ivan Gonzalez Hernández, Dr. Sergio Salazar Cruz y demás profesores que me impartieron clases en esta institución, gracias por sus enseñanzas, experiencia y consejos. Al Dr. Julio Cesar Ramos Fernández, el cual forma parte de la Universidad Politécnica de Pachuca, por sus conocimientos para la elaboración del proyecto.

A mis amigos y compañeros de laboratorio de UMI-LAFMIA Armando, Juan, David, Alexis, Carlos, Néstor, Jesús, Sergio, Ruben, Alex, Oscar, Leonel y todos los demás que me acompañaron en esta etapa de mi vida, les agradezco su apoyo y conocimientos. Al igual les agradezco a Fernando e Iliana que estaban haciendo servicio social con otros compañeros de laboratorio, que después se integraron dentro del laboratorio, pudieron ayudarme en ratos en el proyecto. También a Naim, quien fue alumno de servicio social que me fue asignado,

aunque por un breve periodo de tiempo, por su colaboración dada. Al igual que Giovanni, otro alumno de servicio social, por su asistencia en el proyecto. A mi amigo Saúl que estando en el laboratorio como técnico, igual por un periodo corto de tiempo, me ayudaba en el trabajo.

De igual manera agradezco al Consejo Nacional de Humanidades, Ciencias y Tecnologías (CONAHCYT) por el apoyo económico otorgado a través de la beca de posgrado durante el doctorado.

---

# Índice general

---

<b>Dedicatoria</b>	<b>I</b>
<b>Agradecimientos</b>	<b>III</b>
<b>Índice de figuras</b>	<b>IX</b>
<b>Índice de tablas</b>	<b>XIII</b>
<b>Resumen</b>	<b>XV</b>
<b>Abstract</b>	<b>XVII</b>
<b>Nomenclatura</b>	<b>XVIII</b>
<b>Nomenclatura</b>	<b>XIX</b>
<b>1. Introducción</b>	<b>1</b>
1.1. Antecedentes históricos . . . . .	2
1.2. Partes de un sistema de generación de energía . . . . .	3
1.2.1. Motores de Combustión Interna . . . . .	4
1.2.2. Sistema Eléctrico . . . . .	6
1.3. Motivación . . . . .	10
1.4. Planteamiento del problema . . . . .	10
1.5. Hipótesis . . . . .	11
1.6. Objetivos . . . . .	11
1.6.1. Objetivo general . . . . .	11
1.6.2. Objetivos específicos . . . . .	11

1.7. Justificación . . . . .	12
1.8. Contribuciones . . . . .	12
1.9. Artículos . . . . .	13
1.10. Contenido de la tesis . . . . .	14
<b>2. Estado del Arte</b>	<b>15</b>
2.1. Productos comerciales con SGE . . . . .	15
2.2. Algoritmo de enjambre de partículas . . . . .	20
2.2.1. Parámetro Difuso . . . . .	23
2.3. Sistemas de generación de energía . . . . .	24
2.3.1. Estrategias de control aplicadas . . . . .	31
<b>3. Metodología e Instrumentación</b>	<b>43</b>
3.1. Metodología para la selección de componentes . . . . .	43
3.1.1. Árbol de ideas . . . . .	43
3.1.2. Establecimiento de funciones . . . . .	44
3.1.3. Requerimientos . . . . .	45
3.1.4. Determinando características . . . . .	46
3.1.5. Generando alternativas . . . . .	53
3.1.6. Evaluando alternativas . . . . .	55
3.2. Instrumentación del SGE . . . . .	56
3.2.1. Diseño del SGE . . . . .	56
3.2.2. Conexión de los Componentes . . . . .	56
<b>4. Modelado Difuso Takagi-Sugeno (T-S)</b>	<b>65</b>
4.1. Introducción . . . . .	65
4.2. Modelado . . . . .	66
4.2.1. Modelo Lingüístico Difuso . . . . .	69
4.2.2. Defuzificación . . . . .	69
<b>5. PSO y Estrategia de Control</b>	<b>71</b>
5.1. PSO . . . . .	71
5.1.1. Antecedentes . . . . .	71
5.2. Diseño del Controlador Difuso . . . . .	74

---

---

5.2.1. Ganancia de precompensación . . . . .	76
<b>6. Resultados en Simulación y Experimentales</b>	<b>77</b>
6.1. Adquisición de Datos . . . . .	77
6.2. Identificación, Simulaciones y Control . . . . .	80
6.2.1. Selección de polos . . . . .	81
6.2.2. Parámetro difuso . . . . .	82
6.2.3. Polos del sistema . . . . .	85
6.2.4. Construcción del Sistema T-S . . . . .	87
6.2.5. Control PDC . . . . .	92
6.2.6. Análisis de Estabilidad . . . . .	93
6.3. Pruebas experimentales . . . . .	95
<b>7. Conclusiones</b>	<b>99</b>
7.1. Trabajo Futuro . . . . .	99
<b>Glosario</b>	<b>101</b>
<b>Bibliografía</b>	<b>103</b>
<b>Algoritmos del Sistema de Lazo Abierto y Cerrado en Matlab</b>	<b>117</b>
<b>Algoritmos PSO para la obtención del parámetro óptimo difuso y los polos óptimos del sistema en Matlab</b>	<b>131</b>

---



# Índice de figuras

---

1.1. Diagrama de flujo del diseño de HEV. . . . .	2
1.2. Funcionamiento del motor encendido por chispa de 4T. . . . .	5
1.3. Funcionamiento del motor encendido por chispa de 2T. . . . .	5
1.4. Configuración en serie. . . . .	8
1.5. Configuración en paralelo. . . . .	9
1.6. Configuración en serie-paralelo. . . . .	10
2.1. UGV de Whitebox Robotics Co., Ltd. . . . .	16
2.2. Vehículo eléctrico de despegue y aterrizaje vertical (eVTOL) de Boeing. . .	17
2.3. Generador Foxtech NOVA-2000 con tren de aterrizaje. . . . .	17
2.4. Airborg H8 10K con sistema de energía híbrido en serie. . . . .	18
2.5. Algunos productos de Sullivan. . . . .	19
2.6. Banco de pruebas de un motor de combustión interna. . . . .	26
2.7. Banco de pruebas del motor eléctrico. . . . .	26
2.8. Esquema del sistema híbrido-eléctrico. . . . .	28
2.9. Diagrama del sistema de multirotor. . . . .	29
2.10. Integración de la estructura de IA en UGVs. . . . .	35
2.11. Aerosonde UAV. . . . .	36
3.1. Árbol de ideas. . . . .	44
3.2. Caja negra del sistema. . . . .	45
3.3. Diagrama QFD. . . . .	47
3.4. Casa de la calidad QFD. . . . .	49
3.5. Modulo de Young vs densidad de diferentes materiales. . . . .	50

3.6. Gráfica Esquemática $E$ contra $\rho$ . . . . .	52
3.7. Región de búsqueda. . . . .	53
3.8. Vista isométrica del diseño en CAD del sistema físico. . . . .	56
3.9. Vista lateral del diseño del sistema de generación. . . . .	57
3.10. Vista superior del diseño del sistema de generación. . . . .	57
3.11. Plataforma experimental. . . . .	58
3.12. Diagrama de bloques del SGE. . . . .	58
3.13. Diagrama de conexiones del sistema de generación de energía. . . . .	59
3.14. Motor de combustión interna utilizado. . . . .	60
3.15. Motor U12KV120. . . . .	61
3.16. Dispositivo Embebido NI myRio. . . . .	62
3.17. Puente de diodos trifásico. . . . .	63
3.18. Ejemplo de divisor de voltaje. . . . .	63
5.1. Diagrama de flujo del algoritmo de optimización de enjambre de partículas. . . . .	72
5.2. Diagrama de lazo cerrado del sistema. . . . .	76
6.1. Diagrama de bloques de adquisición de datos en LabView. . . . .	78
6.2. Trenes de pulso del Duty Cycle. . . . .	79
6.3. Diagrama de bloques en lazo abierto del SGE. . . . .	80
6.4. Diagrama de flujo de la identificación del sistema para la obtención del modelo difuso en Matlab. . . . .	80
6.5. Diagrama de flujo del controlador difuso en Matlab. . . . .	81
6.6. Diagramas que muestran la correspondencia entre la franja primaria $s$ y el círculo unitario en el plano $z$ : a)trayectoria en el plano $s$ , b)trayectoria correspondiente en el plano $z$ . . . . .	83
6.7. Diagrama de flujo para la obtención del parámetro difuso. . . . .	84
6.8. Valor de la función de costo utilizada en la optimización del parámetro $m$ . . . . .	85
6.9. Diagrama de flujo para la obtención de las ganancias de cada subsistema. . . . .	86
6.10. Valor de la función de costo utilizada en la optimización de los polos de cada subsistema. . . . .	87
6.11. Ubicación de los clusters y centroides del sistema. . . . .	89

---

6.12. Salida aproximada del modelo difuso y voltaje del generador eléctrico en lazo abierto. . . . .	92
6.13. Regulación del voltaje del SGE. . . . .	93
6.14. Señal de control del sistema en lazo cerrado. . . . .	94
6.15. Motor U12 utilizado en las pruebas experimentales del SGE. . . . .	96
6.16. Prueba física de regulación del voltaje del SGE y valores de la carga en la prueba física. . . . .	97
6.17. Programa de Labview de la prueba física del SGE en lazo cerrado. . . . .	98

---



# Índice de tablas

---

2.1. Características del UGV de White Robotics. . . . .	16
2.2. Especificaciones del Foxtech NOVA-2000. . . . .	18
2.3. Datos del Airborg H8 10K. . . . .	18
3.1. Especificación del sistema de generación de energía. . . . .	45
3.2. Carta morfológica . . . . .	54
3.3. Total de combinaciones posibles de los componentes del sistema de generación	54
3.4. Evaluación de alternativas del sistema de generación de energía . . . . .	55
3.5. Detalles Técnicos del MCI. . . . .	60
3.6. Especificaciones del U12KV120 . . . . .	61
3.7. Especificaciones del puente de diodos usado. . . . .	62
6.1. Parámetros utilizados en el algoritmo PSO y valor obtenido del parámetro $m$ .	83
6.2. Parámetros utilizados en el algoritmo PSO y valores obtenidos para cada subsistema. . . . .	85
6.3. Valores de las coordenadas para cada centroide. . . . .	88
6.4. Parámetros obtenidos por mínimos cuadrados por consecuentes. . . . .	90
6.5. Valores de las ganancias de cada submodelo. . . . .	93



# Resumen

---

La lógica difusa de Takagi-Sugeno se ha aplicado para modelar y controlar sistemas generadores de energía incluso en presencia de perturbaciones externas y cargas variables. Para evitar la derivación de un modelo matemático mediante técnicas clásicas, se propone una técnica difusa para modelar y controlar el sistema generador de energía. En primer lugar, se deriva un modelo matemático no lineal para el sistema de energía eléctrica utilizando el algoritmo difuso c-means en las premisas y el consecuente en el espacio de estado, con datos experimentales de entrada-salida en lazo abierto. Luego, utilizando la estrategia de compensación distribuida en paralelo (por sus siglas en inglés PDC), para cada consecuente del modelo difuso Takagi-Sugeno, se sintoniza un controlador de retroalimentación de estado utilizando el algoritmo metaheurístico de optimización de enjambre de partículas para encontrar las ganancias óptimas del controlador. Utilizando desigualdades matriciales lineales para demostrar la estabilidad del sistema. Por último, para validar la eficacia de la estrategia propuesta, este enfoque se aplica a un sistema generador de energía compuesto por un motor de combustión interna acoplado a un generador eléctrico. Se realizó tanto simulaciones numéricas como pruebas experimentales considerando un motor sin escobillas como carga del sistema.



# Abstract

---

Takagi-Sugeno fuzzy logic has been applied to model and control power generating systems even in the presence of external disturbances and variable loads. To avoid the derivation of a mathematical model by classical techniques, a fuzzy technique is proposed to model and control the power generating system. First, a nonlinear mathematical model for the electric power system is derived using the fuzzy c-means algorithm in the premises and the consequent in the state space, with open-loop input-output experimental data. Then, using the parallel distributed compensation (PDC) strategy, for each consequent of the Takagi-Sugeno fuzzy model, a state feedback controller is tuned using the particle swarm optimization metaheuristic algorithm to find the optimal controller gains. Using linear matrix inequalities to demonstrate the stability of the system. Finally, to validate the effectiveness of the proposed strategy, this approach is applied to a power generating system composed of an internal combustion engine coupled to an electric generator. Both numerical simulations and experimental tests were performed considering a brushless motor as the system load.



# Nomenclatura

---

2T	Dos Tiempos
4T	Cuatro Tiempos
A	Área de la Sección Transversal
$A_i$	Matriz de ganancias del sistema
ANFIS	Adaptive Network based Fuzzy Inference System
$B_i$	Vector de ganancias de los actuadores
BRD	Bridge Rectifier Diodes
$C_i$	Excitación del sistema
CDG	Centro de Gravedad
$C_o$	Corriente
CP	Centro Promedio
$c$	Clusters
$c_i$	Centros de Cluster
$c_1$	Coefficiente de aceleración que regula el tamaño de paso en la dirección de la mejor posición personal de la partícula
$c_2$	Coefficiente de aceleración que regula el tamaño de paso en la dirección de la mejor partícula global
$D$	Distancias Euclidianas
d	diámetro
E	Modulo de Young o de Elasticidad
$E_V$	Elevación de Voltaje
ECMS	Estrategia de Minimización de Consumo Equivalente
ESC	Electronic Speed Controller
F	Carga
F-ECMS	Difuso basado en ECMS
FCM	Fuzzy c-means
FL	Lógica Difusa
FLC	Controlador de Lógica Difusa
$\Gamma$	Matriz que contiene en su diagonal principal los valores de disparo normalizados
GA	Algoritmo Genético
HEPS	Hybrid Electric Power Systems
HESS	Sistema Híbrido de Almacenamiento de Energía
HEV	Hybrid Electric Vehicle
$h_i$	Valores Normalizados por la T Norma
$I$	Matriz Identidad

---

---

J	Función Objetivo que describe los centros de cluster
$K_i$	Ganancias
$k_r$	Ganancia de precompensación
Le	Lectura del sensor
LQR	Controlador Regulador Lineal Cuadrático
l	Longitud de la viga
M	Índice del Material
MCI	Motor de combustión interna
m	Parámetro de diseño difuso
mv	Masa de la Viga
$\mu_{ik}$	Valor de Pertenencia de la i-ésima cluster en la k-muestra
N	Número de Muestras
n	Número de vectores o estados
$\omega_i$	Pesos
$\prod$	Producto
PDC	Parrallel Distributed Compensation
PID	Controlador Proporcional Integral Derivativo
PPT	Técnica de Asignación de Polos
PSO	Particle Swarm Optimization
PWM	Modulación de ancho de pulso
$\mathbb{R}$	Números Reales
$\rho$	Densidad
R	Resistencia
$R_T$	Resistencia Total
$R_i$	Reglas difusas
$\sum$	Sumatoria
RMS	Root Mean Square Error
SGE	Sistema de Generación de Energía
SI	Spark Ignition
SOC	State of Charge
s	Tamaño del enjambre
UAV	Unmanned Aerial Vehicle
UGV	Unmanned Ground Vehicle
$u(k)$	Controlador
VI	Salida identificada del sistema
VLC	Voltaje Generado en Lazo Cerrado
$V_{acq}$	Voltaje de la salida del sistema
$V_i$	Velocidad Actual de la Partícula
T-S	Takagi-Sugeno
t	Tiempo
$\theta_i$	Parámetros Consecuentes
X	Entrada del sistema
$x(k)$	Vector de Estados en el instante (k)
$x(k + 1)$	Vector de Estados en el instante (k + 1)
$x_i$	Posición Actual de la Partícula
Y	Salida del Sistema
$y_i$	Mejor Posición de la Partícula
$\hat{y}$	Aproximación de Mínimos Cuadrados
Z	Matriz de Aprendizaje
z	Matriz de Datos

---

# Introducción

---

En los últimos años se han desarrollado diferentes tipos de sistemas de generación de energía eléctrica dada la necesidad de contar con mejores fuentes de energía en vehículos autónomos (como aplicaciones hacia la aeronáutica [1]), ya sea para alimentar sus motores y dispositivos electrónicos, cargar sus baterías, o más aún, para aumentar su tiempo de autonomía.

Como se indica en [2], un sistema de propulsión eléctrico con dos o más fuentes de energía tiene muchas ventajas sobre los trenes de potencia de los MCI convencionales. Las ventajas más reconocidas son su baja contaminación, bajo nivel de ruido y reducida liberación de calor. La aplicación de propulsión eléctrica híbrida para vehículos de carretera ha mejorado con éxito la eficiencia energética y ha reducido la contaminación. En el ámbito militar, los UAV híbridos eléctricos se pueden utilizar de forma eficaz porque poseen la capacidad para un tiempo de vuelo prolongado, una mejor eficiencia y una operación sigilosa.

En la Figura 1.1, describe un procedimiento de diseño a nivel de sistema para un sistema de energía para un vehículo eléctrico (por sus siglas en inglés HEV), [3]. El primer nivel es la selección de la arquitectura. Esta selección desempeña un papel fundamental en el diseño de una cadena cinemática eficiente. El segundo nivel determina los componentes de tecnología avanzada necesarios y su clasificación para integrarlos en la cadena cinemática. Este nivel incluye la elección del sistema de almacenamiento de energía (EMS), el motor eléctrico y los convertidores CC-CC/CC-CA. La tercera etapa es la selección del sistema de generación de energía. Se trata de un aspecto muy crucial, ya que es responsable de mantener el funcionamiento de cada componente, y del sistema global, en su región de mayor

eficiencia energética. Un EMS bien diseñado puede mejorar significativamente el ahorro de combustible de la cadena cinemática, manteniendo al mismo tiempo la salud de la batería y reduciendo las emisiones del tubo de escape. El EMS adoptado debe tener en cuenta los distintos objetivos y limitaciones para poder alcanzar las metas del diseño.

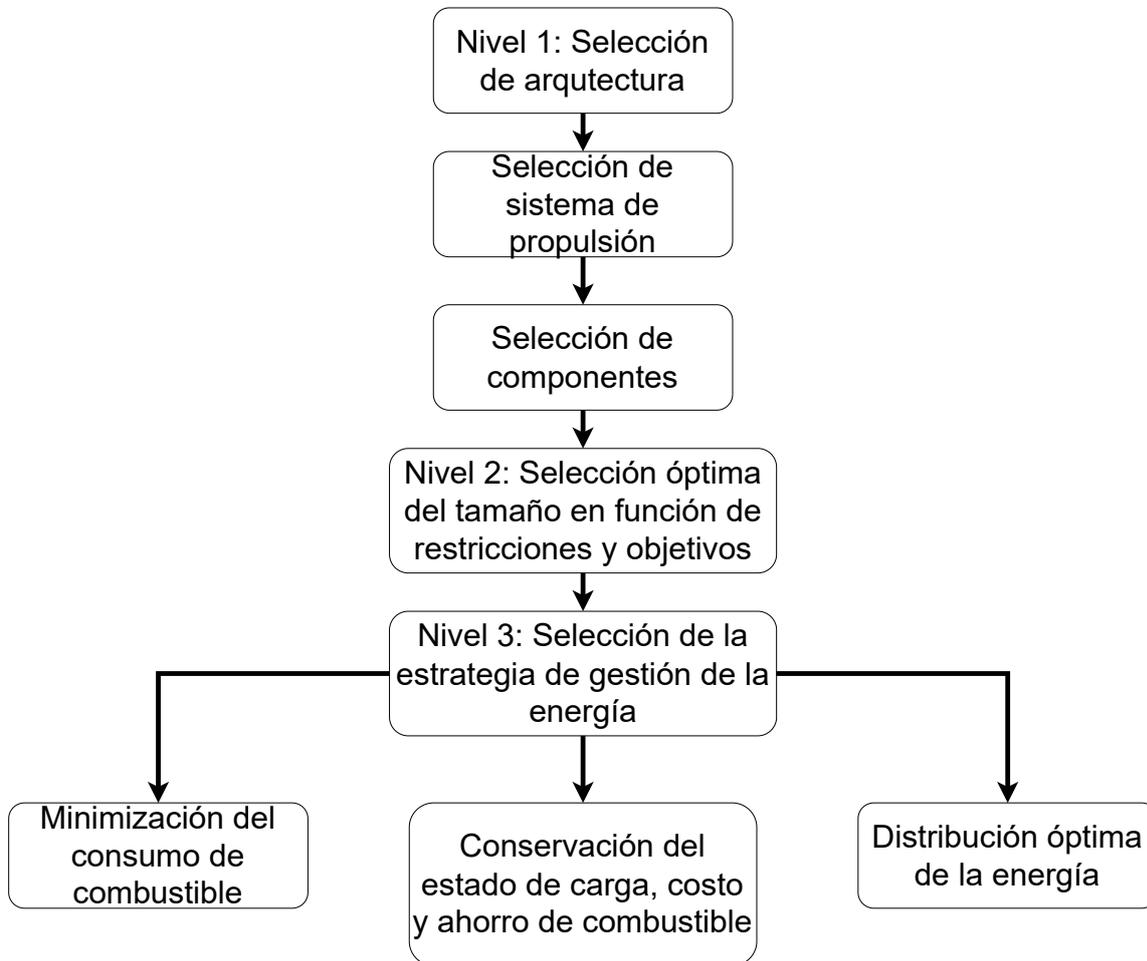


Figura 1.1: Diagrama de flujo del diseño de HEV.

## 1.1. Antecedentes históricos

En 1898, el alemán Dr. Ferdinand Porsche fabricó el primer HEV, llamado Lohner Electric Chaise. Porsche utilizó un motor de combustión interna (MCI) para accionar el generador que daba energía al motor eléctrico de tracción. Este HEV era capaz de moverse casi 40 millas sólo con la batería, [3].

La empresa Krieger fabricó en 1903 un HEV utilizando el motor de gasolina para cargar un paquete de baterías. Basado en las patentes de Pieper, se construyeron vehículos comer-

ciales de 1906 a 1912 por una empresa belga, [4]. En 1904, Henry Ford abordó los problemas relacionados con el ruido, las vibraciones y el mal olor, y fabricó vehículos híbridos baratos, ligeros e híbridos. La producción de de Henry Ford había cesado en 1920.

En 1905, H. Flute presentó una patente para un vehículo eléctrico de petróleo. Propuso utilizar un motor eléctrico para ayudar al MCI, con el que conseguía alcanzar 25 mi/h. Otros intentos en los años 70 para fabricar HEV de consumo. En 1997, Toyota desarrolló el primer HEV moderno, el Prius. Esto atrajo un nuevo interés por esta tecnología. El Honda Insight fue el siguiente HEV introducido en Estados Unidos. Desde entonces, casi todos los demás fabricantes de automóviles han introducido un HEV en su línea de productos, [5, 6].

## 1.2. Partes de un sistema de generación de energía

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 optimizar los resultados de este tipo de sistema de generación de energía. 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 [7] y sistemas de regulación de voltaje y potencia con algoritmos de control con técnicas híbridas de identificación y control automático, como el que se muestra en este trabajo de investigación.

Para optimizar este tipo de sistemas, se han abordado diferentes estrategias tales como el uso de innovadoras técnicas de control [8–10], el estudio del compartimiento de sistemas de generación de energía eléctrica con diferentes topologías de redes neuronales artificiales, para predecir y optimizar las complicadas características de varios tipos de motores con diferentes combustibles [11]. Así como la optimización de los sistemas de generación de energía eléctrica se analiza en [12, 13]. No obstante, la mayoría de las técnicas de control utilizadas para la regulación de voltaje, requieren de un modelo matemático del MCI acoplado mecáni-

---

camente al generador eléctrico, en consecuencia la interrelación de los modelos matemáticos, con sus implicaciones de la identificación de 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 [14, 15], lo que resulta en imprecisiones y por otra parte arquitecturas matemáticas de modelos con serias dificultades para aplicar técnicas del control automático. De igual forma, existen modelos matemáticos para describir las dinámicas de motores eléctricos [16, 17], los cuales consideran una serie de experimentos para obtener los parámetros de los modelos, que resultan costosos.

### 1.2.1. Motores de Combustión Interna

Los MCI son motores térmicos capaces de convertir una parte significativa de la energía térmica, liberada por la combustión del combustible en el interior de la máquina, en energía mecánica, [18]. Los MCI pueden clasificarse típicamente en función de los siguientes parámetros:

- Encendido del proceso de combustión del fluido de trabajo (Encendido por chispa <sup>1</sup>, Encendido por compresión <sup>2</sup>).
- Duración del ciclo de trabajo: De dos tiempos (2T), ver Figura 1.3, <sup>3</sup>, efectúan una carrera útil de trabajo en cada giro y de cuatro tiempos (4T), ver Figura 1.2, <sup>4</sup> efectúan una carrera útil de trabajo cada dos giros.

Se han utilizado configuraciones de tractor <sup>5</sup> y empujador <sup>6</sup>, y, en algunos casos, se han empleado diseños híbridos con motores.

---

<sup>1</sup>Donde una mezcla de aire y combustible vaporizado se comprime, como se ilustra en la Figura 1.2, y luego se enciende mediante una bujía, iniciando un proceso de combustión muy rápido, puesto que los reactivos ya están premezclados. También son llamados motores de ciclo Otto

<sup>2</sup>Donde el combustible se inyecta en una masa de aire, se comprime y se calienta a temperaturas y presiones superiores al punto de auto ignición del combustible. También llamados motores diésel

<sup>3</sup>Los motores de dos tiempos se caracterizan por realizar el ciclo termodinámico en tan solo dos vueltas del cigüeñal. Esto implica que el émbolo realiza solo dos carreras, por lo que solo se produce una subida y una bajada del pistón, [19]

<sup>4</sup>produce una explosión por cada dos vueltas de cigüeñal, haciendo su ciclo en cuatro recorridos del pistón y dos giros del cigüeñal; lo que asegura que una moto de 2T de la misma cilindrada va a tener mucha más velocidad, [20]

<sup>5</sup>Normal, también conocido como tractor ó estándar, la dirección de rotación se establece cuando una hélice gira en sentido antihorario, como lo ve un observador externo parado frente a la hélice y mirándola, como indica en [21].

<sup>6</sup>Reversa, también conocida como tipo P ó empujador, la dirección de rotación se establece cuando una

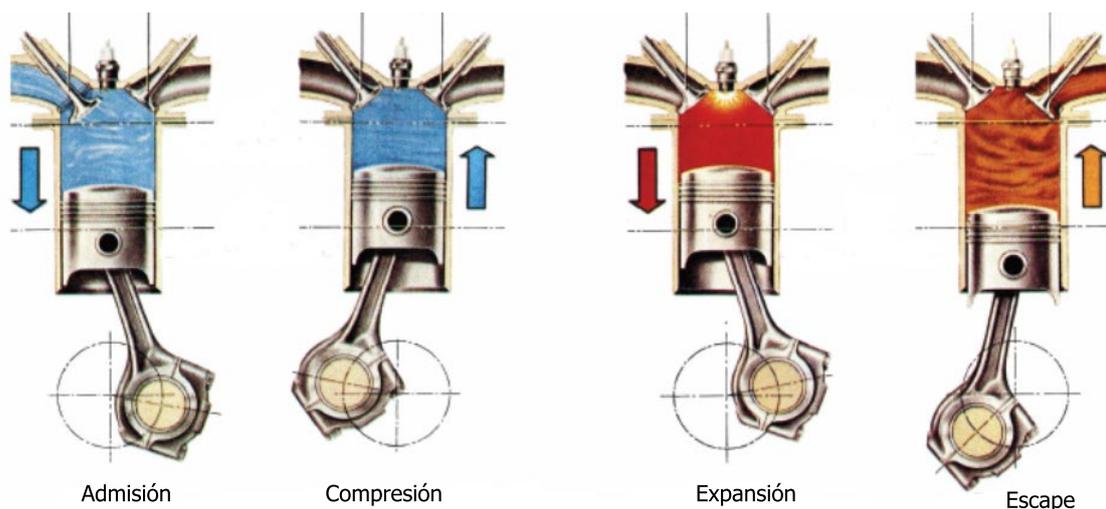


Figura 1.2: Funcionamiento del motor encendido por chispa de 4T.

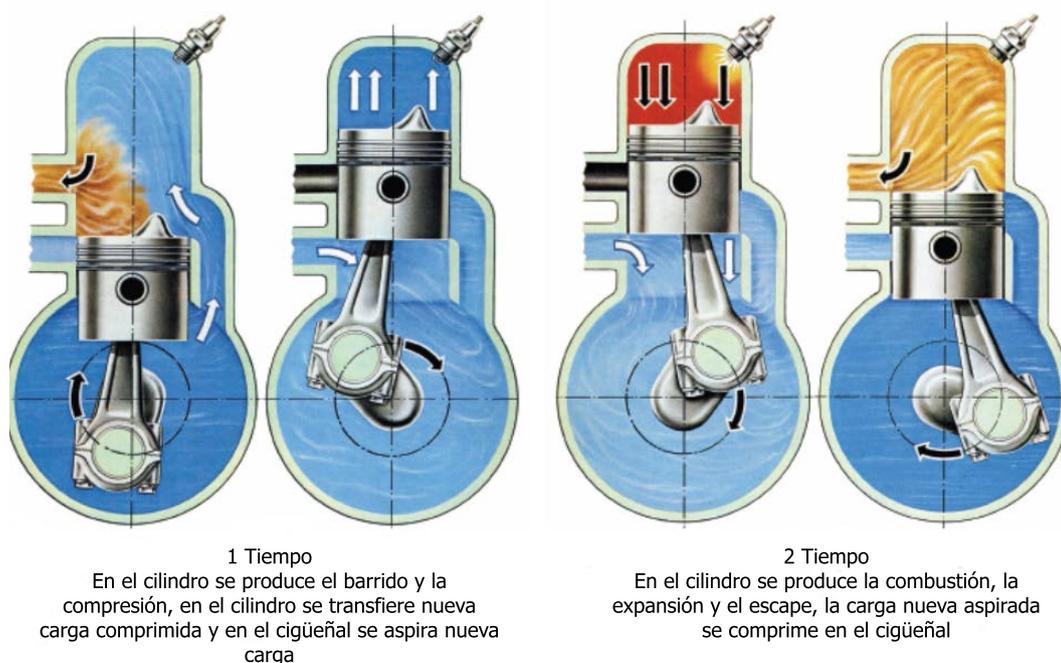


Figura 1.3: Funcionamiento del motor encendido por chispa de 2T.

Actualmente, los motores de gasolina de cuatro tiempos o de queroseno JP8 brindan el mejor alcance y resistencia a las aeronaves, pero deben tenerse en cuenta el suministro de combustible; también pueden causar problemas de vibración con los sensores a bordo, a menos que se preste especial atención a los soportes antivibratorios (tanto de motores como de sensores), como se indica en [22].

hélice gira en el sentido de las manecillas del reloj, como lo ve un observador externo que está frente a la hélice y la mira.

Otro componente dentro de la configuración híbrida es el generador, en la que se distinguen dos arquitecturas los que usan un generador independiente para cargar las baterías, ó los que aprovechan el motor eléctrico para funcionar también como generador, ver en [23]. Con generador independiente: su inconveniente es que tiene más componentes, el generador, el conversor de corriente alterna a corriente continua y la transmisión entre el motor térmico y el generador por lo que será más pesado y caro. Sin embargo, tiene la ventaja que el generador al estar diseñado para funcionar solamente como generador, será más eficiente que el motor funcionando como generador. Usando el motor eléctrico como generador se disminuye el número de componentes, pero puede disminuir el rendimiento. En [24], se explica las diferentes fuentes de energía para UAV. Como motores de dos tiempos, cuatro tiempos, motores rotatorios, motor Wankel, de seis tiempos, motores eléctricos, etc.

### 1.2.2. Sistema Eléctrico

Las baterías no tienen autonomía suficiente y los niveles de emisiones y la eficiencia dependen del tipo de fuente de energía. El motor eléctrico no emite contaminantes y tiene un funcionamiento silencioso. En el funcionamiento del generador, se cambia la energía cinética de frenado por la energía eléctrica, como indica [25]. El motor de combustión puede funcionar con alta eficiencia, pero sólo en una gama baja de rendimiento y velocidad. Mediante la combinación del motor de combustión y motor eléctrico con dispositivos de almacenamiento de energía adecuados producen una propulsión, que conecta beneficios de ambos. Los sistemas de propulsión eléctrica combinan las centrales eléctricas tradicionales con la propulsión eléctrica por batería, como indica [26]. Las motivaciones para la propulsión eléctrica híbrida son:

- Confiabilidad mejorada de un motor a través de una batería de respaldo.
- Mayor potencia eléctrica disponible para cargas útiles.
- Eficiencia de combustible mejorada.

Para configuraciones eléctricas híbridas que convierten toda la potencia de la central eléctrica en energía eléctrica a través de un generador, la combinación de batería/generador puede proporcionar de forma flexible potencia de vuelo y potencia de carga útil.

---

## Configuraciones

En el sistema de generación de energía, en donde dos o más fuentes de energía son combinados para incrementar la eficiencia del vehículo. La selección adecuada se centra generalmente en los aspectos ecológicos y económicos: reducción de emisiones, consumo de combustible y utilización de energías renovables. Actualmente, representa combinaciones de energía mecánica y eléctrica, [25]. La fuente de energía mecánica puede ser el motor de combustión. La energía eléctrica para la propulsión de los vehículos se produce mediante un generador eléctrico y se almacena en baterías.

Basándose en el conocimiento de la propulsión híbrida, su implementación al UGV puede producir las siguientes ventajas: reducción de su peso total, consumo de combustible y emisiones, uso óptimo del motor de combustión, funcionamiento silencioso a corto plazo, alta capacidad de aceleración, mayor fiabilidad de los componentes y acumulación de electricidad para aplicaciones internas y externas, [27]. Tradicionalmente, los HEVs se clasificaban en dos tipos básicos: en serie y en paralelo. Recientemente, con la introducción de algunos vehículos eléctricos híbridos que ofrecen las características de los híbridos en serie y en paralelo, la clasificación se ha ampliado a tres tipos: el híbrido con motor y batería y el híbrido con motor y batería. La clasificación se ha ampliado a tres tipos: en serie, en paralelo y en serie-paralelo, [28].

De acuerdo a lo ya aludido, un sistema de generación de energía utiliza un MCI y un motor/generador eléctrico para la generación de energía eléctrica. Los dos dispositivos de potencia, el MCI y el motor eléctrico, pueden conectarse en serie o en paralelo desde el punto de vista del flujo de potencia. Cuando el MCI y el motor están conectados en serie, es una configuración en serie, en el que sólo el motor eléctrico proporciona potencia mecánica a las ruedas. En un HEV o los vehículos eléctricos híbridos recargables (por sus siglas en inglés PHEV)<sup>7</sup>, tanto el MCI como el motor eléctrico están acoplados al eje de transmisión final a través de un mecanismo de acoplamiento mecánico, como embragues, engranajes, correas o poleas. Esta configuración en paralelo permite que tanto el motor de combustión interna como el eléctrico impulsen el vehículo, ya sea de forma combinada o por separado.

---

<sup>7</sup>Están equipados con una batería más grande y un motor de mayor tamaño que los HEV. Una vez agotada la energía de la batería, los PHEV funcionan de forma similar a los HEV normales, lo que se conoce como modo de carga sostenida o funcionamiento de autonomía extendida.

---

El motor eléctrico también se utiliza para el frenado regenerativo y para capturar el exceso de energía del motor de combustión interna durante la marcha por inercia. Los HEV y PHEV también pueden tener la configuración serie-paralelo o una configuración más compleja que normalmente contiene más de una máquina eléctrica. Por lo general, estas configuraciones pueden mejorar aún más el rendimiento y el ahorro de combustible del vehículo con un coste añadido de componentes, [29].

- Configuración en Serie:

La configuración en serie se basa en el principio de que las ruedas son impulsadas directamente por el motor eléctrico, véase Figura 1.4. De acuerdo con [30], la fuente propulsión primaria es el motor eléctrico. Normalmente, un motor de combustión interna acciona al generador, que a su vez proporciona energía al motor y un sistema de almacenamiento de energía. Como el motor de combustión no está vinculado mecánicamente al eje de transmisión, puede operar en su rango óptimo de torque y velocidad independientemente de la demanda de potencia.

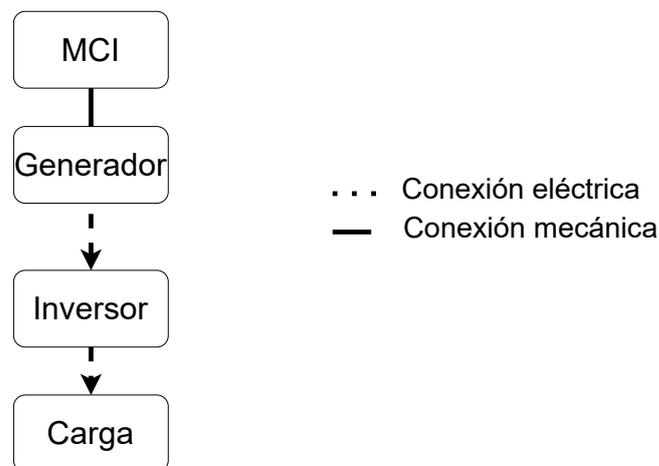


Figura 1.4: Configuración en serie.

- Configuración en Paralelo:

En esta configuración, el MCI y el motor eléctrico están acoplados a la transmisión final a través de un mecanismo como embragues, correas, poleas y engranajes. Tanto el MCI como el motor pueden suministrar potencia a la transmisión final, ya sea de forma combinada o cada uno por separado, como en la Figura 1.5. El motor eléctrico puede utilizarse como generador para recuperar la energía cinética durante el frenado o absorbiendo una parte de la potencia del MCI, [29]. Está configuración en paralelo

sólo necesita dos dispositivos, el MCI y el motor eléctrico, que pueden utilizarse en los siguientes modos:

- Modo motor solo: Cuando la batería tiene energía suficiente y la demanda de potencia del vehículo es baja, se utiliza el motor de combustión.
- Modo de potencia combinada: Cuando la demanda de potencia es alta, el motor se enciende y el motor también suministra potencia a las ruedas.
- Modo solo motor: Durante la circulación por autopista y en demandas de potencia moderadamente altas, el motor proporciona toda la potencia necesaria para impulsar el vehículo. El motor permanece al ralentí. Esto se debe principalmente al hecho de que el SOC (por sus siglas en inglés, estado de carga) de la batería ya está en un nivel alto, pero la demanda de potencia impide que el motor se apague, o puede que no sea eficiente apagar el motor.
- Modo de potencia dividida: Cuando el motor está encendido, pero la demanda de potencia es baja y el SOC de la batería también es bajo, entonces una parte de la potencia del motor es convertida en electricidad por el motor para cargar la batería.
- Modo de carga estacionaria: La batería se carga haciendo funcionar el motor como generador e impulsada por el motor.

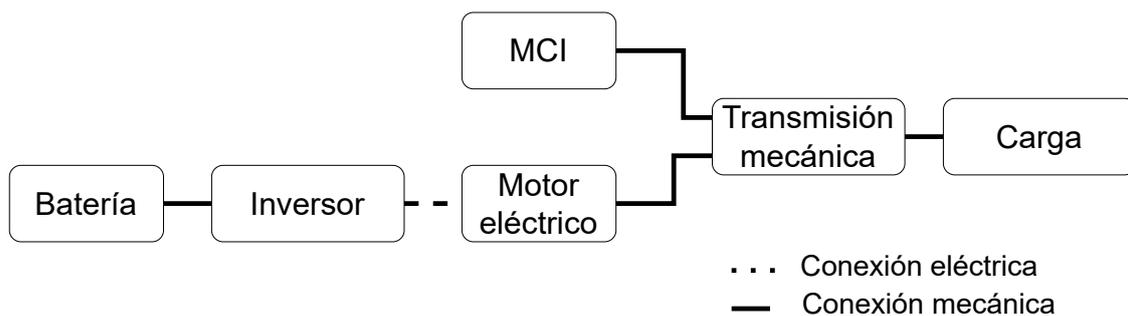


Figura 1.5: Configuración en paralelo.

■ Configuración Serie-Paralelo o Combinado:

Esta configuración incorpora las características tanto en serie como en paralelo, véase Figura 1.6. Por lo tanto, el sistema puede funcionar en serie o en paralelo, [25, 29]. En comparación con un paralelo, el serie-paralelo añade una segunda máquina eléctrica que sirve principalmente como generador. El mayor grado de libertad en el control

hace que el serie-paralelo sea una opción popular. Sin embargo, debido al aumento de los componentes y la complejidad, esta configuración suele ser más caro que un serie o paralelo.

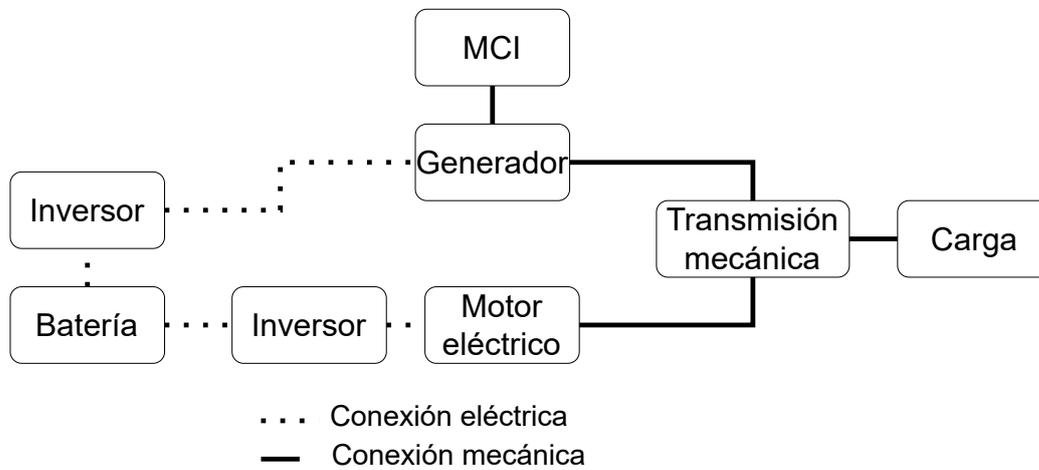


Figura 1.6: Configuración en serie-paralelo.

### 1.3. Motivación

Se han desarrollado enfoques basados en principios de equilibrio energético para modelar y controlar los sistemas de energía, más sin embargo, se trata de una tarea complicada debido a la complejidad y la naturaleza del motor de combustión interna. Por lo cual la necesidad de contar con sistemas energéticos que permitan regular el voltaje para diferentes tipos de carga para que tengan la capacidad de ser mas versátiles y contar con características que puedan mejorar su rendimiento para llevar a cabo sus tareas correspondientes, lo cual brinda la capacidad de ser utilizados en una gran variedad de aplicaciones.

### 1.4. Planteamiento del problema

Los sistemas de generación de energía eléctrica basados en el uso de motores de combustión interna 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 motores de combustión interna

reduce la eficiencia del sistema de generación de energía eléctrica, por lo que recientemente, se han desarrollado diferentes investigaciones que buscan optimizar los resultados de este tipo de sistema de generación de energía.

## 1.5. Hipótesis

- Utilizando datos de entrada-salida, que son la unidad de carburación con una señal de modulación por ancho de pulso (PWM, por su siglas en inglés) y el voltaje del generador eléctrico, respectivamente, es posible identificar un modelo difuso del tipo Takagi Sugeno (T-S), con los consecuentes de las reglas difusas en espacio de estado.
- Aplicando el algoritmo PSO es posible elegir el mejor valor del parámetro difuso  $m$ , dentro de un espacio de búsqueda. Es decir, con el mejor valor de  $m$ , se clasifican los datos de aprendizaje de las premisas de las reglas difusas.
- Utilizando una estrategia de control paralelo distribuido (PDC, por sus siglas en inglés), basada en el modelo difuso T-S, usando las premisas de las reglas y cambiando los consecuentes por la ley de control es posible regular el voltaje del sistema de generación de energía

## 1.6. Objetivos

### 1.6.1. Objetivo general

Desarrollar un sistema de generación de energía, basado en un esquema de motor de combustión interna-generador controlado mediante una estrategia difusa óptima para modelar y controlar el sistema que evita derivar un modelo matemático complejo.

### 1.6.2. Objetivos específicos

1. Diseñar una plataforma de un sistema de generación de energía utilizando un motor de combustión interna acoplado a un generador eléctrico para la regulación del voltaje.
-

2. A partir de datos experimentales, identificar un modelo difuso del tipo Takagi-Sugeno del sistema de generación de energía eléctrica, para obtener el modelo matemático del sistema.
3. Diseñar una estrategia de control basado en el modelo Takagi-Sugeno identificado para la regulación del voltaje.
4. Realizar pruebas en tiempo real con la plataforma experimental del sistema de generación de energía acoplando una carga para validar su efectividad.

## 1.7. Justificación

Recientemente, se han desarrollado diferentes investigaciones que buscan optimizar los resultados de este tipo de sistema de generación de energía. Dichas investigaciones incluyen el desarrollo de nuevos combustibles y sistemas de cámaras de explosión con nuevos materiales para la operación de los motores de combustión interna, generadores eléctricos con nuevos materiales mas eficientes y sistemas de regulación de voltaje y potencia con algoritmos de control con técnicas híbridas de identificación y control automático. Por lo tanto ,en el presente trabajo de investigación se utilizó la técnica propuesta por Takagi-Sugeno para la identificación de un sistema de generación de energía basado en un esquema de motor de combustión interna-generator 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.

## 1.8. Contribuciones

También esta investigación es para el apoyo a la docencia en análisis y control de sistemas difusos. Al igual que proponer otra manera de identificación del modelo matemático para este sistema de generación para la reducción del costo computacional para la obtención de parámetros óptimos. 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 (por sus siglas en inglés, módulo de ancho de pulso) 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 (por sus siglas en inglés, optimización de enjambre de partículas) 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 [31].

## 1.9. Artículos

Derivado del trabajo realizado en el presente tema de tesis se desarrollaron los siguientes artículos:

- Christian Reyes, Julio C. Ramos, Eduardo S. Espinoza, Rogelio Lozano, Modelado
-

difuso y control PDC de un sistema de generación de energía basado en un motor de combustión interna con un generador eléctrico, *Revista Iberoamericana de Automática e Informática Industrial*, 2024. Aceptado con modificaciones mayores.

- Christian Reyes, Julio C. Ramos, Eduardo S. Espinoza, and Rogelio Lozano, Fuzzy modelling algorithms and parallel distributed compensation for coupled electromechanical systems, *Algorithms*, MDPI, 2024. Sometido.

## **1.10. Contenido de la tesis**

El presente trabajo esta organizado por siete capítulos. El Capítulo 2 es sobre el estado del arte, en él se explica los aspectos de la investigación que son los sistemas de generación de energía, sobre lo que hay en la industria y las estrategias de control aplicadas. En el Capítulo 3 se explica la metodología ocupa para la selección de materiales del sistema de generación de energía para la construcción y los componentes utilizados para la plataforma del sistema de generación de energía (SGE), así como la instrumentación de esta misma. En el Capítulo 4 se exponen los pasos de la construcción del SGE utilizando la metodología del modelado difuso. En el Capítulo 5 se presenta la estrategia de control difuso del sistema construido en el capítulo anterior. En el Capítulo 6 se muestran los resultados en simulación y experimentales de la plataforma. Por último en el Capítulo 7 se explican las conclusiones respectivas de este trabajo de tesis, así como el trabajo futuro.

---

# Estado del Arte

---

En este capítulo se describe los estudios llevados a cabo previamente, que tienen relación con el trabajo de tesis. Este capítulo se describe el estado del arte, el cual está constituido en tres puntos importantes: en productos comerciales, en uno de los métodos de optimización utilizados es la Optimización por Enjambre de Partículas, que se inspira en el movimiento de seres vivos como aves y peces que se adaptan al entorno., en los sistemas de generación de energía y las estrategias de control aplicadas e instrumentación reportadas en la literatura consultada para el presente trabajo, teniendo como ejemplos en aplicaciones en vehículos no tripulados.

## 2.1. Productos comerciales con SGE

Existen productos comerciales que utilizan sistemas de generación de energía que son aplicados en vehículos autónomos como son los ejemplos siguientes.

En [32], menciona que vehículo no tripulado de acción militar, ver Figura 2.1, controlado a distancia por el operador a través de la línea de visión y mediante cámara y sensores orientados hacia adelante. El sistema de energía esta compuesto por un motor de gasolina junto con un generador eléctrico y una celda de fosfato de hierro y litio. En la Tabla 2.1 se muestran las características del UGV mencionado.

Actualmente, vehículos comerciales se están implementando sistemas de propulsión, mencionados anteriormente en la subsección 1.2.2, ya que beneficios de conducción y ahorro de combustible además de que propician el cuidado del medio ambiente, [33]. Recientemente



Figura 2.1: UGV de Whitebox Robotics Co., Ltd.

Tabla 2.1: Características del UGV de White Robotics.

Basado en la plataforma anfibia 6×6
Motor híbrido, hasta 12 horas de funcionamiento continuo funcionamiento continuo entre recargas. (Alcance máximo de 200 km)
Multimisión: patrullar, observar, detectar, responder y perseguir.
Plataformas multisensor, posicionamiento, cartografía, detección de obstáculos y seguridad operativa.
Velocidad de hasta 35Km/h en tierra, 5Km/h en el agua.
Gran capacidad de desplazamiento, incluyendo pantanos y nieve.
Capacidad de ascenso de hasta 30 grados con 350 kg de carga útil

hay 55 vehículos híbridos en México cuyas marcas son Audi, BMW, Ford, Hyundai, Lexus, Mazda, Porsche, Suzuki, etc., [34].

En [35], la empresa Boeing ha presentado el prototipo de su vehículo eléctrico de despegue y aterrizaje vertical (eVTOL, por sus siglas en inglés), véase Figura 2.2, capaz de soportar más de 200 kg de carga útil, sistema de propulsión eléctrica, está equipado con ocho motores y mide alrededor de cinco metros de largo, más de cinco de ancho y 1.20 de alto.

El generador NOVA-2000, en [36], es un generador de alta eficiencia diseñado para multihélices y alas fijas VTOL, se muestra en la Figura 2.3. El generador NOVA-2000 pesa



Figura 2.2: Vehículo eléctrico de despegue y aterrizaje vertical (eVTOL) de Boeing.

solo cuatro kg, lo que es mucho más liviano que cualquier otro generador que produzca una potencia de salida de 2000 W, por lo que el generador NOVA tiene cinco veces la eficiencia de otros generadores. La potencia de salida continua del generador es de 1800 W. Un motor de combustión interna consume gasolina y hace girar un generador para asegurar una salida de 48V. Además de esto, también es necesario instalar un paquete de batería LiPo 12S a bordo para ofrecer energía de respaldo de emergencia para escalar y maniobrar rápidamente. Con este generador, el peso máximo de despegue puede alcanzar los 21 kg (según su sistema de potencia), y el tiempo máximo de vuelo es de aproximadamente cinco horas, en la Tabla 2.2 se muestra los datos mencionados.



Figura 2.3: Generador Foxtech NOVA-2000 con tren de aterrizaje.

En [37], la compañía estadounidense Top Flight creó el Airborg H8 10k, que es un UAV con 8 rotores, ver Figura 2.4. Tiene un tiempo estimado de vuelo de dos horas con una carga de 4 kg o una hora de vuelo con una carga de 10 kg con una velocidad máxima de 40 mph,

Tabla 2.2: Especificaciones del Foxtech NOVA-2000.

Datos	Valores
Peso del generador	4 kg
Voltaje	48 V
Salida del generador	1.8kw (continua), 2kw (máxima)
Peso máximo de despegue	18 kg para cuadrirotor, 21 kg para hexarotor
Tanque de combustible	3.5 L
Fuel consumption	1.5L/H(Max)
Temperatura	-20 ~40°C
Tipos de UAV aplicables	Multirotores, VTOL ala fija

en la Tabla 2.3 se mencionan los datos del UAV.



Figura 2.4: Airborg H8 10K con sistema de energía híbrido en serie.

Tabla 2.3: Datos del Airborg H8 10K.

Datos	Valores
Peso seco (sin combustible, sin carga útil)	33 kg
Capacidad de combustible	Hasta 19 L (~5 US Galones)
Tamaño	70 cm de alto × 180 cm de ancho × 220 cm de largo
Tamaño (brazos retirados)	70 cm de alto × 70 cm de ancho × 90 cm de largo
Carga útil y tiempo de vuelo	4 kg de carga útil \2 horas de tiempo de vuelo
Carga útil y tiempo de vuelo	10 kg de alto \1 hora de tiempo de vuelo
Velocidad máxima	55 km/hr (34 mph; 15m/sec)

En [38], se explica sobre los vehículos aéreos multi rotor, donde tienen aplicaciones profesionales, principalmente relacionadas con el monitoreo y el análisis de imágenes, pero tienen el potencial de ir mucho más lejos, convirtiéndose en una nueva generación de vehículos de transporte de pasajeros y de carga. ModelWorks ha estado trabajando en un vehículo aéreo no tripulado doblemente híbrido con más de 250 kg de capacidad de carga. Su sistema de elevación híbrido le permite realizar despegue y aterrizaje vertical (VTOL) y vuelo horizontal con alas fijas como un avión, lo que le brinda versatilidad, ahorro de combustible

y velocidad. El sistema de propulsión híbrido consiste en un grupo electrógeno de combustible flexible que proporciona toda la potencia necesaria para la operación del UAV, lo que garantiza una alta carga útil, un reabastecimiento rápido de combustible y hasta 24 horas de vuelo.

La empresa Sullivan UV está en el mercado de vehículos no tripulados en expansión, como se indica en [39]. Los productos Sullivan UV son el resultado directo de la experiencia de ingeniería desarrollada mientras se refinaban los para los sistemas electrónicos/de potencia del vehículo, el hardware de control y los sistemas de combustible. Ofrece en el mercado alternadores, arrancadores, reguladores de voltaje, como se muestra en la Figura 2.5, también tiene soportes de motor, componentes del sistema de control, conos de nariz de aluminio, inserciones de silicona, inserciones de goma, inserciones de neopreno, bombas de combustible, componentes del sistema de combustible, filtros y tubos.

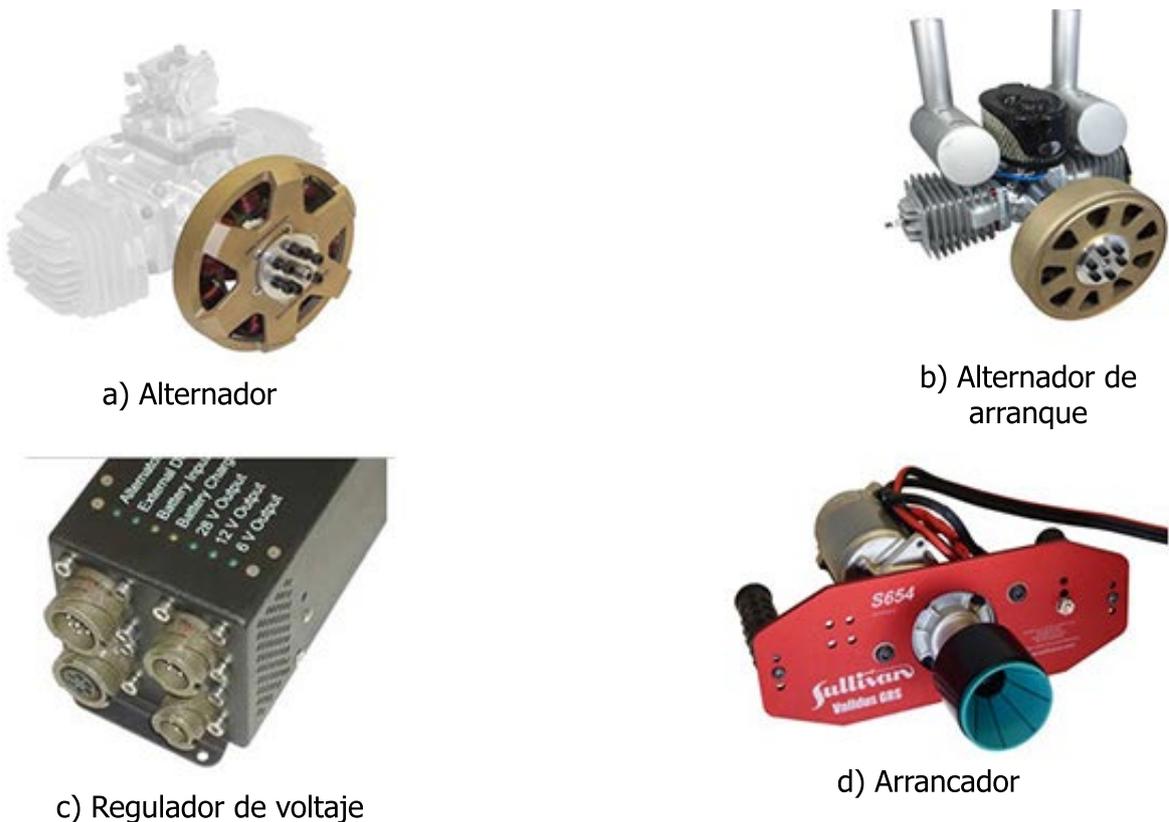


Figura 2.5: Algunos productos de Sullivan.

## 2.2. Algoritmo de enjambre de partículas

Las baterías de los vehículos eléctricos experimentan un proceso de degradación durante el funcionamiento del vehículo. Aún faltan investigaciones que tengan en cuenta tanto la degradación de las baterías como el consumo de energía en los vehículos eléctricos con batería/ultracapacitor, [40]. Lo cual los autores proponen una estrategia basada en el aprendizaje Q para minimizar la degradación de la batería y el consumo de energía. Además del aprendizaje Q, también se proponen dos métodos de gestión de la energía basados en reglas, que se optimizan mediante el algoritmo PSO. Primero se presenta un modelo de sistema de propulsión de vehículo, donde se considera el modelo de degradación de la batería por factor de severidad y se valida experimentalmente con la ayuda del Algoritmo Genético (GA).

Los HEPS suscitan un gran interés de investigación por su potencial para reducir el consumo de combustible, la emisión de gases de efecto invernadero y el coste neto actual. Sin embargo, la optimización independiente del tamaño de los componentes o de la gestión de la energía puede degradar el rendimiento. El estudio propone una optimización multiobjetivo en dos niveles que realiza simultáneamente el dimensionamiento de los componentes en el nivel superior y la gestión de la energía en el nivel inferior, [41]. La optimización multiobjetivo por PSO se desarrollo para el nivel superior debido a sus ventajas en tiempo computacional y distancia generacional. Para el nivel inferior se modifico una estrategia adaptativa de minimización del consumo equivalente, que tiene una carga computacional ligera, actualizando el factor de equivalencia en función del estado de carga de la batería y de la eficiencia del motor. Realizaron experimentos hardware-in-the-loop en tiempo real para validar la eficacia de la optimización. Los resultados de la optimización de dos niveles propuesta se comparan con dos optimizaciones independientes de un solo nivel. La solución óptima del método propuesto es significativamente superior a las optimizaciones de un solo nivel. Además, el resultado de la optimización de un nivel inferior se aproxima más al de la optimización binivel que al de la optimización de un nivel superior.

Para superar las desventajas del algoritmo PSO, como la baja precisión y la facilidad para caer en un óptimo local, se puede introducir en el algoritmo PSO el algoritmo de búsqueda de antenas de escarabajos (BAS) mediante la sustitución de las partículas por escarabajos, y evita eficazmente que el algoritmo PSO caiga fácilmente en el óptimo local, [42]. Al mismo

---

tiempo, el algoritmo BAS ya no estará limitado a la parametrización de un único objetivo. Aquí proponen método de optimización de parámetros PID basado en el algoritmo híbrido BAS-PSO para el motor de propulsión de un buque de superficie no tripulado (USV). La optimización de los parámetros PID del motor de propulsión se convierte en un problema de búsqueda de escarabajos con optimización en grupo. Los resultados numéricos muestran que el método puede resolver eficazmente los problemas de PSO y mejorar en gran medida la velocidad de convergencia. En comparación con el algoritmo genético y el algoritmo PSO estándar, el algoritmo BASPSO es superior para el ajuste de parámetros PID y puede mejorar el rendimiento del sistema de propulsión USV.

En [43], presenta una comparación del diseño del modelo óptimo de un motor de inducción de jaula de ardilla de seis fases para propulsión eléctrica mediante el uso del GA y PSO. Se diseña y simula un motor de inducción de jaula de ardilla de seis fases mediante ANSYS Motor-CAD. Se compararon los resultados de la simulación y se aplican a los motores para propulsión eléctrica, teniendo en cuenta la influencia del diseño en el rendimiento del motor. El motor de inducción de jaula de ardilla de seis fases es más eficiente energéticamente, fiable y rentable para la propulsión eléctrica en comparación con el motor trifásico convencional. En este estudio, primero se han determinado los parámetros iniciales del motor de inducción de jaula de ardilla de seis fases y luego estos parámetros se han comparado con los valores optimizados mediante Algoritmo Genético (GA) y optimización PSO. El motor diseñado se optimiza utilizando la eficiencia y las pérdidas de potencia como función de aptitud. El motor de inducción de jaula de ardilla de seis fases se diseña utilizando ANSYS Motor-CAD y los resultados de la simulación también se presentan junto con la geometría bidimensional y tridimensional.

Este artículo, [44], propone una metodología basada en los parámetros del sistema, que utiliza la optimización por enjambre de partículas, para identificar diseños de cables tolerantes a fallos, que ofrezcan unos costes mínimos a lo largo de su vida útil. Esto facilita la realización de estudios comerciales de diseño cuantificables y de alto valor que incorporan parámetros del sistema. Las principales observaciones que se extraen son que la elección entre mejorar la capacidad de resistencia a fallos de un cable superconductor aumentando la cantidad de material superconductor o de material convencional depende en gran medida de la temperatura y la tensión de funcionamiento aceptables del sistema.

---

El algoritmo básico de red neuronal difusa tiene una convergencia lenta y una gran cantidad de cálculos, por lo que en diseñaron un algoritmo de red neuronal difusa entrenado con PSO para resolver este problema, [45]. El PSO tradicional es fácil de caer en extremos locales y tiene baja eficiencia, este trabajo diseñó nuevas reglas de actualización para el peso de inercia y los factores de aprendizaje para superar estos problemas. También diseñaron reglas de entrenamiento para el PSO mejorada para entrenar la red neuronal difusa, y el algoritmo híbrido se aplicó para resolver el problema de planificación de la trayectoria de los vehículos de conducción inteligente. En [46], los algoritmos Fuzzy Adaptive PSO (FAPSO) se han estudiado ampliamente en los últimos años. En este estudio, se presenta una versión modificada de los algoritmos PSO y se denomina Optimización Adaptativa de Enjambre de Partículas Fuzzy Particularmente Sintonizable (APT-FPSO). En ella, los coeficientes de aprendizaje global y personal de cada partícula se ajustan de forma adaptativa y particular, en una medida individual, dentro de cada iteración con la ayuda de conceptos de lógica difusa.

Fuzzy c-means (FCM) es uno de los algoritmos de agrupación más utilizados por su sencillez y eficacia. Sin embargo, FCM tiene las desventajas de la sensibilidad a los valores iniciales, cayendo fácilmente en la solución óptima local y la sensibilidad al ruido. Para hacer frente a estas desventajas, en la literatura se han propuesto muchos métodos de clustering difuso basados en la optimización. PSO tiene una buena capacidad de optimización global y un híbrido de FCM y PSO han mejorado la precisión sobre la agrupación FCM tradicional. En este trabajo, [47], se propone un nuevo método de segmentación de imágenes basado en la optimización dinámica de enjambre de partículas (DPSO) y el algoritmo FCM junto con el mecanismo de reducción de ruido. DPSO tiene la ventaja de cambiar el peso de inercia y los parámetros de aprendizaje dinámicamente.

En este trabajo se propone el ajuste dinámico de parámetros con PSO para el diseño de redes neuronales modulares (MNN) utilizando computación granular y lógica difusa (FL). En la actualidad existen multitud de técnicas de optimización, pero sus implementaciones requieren tener conocimientos sobre las mismas para establecer sus parámetros, ya que el rendimiento y los resultados finales de una determinada técnica dependen de los valores óptimos de los parámetros. Por este motivo, en este trabajo, [48], proponen el ajuste difuso de los parámetros durante la ejecución, y esta propuesta permite ajustar los parámetros en función del comportamiento actual de PSO en cada iteración. El método propuesto realiza

---

una optimización modular de redes neuronales aplicada al reconocimiento humano utilizando bases de datos de referencia de orejas, iris y caras. Proponen dos sistemas de inferencia difusa para realizar este ajuste dinámico, se realizan comparaciones frente a una PSO sin este ajuste dinámico (PSO simple) para comprobar si el ajuste propuesto utilizando un sistema difuso es mejor mejorando la tasa de reconocimiento y el tiempo de ejecución. Las variantes de PSO presentadas en este trabajo tienen como objetivo realizar la optimización de MNNs. Esta optimización consiste en encontrar parámetros óptimos, tales como: número de módulos (o submódulos), porcentaje de datos para la fase de entrenamiento, algoritmo de aprendizaje, error objetivo, número de capas ocultas y su número de neuronas.

Este artículo, [49], presenta un algoritmo de optimización metaheurística híbrido que combina el filtro de partículas (FP) y PSO. El nuevo algoritmo PF-PSO consta de dos pasos: el primero genera aleatoriamente la población de partículas y el segundo amplía el dominio de búsqueda. Como segunda contribución se presenta una aplicación de este algoritmo a la sintonización óptima de controladores proporcionales-integrales-fuzzy para el control de posición de una familia de servosistemas de tipo integral. La reducción de la función de coste del algoritmo PF-PSO permite reducir el consumo energético del sistema de control difuso.

### 2.2.1. Parámetro Difuso

En la actualidad, existen diferentes trabajos sobre la selección del valor del parámetro difuso  $m$ . Por ejemplo, en ([50]) proponen bajo su experiencia un rango de  $1.1 \leq m \leq 5$ . En tanto en ([51]), 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 ([52]), se propusieron 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 ([53]), 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 ([54]), 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.

### 2.3. Sistemas de generación de energía

En [55], presenta modelos y métodos de optimización para el diseño de sistemas de propulsión de vehículos eléctricos. En concreto, deriva un modelo biconvexo de un sistema de propulsión eléctrico de batería que incluye la transmisión y tiene en cuenta explícitamente el impacto del tamaño de sus componentes en el consumo energético del vehículo. Por último, presenta un estudio de caso real para camiones eléctricos pesados, comparando una transmisión de una sola marcha con una transmisión variable continua (CVT).

Se debe de conocer cuantitativamente las características de agotamiento de la carga de la batería que alimenta un vehículo móvil terrestre no tripulado (VANT), a fin de disponer de estimaciones sobre la duración de la misión, el coste del transporte, la autonomía y otros datos útiles. La plataforma autónoma UGV del Ejército de Estados Unidos, el Clearpath Warthog. Los autores observaron que los índices de consumo de energía por metro disminuían y la autonomía aumentaba al aumentar la velocidad. La autonomía media máxima del UGV en esta configuración experimental y para velocidades de hasta 2.5 m/s resultó ser de entre 34 y 36 kilómetros, [56].

El objetivo del estudio es presentar un sistema híbrido pasivo de pila de combustible/-batería sin CC-CC para garantizar un volumen compacto y un bajo costo. Propusieron una novedosa estructura topológica del sistema pasivo de potencia de celda de combustible/-batería para el scooter eléctrico ligero, y el sistema pasivo de potencia funciona sólo con hidrógeno, [57].

El artículo, [58], presenta una comparación del balance energético del sistema de propulsión de un vehículo: vehículo eléctrico puro y vehículo equipado con transmisión eléctrica híbrida. La investigación se llevó a cabo en una pequeña plataforma terrestre no tripulada equipada con un sistema de propulsión híbrido alimentado de serie con un generador diesel y alimentado sólo eléctricamente. Se calculó la energía utilizada para cargar la batería, desde el depósito hasta la rueda. Esto también permite calcular la eficiencia total de la transmi-

---

sión de potencia eléctrica e híbrida. Calculando la capacidad de la batería y la potencia del generador, es posible determinar la autonomía del vehículo.

Al aprovechar tanto el motor eléctrico como el MCI, los sistemas de propulsión híbridos eléctricos brindan no solo un beneficio en el ahorro de combustible, sino también una reducción en el ruido de despegue y los niveles de emisión. Esta investigación considera, véase [59], el proceso de diseño y dimensionamiento de un sistema de propulsión híbrido-eléctrico para una aeronave de demostración monoplaza, la derivación experimental del mapa del motor de combustión interna y los parámetros del motor eléctrico. Además del análisis de una aeronave de mediana escala híbrida-eléctrica paralela, este documento también presenta un enfoque de escala para un vehículo aéreo no tripulado de 20 kg y un avión interurbano de 50 toneladas. En la Figura 2.6 se muestra el banco de pruebas del motor Honda GX160 y Joby JM1 para medir su comportamiento real, en el cual consiste en el motor conectado a un motor/generador sin escobillas que funciona como una carga de freno variable. La cubeta de agua proporciona refrigeración para las resistencias de carga eléctrica conectadas al generador, a través de las cuales se puede variar la carga mecánica con un controlador y resistencias de carga adicionales. Mientras en la Figura 2.7, realizaron un análisis de eficiencia a 5500 rpm, revela que el área de operación deseada (entre 4,6 y 6 kW) produce una eficiencia menor de alrededor del 20%. Para obtener mayores eficiencias en esta área, el motor debe modificarse aún más (es decir, para quitar el silenciador de escape restrictivo de Honda y reducir la contra presión en el motor).

En [60] explica que utiliza imanes permanentes basados en imanes Nd-Fe-B de tierras raras, para mejorar los parámetros técnicos de los generadores eléctricos, donde la ausencia de contactos eléctricos deslizantes aumenta significativamente la vida y la confiabilidad en comparación con los generadores eléctricos de corriente continua y los generadores síncronos. En [61] diseñaron un sistema de propulsión híbrido-eléctrico de configuración en serie para pequeños sistemas de aeronaves no tripuladas de respuesta rápida (UAS, por siglas en inglés) con el objetivo de mejorar la resistencia, proporcionar propulsión eléctrica flexible y sensible, y permitir un uso intensivo de combustible. La arquitectura híbrida en serie usa una hélice accionada por motor impulsada por un banco de baterías, que es recargada por un generador accionado por motor, similar a otros vehículos eléctricos de rango extendido. El diseño del motor se centró en un motor de combustible pesado, de encendido y

---

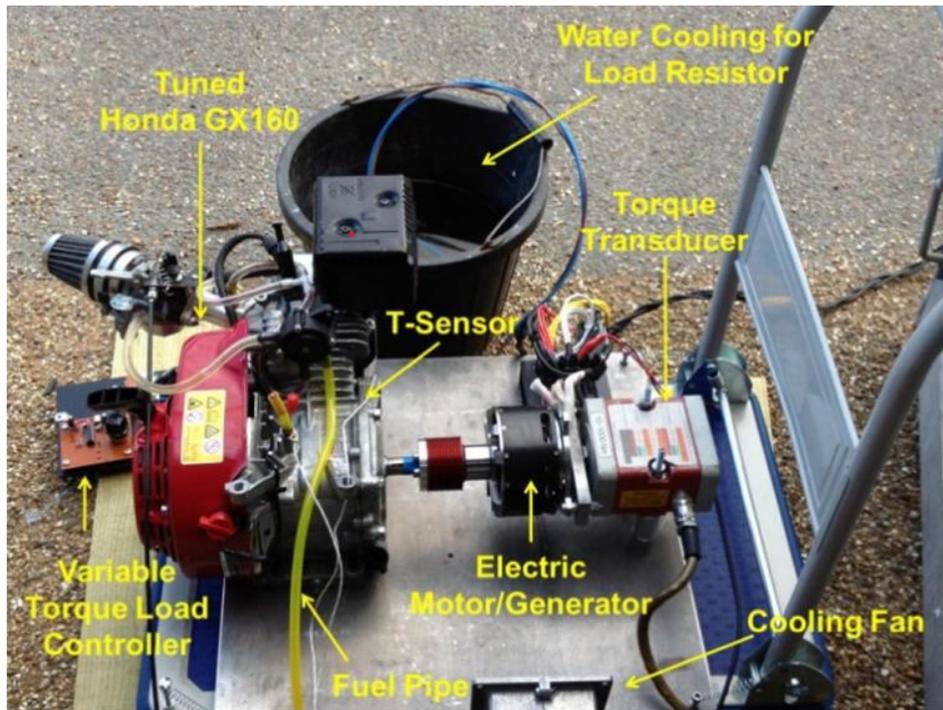


Figura 2.6: Banco de pruebas de un motor de combustión interna.

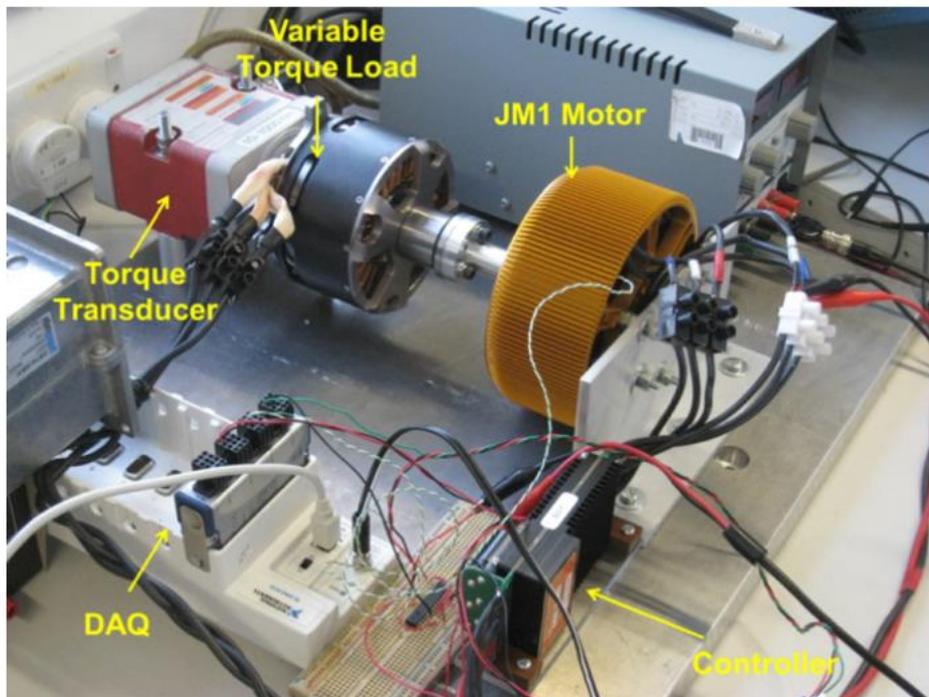


Figura 2.7: Banco de pruebas del motor eléctrico.

compresión de dos tiempos, que se acopló a un alternador de arranque integrado (ISA) para proporcionar energía eléctrica. El motor de combustible pesado fue diseñado para alta den-

sidad de potencia, eficiencia de combustible mejorada y compatibilidad con combustibles pesados. encendido por chispa de combustible pesado también se consideraron en el estudio de comercio. La configuración híbrida de la serie permite que el motor fuera desacoplado mecánicamente de la hélice, de modo que el motor pudiera funcionar en la condición de carga/velocidad para una eficiencia máxima de conversión de combustible. Utilizan un paquete de baterías recargables de alta densidad energética para almacenar energía y permitir que el UAS funcione con el motor apagado, lo que proporcionó un modo de funcionamiento con el motor apagado. La ISA permite reiniciar el motor en vuelo sin la necesidad de un motor de arranque separado.

Como se indica en [62], investiga la integración de la tecnología de propulsión híbrida-eléctrica (las configuraciones híbridos eléctricos se muestran en las Figuras 1.4 y 1.5) en un pequeño sistema de aeronave pilotado a distancia (RPAS). Su objetivo general fue desarrollar una metodología de adaptación de diseño con un potencial de ampliación a mediano y grandes aviones de transporte. Consideran un modelo RPAS actualmente operado y se evaluaron diferentes parámetros de rango, resistencia y rendimiento del combustible en condiciones representativas para los casos de propulsión híbrida, solo con MCI, solo eléctricos y híbridos. Consistentemente con las estimaciones basadas en energía, el rango fue mayor para el caso de MCI en comparación con los casos híbridos y eléctricos, siendo la principal limitación la energía específica de las baterías. Sin embargo, las configuraciones híbridas-eléctricas pueden contribuir a minimizar las emisiones de escape y mostrar complementarios a las configuraciones de propulsión solo para MCI.

En [63] presenta soluciones existentes de unidades de energía híbrido-eléctrico para cuadrirotors y propone un sistema híbrido eléctrico, véase Figura 2.8. El cual consiste en generar energía eléctrica por el generador y rectificador. La batería es conectada hacia el generador en paralelo. Igual trata esta tesis del desarrollo de un sistema de control embebido para unidad de potencia híbrida para UAV. Este sistema de control integrado es compatible con el sistema a bordo de los UAV. El sistema integrado controla el flujo de energía dentro de la unidad híbrida y asegura una salida de energía suficiente. También se creó un modelo matemático del sistema híbrido-eléctrico propuesto y en base a este modelo se ha diseñado un controlador.

---

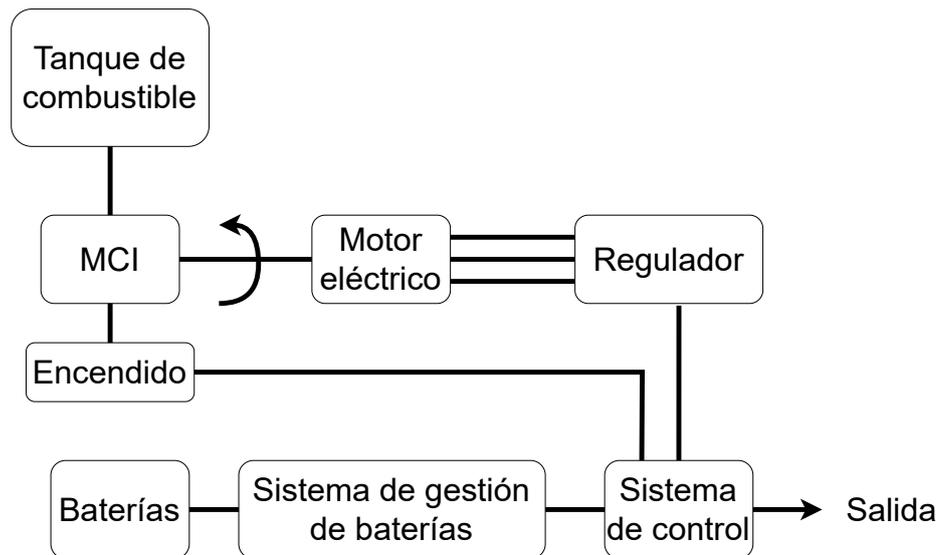


Figura 2.8: Esquema del sistema híbrido-eléctrico.

En [64] se presentó una descripción general de los métodos de simulación del sistema de propulsión de la aeronave (por sus siglas en inglés APSS (por sus siglas en inglés, Aircraft Propulsion System Simulation) necesarios para el diseño conceptual y la simulación de HEPS. Finalmente, se reveló una descripción detallada del modelo y los métodos desarrollados para modelar componentes del sistema eléctrico relacionados con HEPS.

En este trabajo [65], se diseñó, construyó y se probó un prototipo de motor híbrido de avión. Se muestra que se puede suministrar un 35 % de potencia adicional desde el sistema híbrido con una penalización de peso total del 5 %, para un sistema aéreo no tripulado dado. Se desarrolló un modelo dinámico de vuelo utilizando AeroSim Blockset en MATLAB Simulink. El dimensionamiento y la combinación de motores primarios como motores eléctricos y MCI con hélices para adaptarse a requisitos operativos específicos se pueden simplificar utilizando técnicas de curva de carga.

En [66] intenta revisar la forma en que estas tecnologías se pueden combinar para formar sistemas en múltiples configuraciones. De estos muchos sistemas identificados en la literatura, se han detallado aquellos de interés específico en el diseño y desarrollo de aeronaves no tripuladas, incluidos los beneficios potenciales de cada uno. Se incluyen algunos ejemplos de casos de estos sistemas, y se utilizan para demostrar las posibles mejoras en el rendimiento, específicamente en términos de resistencia.

En [67] mencionan una introducción de las arquitecturas de propulsión híbrido-eléctricas más populares y las evalúa críticamente en comparación con las configuraciones de propulsión convencionales y totalmente eléctricas. En [68], obtiene los parámetros del sistema de energía de un UAV con rotores coaxiales y comprueba el desempeño de los componentes. El cual está dividido en dos partes, la primera parte es la parte híbrida y la segunda parte es la plataforma con cuatro rotores. La sección híbrida incluye un motor de combustión, el embrague, un generador, rotores coaxiales y otras estructuras. El sistema tiene dos modos principales de trabajo: el modo de salida de energía (el motor impulsa los rotores para girar a través de la polea y el engranaje de la correa, proporcionando la fuerza de tracción vertical para el UAV) y el modo de generación paralela (el embrague está cerrado, y el motor acciona el generador para generar energía mientras se mueven los rotores para girar a través de la polea de la correa y el engranaje). En la Figura 2.9 se muestra el diagrama del sistema mencionado.

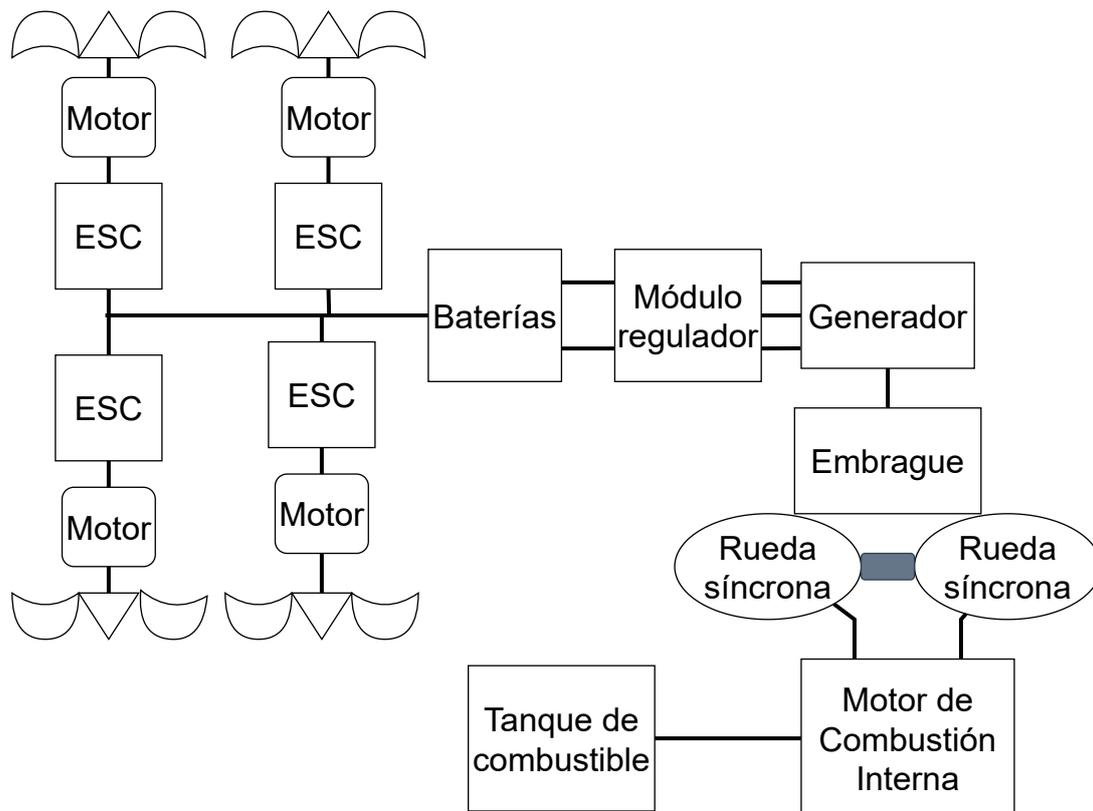


Figura 2.9: Diagrama del sistema de multirrotor.

En [69], logra la modificación de un avión de escala media con un HEPS, utilizando la optimización de objetivos múltiples. El algoritmo NSGA (por sus siglas en inglés Nondominated Sorting Genetic Algorithm) se utilizó para la optimización de objetivos múltiples y para investigar la mejor economía de combustible de las aeronaves híbridas adaptadas a diferentes duraciones de vuelo para el mismo ciclo de misión.

En [70], utiliza una red neuronal de computadora de cálculo aritmético (CMAC) para aproximar los resultados de optimización y controlar el sistema híbrido para el uso de energía de un sistema de propulsión híbrido-eléctrico paralelo para un pequeño vehículo aéreo no tripulado. La rutina de optimización flexible permite asignar una importancia relativa entre el uso de gasolina, la electricidad y la recarga. El UAV híbrido-eléctrico con el controlador CMAC utiliza un 37.8 % menos de energía que un UAV de gasolina de dos tiempos durante una misión.

En [71] presenta un método para dimensionar el sistema de propulsión eléctrica, que diseñó y fabricó un multicoptero que sea capaz de manejar los requisitos de la misión. Se da la sensibilidad de los parámetros de diseño a GTOW (por sus siglas en inglés Gross Takeoff Weight). Se construye un cuadratorotor agrícola y se compara con los resultados del dimensionamiento y la diferencia se mantiene dentro de 4 % para el peso bruto de despegue. Se introduce la relación máxima de empuje sobre peso, y el corte de la carga útil durante la operación de fumigación de pesticidas también se tiene en cuenta en el cálculo para mejorar el tamaño del dron.

Este trabajo [72], presenta un modelo multifísico de un sistema de propulsión eléctrica de un UAV pequeño y lo compara con dos modelos aproximados encontrados en la literatura. Los resultados experimentales muestran que el modelo propuesto es capaz de realizar predicciones precisas del empuje hacia adelante, así como estimaciones de la corriente demandada de la batería y la velocidad de la hélice utilizando solo el voltaje de la batería, el acelerador y la velocidad del aire como entradas.

En [73], se comparan cuatro conceptos diferentes de aeronaves con respecto a los posibles beneficios de los sistemas de propulsión híbridos-eléctricos. Se confirma la hipótesis de los autores; los sistemas de propulsión híbridos-eléctricos son los más adecuados para

---

aeronaves con requisitos de potencia fluctuantes. Un sistema de propulsión eléctrico puede absorber períodos breves de requisitos de alta potencia. Es poco probable que las aeronaves que vuelen a una potencia constante y que no se aceleren significativamente durante el vuelo se beneficien de los sistemas de propulsión híbridos-eléctricos. Para ambos objetivos de optimización, e incluso los niveles de tecnología más optimistas, el avión de aviación general y el avión de transporte regional convergieron en configuraciones de propulsión de combustión de combustible de propulsión convencional.

Existen sistemas híbridos basados en pistones, sin embargo, enfrentan problemas con el enfriamiento de la culata de cilindros, así como problemas de vibración que podrían mitigarse incorporando un sistema turboeléctrico. Este artículo [74], presenta el diseño preliminar y la caracterización del sistema eléctrico de un sistema híbrido de propulsión y potencia distribuida gas-eléctrico para pequeñas aeronaves no tripuladas basado en un motor de turbina. La configuración turboeléctrica que presenta cumple con los requisitos de versatilidad y escalabilidad para aeronaves pequeñas de hasta 25 kg que vuelan una variedad de misiones de inspección de oleoductos y gasoductos. Para la caracterización del sistema eléctrico, seleccionaron un motor eléctrico capaz de este consumo de energía esperado como planta motriz para la prueba de la fase I. Esta prueba inicial, también que consta de un generador trifásico compatible y carga eléctrica, mostró las relaciones entre la velocidad angular del generador, la carga eléctrica y la eficiencia eléctrica.

### 2.3.1. Estrategias de control aplicadas

Dentro del estudio del estado del arte se revisaron artículos relacionados a sistemas difusos utilizando el método de clustering usando mínimos cuadrados. Este método se empleará para obtener los parámetros consecuentes del sistema difuso. Así como estrategias de control usadas en SGE y en vehículos no tripulados.

Este trabajo, [75], se centra en la aplicación de una de las técnicas de soft computing, es decir, un controlador basado en lógica difusa en el vehículo autónomo para la difícil tarea de evitar obstáculos. El controlador de lógica difusa propuesto tiene dos entradas y una salida. Las distancias del sensor izquierdo y derecho se han considerado como la entrada, mientras que el ángulo de rotación se considera como la salida. Se ha utilizado un total de 36 conjuntos

---

de reglas base para diseñar los controladores de lógica difusa con interfaz gráfica de usuario, que proporciona la información en la que se mueve el vehículo.

Para diseñar un controlador proporcional-integral (PI) difuso óptimo para un motor de corriente continua sin escobillas (BLDCM), en este artículo, [76], desarrolla un enfoque basado en PSO de vibración aleatoria (PSO) y el algoritmo de búsqueda gravitacional (GSA). Mediante la introducción de un término de vibración aleatoria, el PSO-GSA, que combina las ventajas de PSO y GSA, puede obtener más potencia para explotar el espacio de búsqueda alrededor de los mínimos locales y/o saltar fuera del atrapamiento local para explorar más a fondo todo el espacio de búsqueda. Se realizan varias pruebas de simulación con funciones de referencia que confirman la superioridad de la propuesta PSO-GSA en comparación con PSO y GSA. El PSO-GSA desarrollado se aplica para diseñar un controlador PI difuso óptimo para BLDCM, cuyos parámetros pueden seleccionarse de forma óptima para obtener un mejor rendimiento. En, [77], estudia la aplicación del algoritmo de PSO basado en el control PID difuso para el control estable de un sistema de cojinetes magnéticos activos (AMB).

Para resolver los posibles efectos adversos de las perturbaciones externas sobre la estabilidad del sistema, se construye un modelo difuso T-S que considera tanto las incertidumbres de los parámetros como las perturbaciones externas, y se utiliza un método de control adaptativo difuso relativamente maduro para el control de la suspensión, [78]. Sin embargo, teniendo en cuenta el rendimiento de seguimiento de los parámetros de control del sistema y la velocidad de respuesta de los cambios de parámetros cuando cambia la perturbación externa, se utiliza el algoritmo PSO para optimizar el sistema. La eficacia de la ley de control adaptativo difuso optimizada para coordinar la estabilidad en lazo cerrado del sistema de suspensión se demuestra en términos de velocidad de respuesta y rendimiento de convergencia. Basándose en la desigualdad matricial lineal (LMI), la región de respuesta de control Se define la región de respuesta de control que satisface el rendimiento de control tras la optimización.

Los controladores de movimiento longitudinal basados en modelos excesivamente simplificados dan lugar a errores de estado estacionario, oscilaciones y excesos de velocidad, todo lo cual perjudica a los múltiples objetivos del UGV (capacidad de seguimiento de la trayectoria, ahorro de energía y confort de marcha), [79]. Para el modelo de seguimiento de

---

trayectoria, los autores establecen un modelo dinámico interno de tren de potencia/freno y dividimos la resistencia externa en tres componentes. La estrategia de control se compone de un controlador predictivo multiobjetivo (MPC) de alto nivel que obtiene la aceleración interna óptima y un controlador de bajo nivel que calcula las entradas de control basándose en el modelo de la cadena cinemática/freno.

Este trabajo de investigación, [80], se implementó un modelo integrado utilizando una controlador de lógica difusa (FLC) de Intervalo Tipo 2 de un tren de potencia eléctrica con un sistema híbrido de almacenamiento de energía (HESS). Consta de energía solar fotovoltaica, batería, pila de combustible y supercondensador con controladores como entrada y muestra una respuesta práctica. El sistema de accionamiento PMSM proporciona la salida deseada en diferentes condiciones de irradiación solar fotovoltaica y entrada de par, lo que proporciona un rendimiento satisfactorio según la ejecución requerida del sistema.

El control lateral se considera uno de los retos más difíciles en el desarrollo de vehículos automatizados debido a sus características de no linealidad, incertidumbres paramétricas y perturbaciones externas. Por lo cual en [81], propusieron una estrategia de control adaptativo de modo deslizante difuso para el control lateral de vehículos automatizados basados en visión. En primer lugar, diseñaron un algoritmo de visión para proporcionar información precisa de la localización del vehículo respecto a la trayectoria de referencia. Y proponen un controlador lateral adaptativo de modo deslizante difuso para contrarrestar las incertidumbres paramétricas y las fuertes no linealidades, y se demuestra la estabilidad asintótica del sistema de control lateral de lazo cerrado mediante la teoría de Lyapunov.

En este artículo, [82], se presentaron modelos y algoritmos de optimización para calcular las estrategias óptimas de control de bajo nivel para cadenas cinemáticas eléctricas híbridas. En concreto, se estudia el funcionamiento con combustible mínimo de un MCI acoplado a un sistema de recuperación de energía eléctrica, compuesto por una batería y dos motores conectados al turbocompresor y a las ruedas, respectivamente. Combina enfoques de modelado basados en la física con redes neuronales para identificar un modelo afín a partes de la unidad de potencia que tenga en cuenta la dinámica interna del motor, y formulan el problema de control de combustible mínimo para un ciclo de conducción dado.

---

En este artículo, [83], estudiaron una gestión de la energía basada en la predicción para un HESS a bordo, que combina motor-generador, batería y ultracondensador. Cada una de estas fuentes de energía tiene una función de utilidad específica para representar su preferencia única. Por lo que presentaron una estrategia teórica de juegos para modelar las distintas preferencias de estas fuentes de energía y sus interacciones y, de este modo, distribuir adecuadamente la demanda de carga entre ellas. Para mejorar aún más la gestión energética, que puede verse influida por la fluctuación de la demanda incierta de carga eléctrica, incluyeron una predicción en la estrategia teórica de juego básica para formar una estrategia teórica de juego basada en la predicción. La demanda de carga eléctrica puede derivarse de la velocidad en HESS y la predicción de la velocidad se implementa mediante una red de memoria a corto plazo. La precisión de esta predicción se mejora mediante la extracción de características y el análisis de series temporales.

Utilizaron una red neuronal recurrente (RNN) para predecir la generación de energía fotovoltaica (FV), [84]. Una RNN es una red neuronal artificial en la que la conexión entre unidades se compone de una estructura cíclica que puede reflejar las características de las series temporales. Por lo tanto, con el fin de incorporar una técnica de control predictivo de modelos para ajustar la oferta y la demanda de energía, este estudio utiliza datos meteorológicos medidos previamente y datos de generación de energía fotovoltaica para predecir la futura generación de energía fotovoltaica. Igual realizan varios procesos de optimización, como la normalización, la clasificación de los datos de aprendizaje y la configuración de las opciones de las capas, para crear un modelo predictivo.

En esta investigación [85], se integraron una batería y un ultracapacitor en un vehículo eléctrico para evaluar su rendimiento. La utilización frecuente de vehículos basados en MCI ha tenido un importante impacto negativo en el medio ambiente y ha acelerado el agotamiento de las reservas de combustibles fósiles, lo que ha provocado un aumento significativo del precio de la gasolina en las dos últimas décadas. Las deficiencias del enfoque tradicional para determinar valores precisos de los factores relacionados con la corriente y los motores el sistema basado en controladores de lógica difusa se creó para superar los inconvenientes del sistema basado en controladores de lógica difusa implementado en el controlador tradicional. El controlador lógico realizó múltiples iteraciones que produjeron valores precisos, el controlador lógico difuso controla el voltaje.

---

El vehículo híbrido terrestre no tripulado (HUGV) puede circular por cualquier terreno, incluidas las paredes, y también volar, utilizando la fuerza de empuje multidireccional de las hélices. En la era de la revolución industrial, los UGV híbridos deben ser autónomos y tener capacidad de decisión inteligente, [86]. Durante la escalada de muros de los UGV híbridos, la estabilidad es esencial y depende de la información en tiempo real procedente de múltiples sensores. Para aumentar la estabilidad y el control, se propone sustituir los lazos de control PID por algoritmos basados en IA (Inteligencia Artificial) que reduzcan el tiempo de decisión y la complejidad matemática. Para el movimiento autónomo en cualquier terreno utilizando el modelo propuesto, los UGVs inteligentes pueden mapear y localizar simultáneamente. Pueden tomar decisiones inteligentes sobre el modo de movimiento, es decir, conducir sobre el suelo o la pared, dirigir sobre el suelo o la pared, volar y maniobrar utilizando las lecturas de los sensores en tiempo real. En la Figura 2.10 describe un flujo esquemático y la integración de los módulos que proponen.

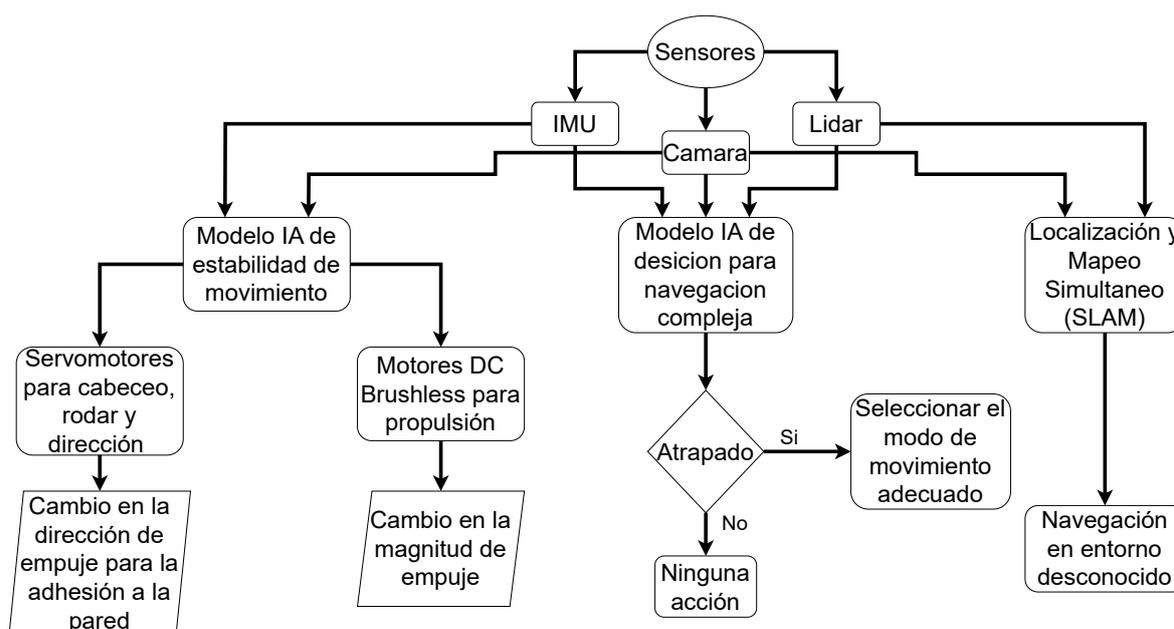


Figura 2.10: Integración de la estructura de IA en UGVs.

El objetivo principal de [87] es controlar la velocidad del vehículo eléctrico híbrido no lineal (HEV, por sus siglas en inglés Nonlinear Hybrid Electric) mediante el control de la posición del acelerador. Diseñaron varias técnicas de control, como el controlador Proporcional Integral Derivado (PID) junto con el controlador de retroalimentación de estado (SFC, por sus siglas en inglés State Feedback Controller), como la Técnica de asignación de polos (PPT, por sus siglas en inglés Pole Placement Technique), el Controlador Basado en el Obser-



Figura 2.11: AeroSonde UAV.

vador (OBC, por sus siglas en inglés Observer Based Controller) y el Controlador Regulador Lineal Cuadrático (LQR, por sus siglas en inglés Linear Quadratic Regulator). También diseñaron algunas técnicas de control inteligente, como el PD Difuso, un PI Difuso junto con el controlador adaptativo, como el controlador de organización automática (SOC, por sus siglas en inglés Self Organizing Controller). El objetivo de su trabajo de investigación es proporcionar un movimiento suave del acelerador, cero errores de velocidad de estado estable y mantener una velocidad de Vehículo seleccionado. También hicieron un estudio comparativo para identificar la superioridad de la técnica de control óptimo para obtener una mejor economía de combustible, una menor contaminación, una mayor seguridad en la conducción y una reducción de los costos de fabricación.

En [88] presentaron una estrategia de control y gestión de energía basada en lógica difusa para vehículos híbridos paralelos. Usando los comandos del conductor, el estado de carga de la batería y la velocidad del generador del motor, desarrollaron un conjunto de reglas de control usando lógica difusa, para dividir efectivamente la potencia entre las dos centrales eléctricas: motor eléctrico y MCI. El objetivo de [89] fue establecer una estrategia de gestión de energía para un sistema híbrido de propulsión marina diesel-eléctrica. Para esto, se diseñaron e implementaron controladores predictivos con diferentes capacidades: un MPC estándar y un MPC (por sus siglas en inglés, Model Predictive Control) adaptativo. De acuerdo con [90] presentaron una nueva estrategia de control difusa para la propulsión híbrido por celda de carga/batería de un UAV. En [1] proponen un simulador de banco de pruebas para un sistema en paralelo para aplicaciones aeronáuticas.

De igual manera se tiene contemplado en el proyecto implementar un control difuso basado en un modelo difuso T-S, se leyó varios artículos referentes al control ya mencionado

con retardos. Ya que el motor de combustión interna tiene un retardo al momento de la ignición.

En [91] propusieron una nueva función candidata difusa de Lyapunov para una clase de sistemas difusos continuos en el tiempo, la cual considerando como trabajo desde el origen hacia al vector difuso de fuerzas. En [13], para proteger la celda de combustible y garantizar su eficiencia, se propone un esquema de batería de estructura variable para para mejorar el sistema eléctrico híbrido, y se desarrolla un método de lógica difusa incremental teniendo en cuenta la eficiencia y la tasa de cambio de potencia de la celda de combustible para equilibrar la carga del sistema eléctrico. El objetivo de [92] fue diseñar y aplicar el controlador basado en reglas sistema de inferencia neuro difuso adaptativo (ANFIS) con la estrategia semi empírica para predecir no linealidades, incertidumbres del sistema de almacenamiento de energía con dos salidas de corriente de batería y voltaje DC para elegir el diseño del sistema de control.

Este trabajo [75], se centró en un controlador basado en lógica difusa en un UGV para la difícil tarea de evitar obstáculos, el cual tiene dos entradas y una salida. Las distancias del sensor izquierdo y derecho se han considerado como la entrada, mientras que el ángulo de rotación se considera como la salida. Se han utilizado un total de 36 conjuntos de reglas base para diseñar los controladores de lógica difusa con interfaz gráfica de usuario, que proporciona la información en la que se mueve el vehículo. En [93] se diseñó un sistema de detección de sensores montado en el UGV y se estudia el modelo de estimación cinemática del vehículo, además que en este trabajo se diseña un algoritmo de evitación de obstáculos de red neuronal difusa basado en la fusión de información multisensor.

De acuerdo con [94], se obtienen mejores resultados logrando condiciones suficientes menos conservadoras sobre la definición positiva de las sumas difusas (relacionadas con los criterios de estabilidad y rendimiento en el control difuso). Basado en el teorema de Polya, se puede demostrar que las condiciones son progresivamente menos conservadoras a medida que aumenta un parámetro de complejidad  $n$ , volviéndose asintóticamente exacto. Los límites para  $n$  se pueden calcular si se introduce un parámetro de tolerancia. El número de condiciones es polinomial en  $n$ ; Si se introducen variables de decisión, el número de ellas puede ser exponencial en  $n$ . El valor alcanzable de  $n$  en un problema particular de control

---

difuso depende de la precisión del solucionador y de los recursos informáticos disponibles. Mientras en [95] desarrollan extensiones de controladores no cuadráticos difusos y observadores que permiten reducir el conservatismo de los resultados que obtienen e incrementan la solución de conjuntos del modelo no lineal. La complejidad computacional incrementa de una manera fácil para aprovechar el uso de una aplicación real. Por otro lado en [96] proponen una nueva estrategia simple para reducir el carácter conservador en el análisis de estabilidad de los sistemas difusos de tiempo continuo T-S basados en funciones difusas de Lyapunov.

En [97] desarrollan condiciones para el diseño del controlador utilizando funciones no cuadráticas de Lyapunov y controladores retardados y un marco general para el uso de tales funciones de Lyapunov. Los dos métodos de diseño de controladores desarrollados superan y generalizan los métodos actuales más modernos. Los métodos propuestos se extienden al control robusto y  $H_\infty$ .

Los autores en [98] presentaron tres algoritmos diferentes para la aproximación de mínimos cuadrados recursivos de la función no lineal multidimensional mediante un sistema difuso que garantiza la monotonía. Los autores en [99] se centraron principalmente en el problema de la estimación de fallas para una clase de sistemas difusos Takagi-Sugeno (T-S) con retrasos de estado. Primero se introduce un enfoque de solución de mínimos cuadrados de la norma mínima (por sus siglas en inglés MNLSS) para establecer un compensador de estimación de fallas, que puede optimizar el estimador de fallas. Diseñaron un observador de estimación de fallas a través del enfoque MNLSS, el cual es exactamente capaz de disminuir el efecto de los errores de estado en la precisión de la estimación de fallas. La falla del actuador se puede estimar con buena precisión utilizando el estimador de falla basado en MNLSS diseñado. Las ganancias del observador se diseñaron a través del método LMI (Linear Matrix Inequality) para que el sistema de error difuso general T-S sea asintóticamente estable y satisfaga el rendimiento  $H_\infty$  prescrito.

Los autores en [100] propusieron un método neuro-difuso para modelar el comportamiento dinámico de los sistemas complejos basados en datos experimentales reales. Primero, investiga la fuerza de disparo de las reglas mediante un método de agrupamiento difuso c-means. Luego, recupera las funciones de membresía de las variables de entrada mediante

---

una red neuro-difusa. Finalmente, identifica los parámetros de los modelos locales lineales por mínimos cuadrados recursivos.

Los autores en [101] presentaron un algoritmo de identificación de agrupamiento sustractivo para los sistemas de lógica difusa (FLS, por sus siglas en inglés Fuzzy Logic System) Takagi-Sugeno-Kang (TSK). Este algoritmo, el método de agrupamiento sustractivo se combina con algoritmos de estimación de mínimos cuadrados para identificar previamente un tipo de FLS de forma de datos de entrada/salida.

Los autores en [102] desarrollaron el método de mínimos cuadrados acotados difusos que utiliza información lingüística y datos numéricos para identificar modelos difusos. Basado en el concepto de sistemas de intervalo difuso, la idea básica de este método es: utilizar toda la información lingüística disponible para obtener un sistema de intervalo difuso y luego usar el sistema de intervalo difuso para dar el conjunto de modelos admisible (es decir, el conjunto de todos los modelos difusos que son aceptables y razonables desde el punto de vista de la información lingüística), y para encontrar un modelo difuso y el conjunto de modelos difusos admisibles que mejor se ajusta a los datos numéricos disponibles.

Los modelos difusos T-S no siempre son fáciles de interpretar, en particular cuando se identifican a partir de datos experimentales. Idealmente, es deseable que un modelo difuso dinámico de Takagi-Sugeno proporcione una predicción no lineal global precisa y, al mismo tiempo, que sus modelos locales sean aproximaciones cercanas a las linealizaciones locales del sistema dinámico no lineal. Esto último es importante en muchas aplicaciones donde los modelos locales constituyentes se usan individualmente y ayudan a la validación e interpretación del modelo considerablemente. Esto define un problema de identificación de objetivos múltiples, a saber, la construcción de un modelo dinámico que es una buena aproximación de la dinámica local y global del sistema subyacente, [103].

Los autores en [104], propusieron un control difuso predictivo tolerante a fallas con un método de acción integral para una clase de sistemas no lineales. La estrategia de control propuesta se basa en una combinación entre la ley de control de Compensación Distribuida Paralela (PDC) y el MPC donde el enfoque difuso T-S utiliza las Variables de premisa inconmensurables.

---

Los autores en [105] tuvieron como objetivo el aplicar varios enfoques de control para controlar la velocidad de un vehículo pesado utilizando un sistema electrónico de control del acelerador. Acorde a los resultados de la simulación para cuatro enfoques mostraron que el sistema de control de inferencia difuso basado en la red neuronal adaptativo robusto tiene un mejor rendimiento en lugar de otros sistemas de control estándar en condiciones de velocidad variable.

En este documento [106], se presentó un método de predicción basado en la lógica difusa para revelar el rendimiento y las características de emisión de un motor de encendido por chispa de un solo cilindro (SI, en inglés Spark Ignition), que utiliza diferentes mezclas de combustible. El sistema de inferencia neuro-difuso adaptativo, ANFIS (Adaptive Network based Fuzzy Inference System), se utilizaron para determinar algunos parámetros característicos debido a la combustión.

En [107] los autores ocuparon el control no lineal de un motor de encendido por chispa de tres cilindros utilizando una estrategia de control difuso basada en un modelo de T-S y un enfoque de control robusto. En [108] se presentó un control del movimiento longitudinal de un avión. El diseño de control de compensación distribuida paralela se basa en el modelo T-S. En [109] los autores identificaron el par motor SI a partir de una medición de entrada-salida, el cual propuso un modelo dinámico no lineal que utiliza un sistema adaptativo de inferencia neuro-difusa y un auto-regresivo no lineal con estructura de entrada exógena para identificar el comportamiento dinámico no lineal de un motor SI.

El MCI consume mucho tiempo y es costoso, por lo tanto, se están adoptando muchas técnicas de computación flexible en este campo. El término informática suave se refiere a encontrar la solución de un problema inexacto. Las diferentes técnicas de computación flexible que utilizan los autores [110], en este campo son la Red Neural Artificial, el Enfoque Difuso, ANFIS, etc. Por el cual el motivo de este trabajo revisan las investigaciones que se llevan a cabo en el campo de motores de combustión interna en diferentes tipos de motores con varios combustibles alternativos utilizando estas técnicas de computación flexible.

El objetivo en [92] fue diseñar y aplicar el controlador basado en reglas sistema de inferencia neuro difuso adaptativo (por sus siglas en inglés ANFIS, Adaptive Neurofuzzy Inference System) con la estrategia semiempírica para proteger de no linealidades, incerti-

---

dumbres del sistema de almacenamiento de energía con dos salidas de corriente de batería y voltaje, para elegir el diseño del sistema de control, que se prueba bajo condiciones de carga pesada y ligera, y mejorar la eficiencia en vehículos eléctricos.

Los autores en [111] propusieron un controlador de motor turborreactor para aeronaves no tripuladas utilizando el algoritmo PI difuso. Presenta una regla de inferencia difusa hecha por la función de logaritmo que puede mejorar las características del error de seguimiento en estado estacionario. La lógica difusa con función de logaritmo está diseñada para obtener la aceleración y desaceleración rápidas del motor bajo la condición de que el punto de operación permanezca entre las líneas de control de sobre tensión y llama durante el transitorio.

Finalmente en la parte de algoritmos genéticos, en el trabajo [112], propuso dos métodos de control de vuelo utilizando el modelo de simulación del UAV, que fue modelado y simulado utilizando MATLAB/Simulink. Los dos métodos son un controlador PID autoajutable mediante algoritmo genético y un controlador ANFIS. En un controlador PID autoajutable, un PID se controla genéticamente y se utiliza como piloto automático para optimizar los parámetros del controlador.

---



# Metodología e Instrumentación

---

En este capítulo se describe la metodología aplicada para la selección de componentes para la instrumentación del prototipo, donde describe los materiales, el diseño y construcción del sistema de generación de energía. Así como también se menciona la instrumentación a partir de la metodología utilizada.

## 3.1. Metodología para la selección de componentes

La metodología empleada para la selección de componentes para la plataforma del sistema de generación de energía fue la Nigel Cross, como se indica [113]. Nigel Cross define metodología de diseño como el estudio de los principios, prácticas y procedimientos de diseño en un sentido amplio. Su objetivo central está relacionado con el cómo diseñar, e incluye el estudio de cómo los diseñadores trabajan y piensan; y el establecimiento de estructuras apropiadas para el proceso de diseño. A continuación, los pasos de esta metodología, así como la secuencia del procedimiento para el proceso de diseño de Nigel Cross para el proyecto de tesis.

### 3.1.1. Árbol de ideas

El objetivo principal del método del árbol de objetivos, es para aclarar las subfunciones y las tareas, y su relación entre ellas. En la Figura 3.1, se muestra el árbol de ideas para el diseño de la plataforma del sistema.

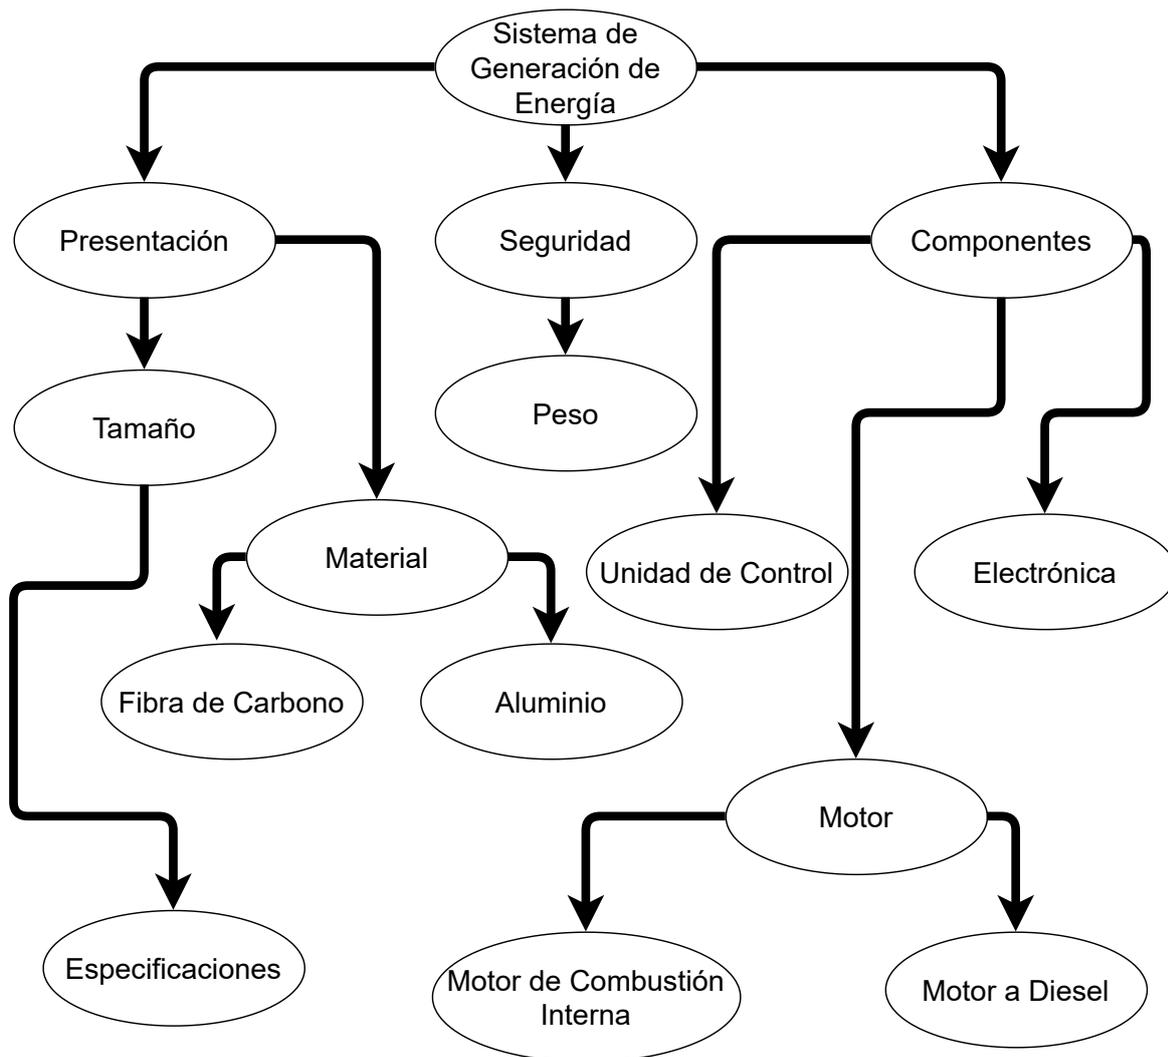


Figura 3.1: Árbol de ideas.

### 3.1.2. Establecimiento de funciones

En este apartado se expresa la función general para el diseño en términos de la conversión de insumos en productos. El punto de partida de este método es concentrarse en lo que tiene que lograrse mediante un nuevo diseño, y no en la forma en que se ha de lograr. La manera más simple y más básica de expresar esto es representar el producto a ser diseñado como una simple caja negra. Después es dividir la función general en un conjunto de subfunciones esenciales. Los subfunciones comprenden todas las tareas que tienen que llevar a cabo dentro de la caja de color negro. A continuación se muestra la caja negra, véase Figura 3.2, y las subfunciones esenciales.

## 1. Material

- Ligero.
- Resistencia a la corrosión.
- Durabilidad.

## 2. Componentes

- Buena precisión.
- Bajo costo.

## 3. Motor

- Tamaño.
- Bajo costo.
- El combustible sea fácil de conseguir.

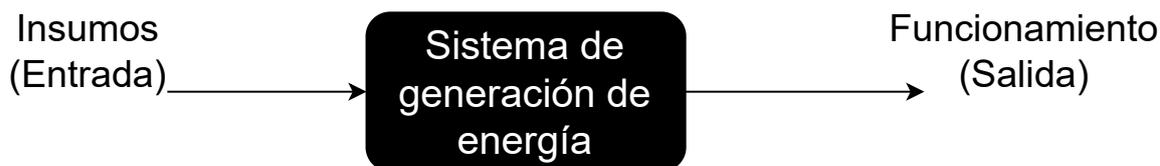


Figura 3.2: Caja negra del sistema.

### 3.1.3. Requerimientos

En esta subsección se realiza una lista de especificaciones del producto, considerando los diferentes de cada solución si los requerimientos son demandados (D) o deseados (W). En la Tabla 3.1 se muestra la lista de especificaciones.

Tabla 3.1: Especificación del sistema de generación de energía.

D ó W	Requerimientos
D	Material: Baja densidad, no corrosivo, resistencia a los materiales
W	Computadora.
D	Tipo de motor: De gasolina, diésel.
W	Tipo de generador eléctrico.
D	Que cumpla las especificaciones de dimensión.
W	De bajo costo.

### 3.1.4. Determinando características

El objetivo del método QFD, véase en [114], es establecer objetivos para las características del producto. El procedimiento es el siguiente:

- Identificar los requerimientos del cliente en términos de atributos del producto.
- Determinar la importancia relativa de los atributos. Técnicas de orden y puntos de asignación pueden ser usados para ayudar a determinar el peso que debería ser adjuntado para varias cualidades.
- Evaluar la competencia.
- Dibujar la matriz con las características del producto.
- Identificar las relaciones entre las características y las cualidades del producto.
- Identificar cualquier interacción.
- Establecer figuras para las características.

La metodología aplicada para la base del sistema de generación de energía fue por el Despliegue de la Función de Calidad (QFD, por sus siglas en inglés), véase en [114], el cual es un método de diseño de productos que recoge las demandas y expectativas de los clientes, el cual mejora las necesidades de comprensión del cliente, mejora el análisis de costos y beneficios, reduce el cambio de ingeniería en el diseño, etc. Para construir la casa de calidad se tiene que identificar las diferentes secciones que tiene, véase Figura 3.3.

1. Identificamos los ¿quiénes?, los cuales son los clientes. En el caso del proyecto son los dos asesores.
  2. ¿Qué es lo que quiere el cliente? Son los requerimientos que quiere el cliente, son:
    - Resistencia a la corrosión
    - Bajo costo de fabricación
    - Bajo costo de material
    - Que cumpla con las dimensiones requeridas.
    - Que no se frágil.
-

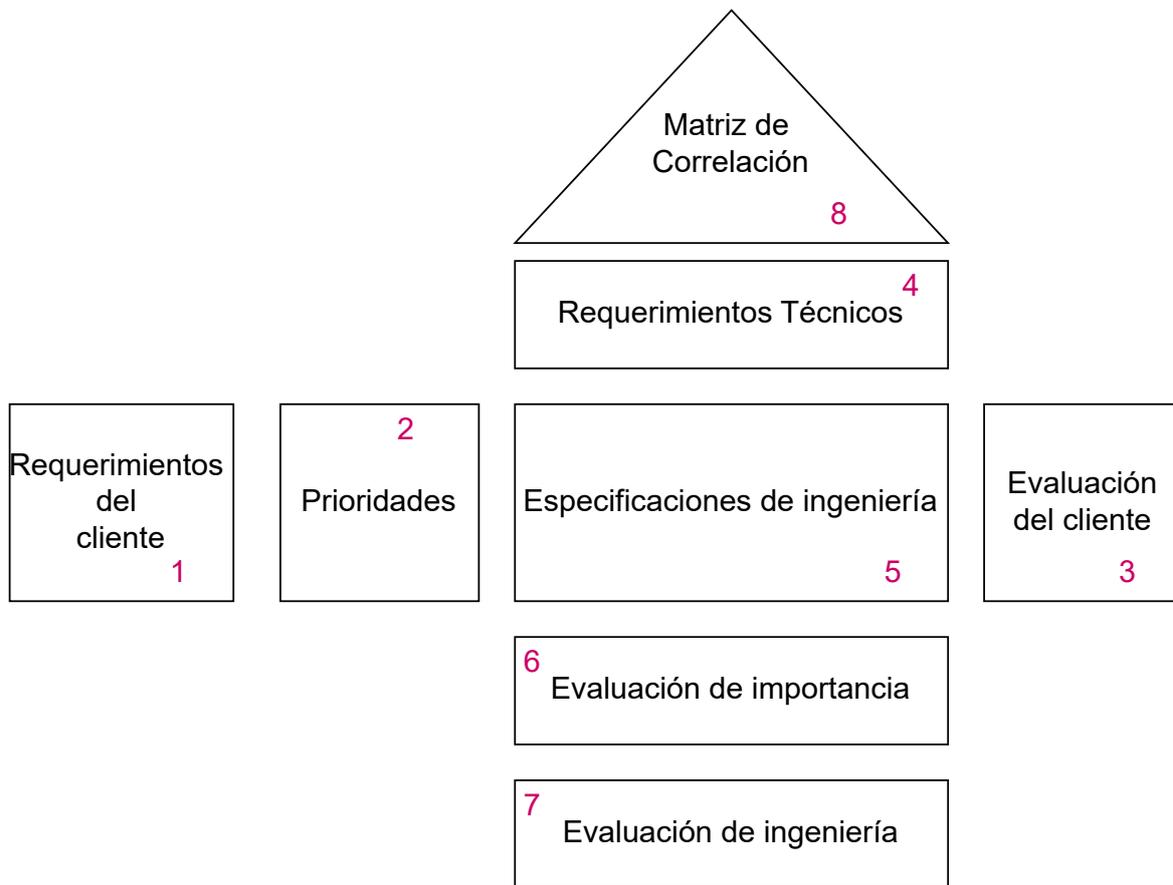


Figura 3.3: Diagrama QFD.

3. Determinar la importancia de los requerimientos (¿quién? vs ¿qué?):

- Se prepara una tabla donde aparezcan los clientes, donde asignará un puntaje.
- Preparar una tabla con cada uno de los requerimientos obtenidos en el paso anterior.
- Se debe dejar bien claro la forma en que deben asignarse los puntajes.

4. ¿Qué tan satisfechos están los clientes ahora? Se analiza la competencia, [114], existente en el diseño del producto. Consta varios niveles:

- El producto no cumple con el requisito en absoluto.
- El producto cumple con los requisitos ligeramente.
- El producto cumple con el requisito de alguna manera.
- El producto cumple con el requisito de su mayoría.
- El producto cumple con los requisitos por completo.

5. Generar las especificaciones de ingeniería: Se traducen los requerimientos del cliente en especificaciones de ingeniería, como:
  - Elaboración.
  - Material.
  - Estética.
  - Durabilidad.
  
6. Relación entre requerimientos y especificaciones de ingeniería. Se asignará una flecha apuntando hacia arriba, en el caso que al aumentar una determinada especificación de ingeniería y se asignará una flecha apuntando hacia abajo, en el caso que al disminuir una determinada especificación de ingeniería. Y por último se le agregaran valores.
  - Del más fuerte relación a la más débil que va de 5 a 1.
  
7. Establecer objetivos para cada especificación de ingeniería y su importancia: Con los valores de importancia de los requerimientos asignados por el cliente, y los valores de relación presentes en cada especificación de ingeniería, se procede a calcular la importancia de cada especificación según el cliente.
  - Para cada cliente multiplicamos la importancia de los requerimientos con los valores de relación 1-5, con el objetivo de tener los valores ponderados.
  - Sumar los valores ponderados de cada especificación.
  - Normalizar estas sumas a través de todas las especificaciones.
  
8. Identificarlas relaciones entre especificaciones de ingeniería.
  - Fuerte ●
  - Media ○
  - Débil △
  - Sin ninguna relación 0

En la Figura 3.4, se muestra la casa de la calidad QFD del presente proyecto

---

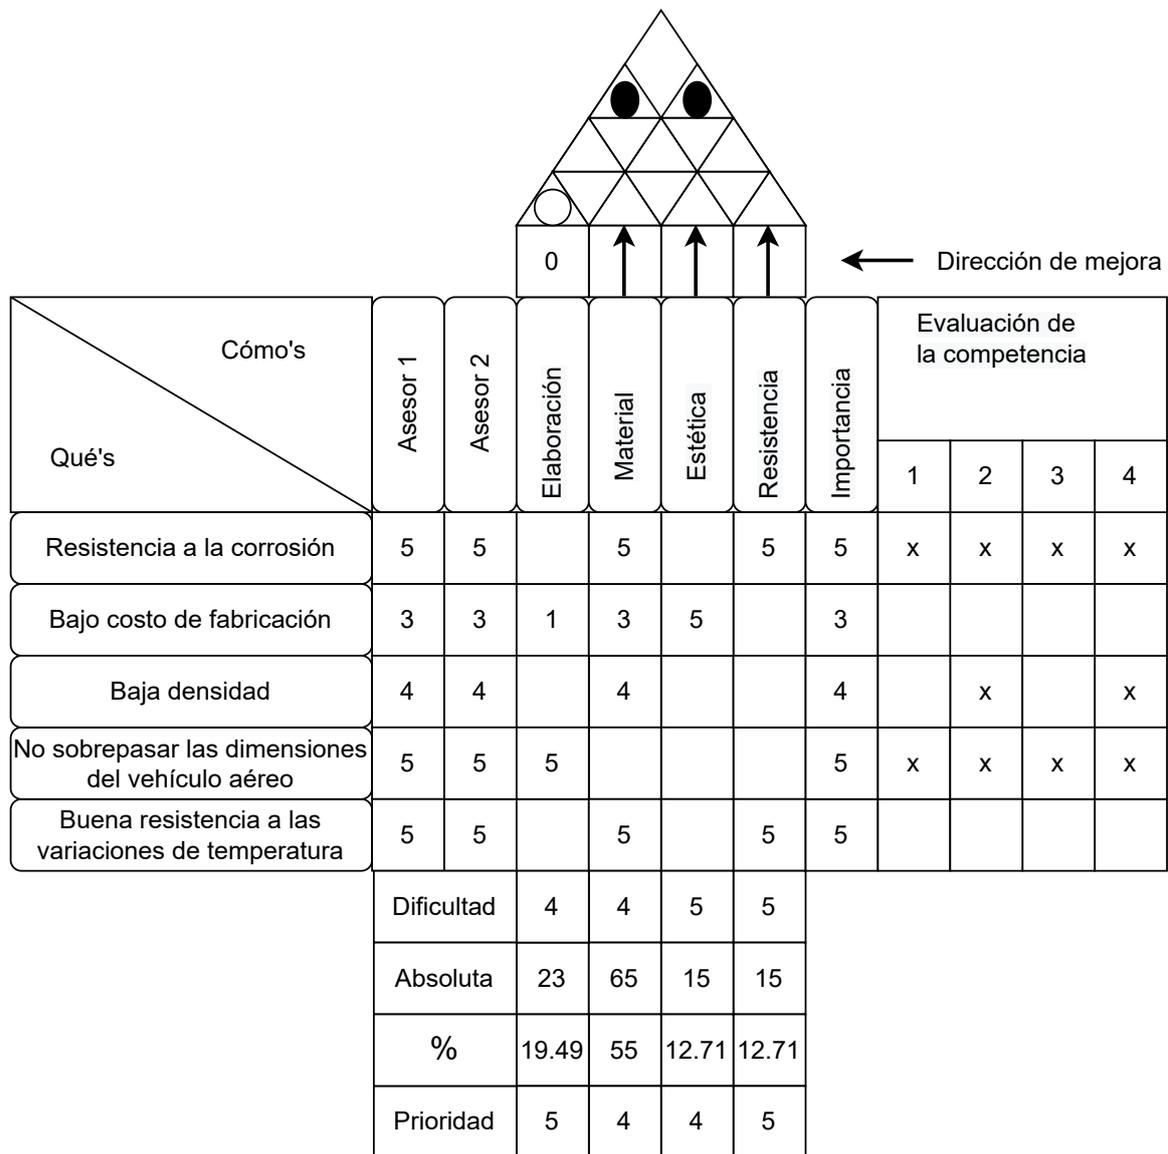


Figura 3.4: Casa de la calidad QFD.

En la Figura 3.5, se muestran grupos de burbujas esquematizadas de acuerdo con las familias de materiales. Además, las líneas punteadas en la esquina inferior derecha de la gráfica indica las relaciones de  $\frac{E^\beta}{\rho}$ , que ayuda a seleccionar materiales para el diseño de masa mínima. Las líneas paralelas a estas rectas representan valores diferentes de  $\frac{E^\beta}{\rho}$ . Por ejemplo, en la Figura 3.5 se muestran algunas líneas punteadas paralelas que representan diferentes valores de  $\frac{E}{\rho} (\beta = 1)$ . Como  $\left(\frac{E}{\rho}\right)^{\frac{1}{2}}$  representa la velocidad del sonido en un material, cada línea punteada,  $\frac{E}{\rho}$ , representa una velocidad diferente tal como se indica. Para la selección de material, Michael Farris Ashby, como se indica en [115] y [116], desarrolló un método que se basa en el empleo de gráficas de selección. Las gráficas representan datos de diferentes propiedades para las familias (metales, cerámicos, cristales, polímeros, elastómeros, híbri-

dos) y clase de materiales. La medida de desempeño ( $P$ ) de un elemento estructural depende de:

1. Los requerimientos funcionales,
2. La geometría
3. Las propiedades de los materiales de la estructura.

$$P = f_1(F), f_2(G), f_3(M) \tag{3.1}$$

Para lograr un diseño óptimo, se debe maximizar o minimizar  $P$ . En relación sólo con las

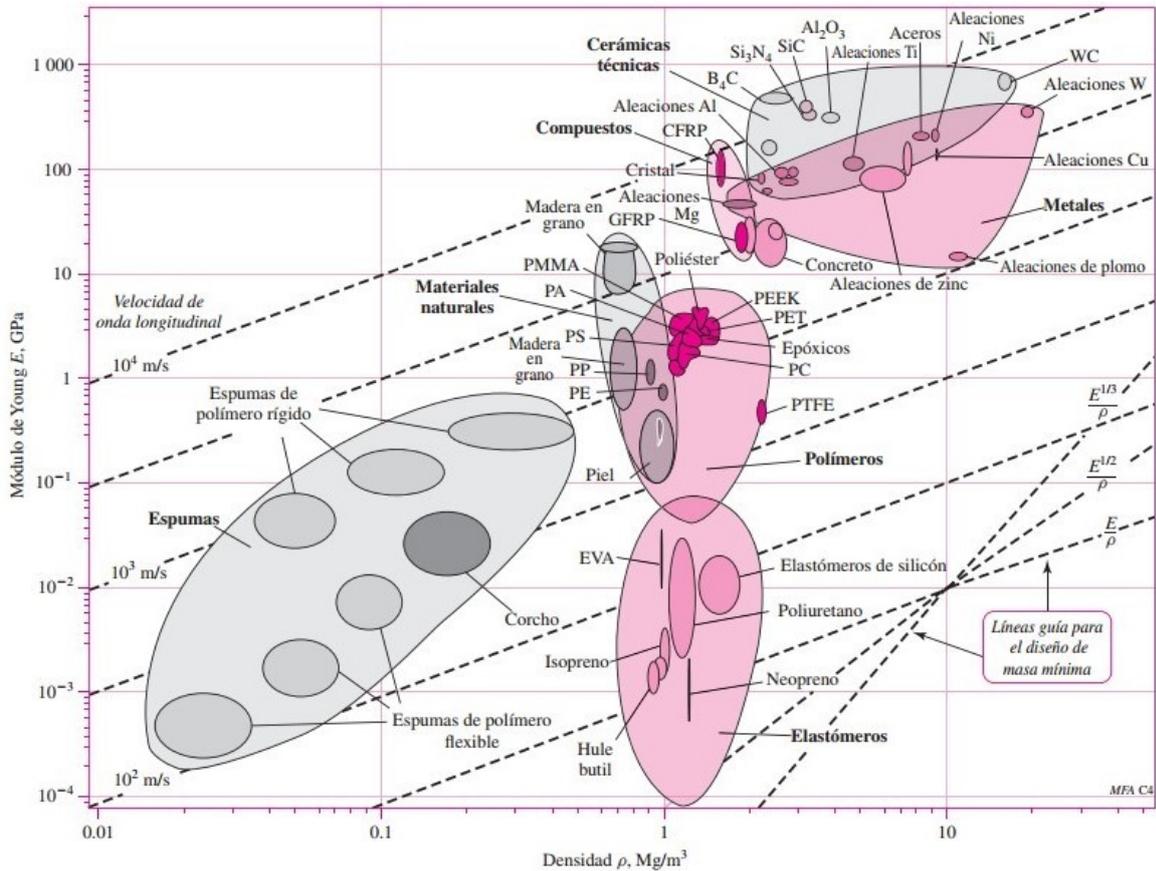


Figura 3.5: Modulo de Young vs densidad de diferentes materiales.

propiedades del material, esto se hace al maximizar o minimizar  $f_3(M)$ , llamado coeficiente de eficiencia del material. La base del sistema de generación se considera como una viga con apoyos simples con carga uniforme, entonces la deflexión queda como:

$$\delta = \frac{Fl^3}{7.8EI} \tag{3.2}$$

La rigidez de la viga está dada:

$$k = \frac{F}{\delta} \quad (3.3)$$

donde

- $F$  = Carga.
- $l$  = Longitud de la viga.
- $E$  = Modulo de Young o de elasticidad.
- $II$  = Segundo momento de la área.

El segundo momento de área de una sección transversal es

$$II = \frac{\pi d^4}{64} = \frac{A^2}{4\pi} \quad (3.4)$$

donde  $D$  es el diámetro y  $A$  es el área de la sección transversal. Se sustituye la ecuación (3.4) en la ecuación (3.2), para que después la ecuación resultante se sustituya en (3.3). Se despeja  $A$ , obteniendo:

$$A = \left( \frac{4\pi l^3}{76.8E} \right)^{\frac{1}{2}} \quad (3.5)$$

La masa de la viga está dada por:

$$mV = Al\rho \quad (3.6)$$

donde  $\rho$  es la densidad. Se sustituye la ecuación (3.5) en la ecuación (3.6), quedando

$$mV = \left( \frac{4\pi l^3}{76.8E} \right)^{\frac{1}{2}} l\rho = (0.163)^{\frac{1}{2}} \left( l^{\frac{5}{2}} \right) \left( \frac{\rho}{E^{\frac{1}{2}}} \right) \quad (3.7)$$

La ecuación (3.7) es de la forma de la ecuación (3.1), por lo cual el coeficiente de eficiencia de material es:

$$f_3(M) = \frac{\rho}{E^{\frac{1}{2}}} \quad (3.8)$$

Es la propiedad del material en términos de la densidad y el módulo de Young. Para minimizar  $m$  se desea minimizar  $f_3M$ , o maximizar:

$$M = \frac{E^{\frac{1}{2}}}{\rho} \quad (3.9)$$

donde  $M$  es el índice de material. Ya teniendo el valor  $M$ , se dibujan varias líneas de guía con valores de  $M$ , ver Figura 3.6, las rectas de incremento  $M$  se mueven hacia arriba y a la izquierda, como se muestra. Se considera con mayor índice de material  $\frac{E^{1/2}}{\rho}$  que 1, observando así los materiales candidatos tales como maderas, compuestos, metales. Pero se le agrega la condición que se necesita un material con módulo de elasticidad mayor de 50 GPa. Esta restricción se agrega porque mientras mayor sea el esfuerzo requerido para producir una deformación dada, más rígido se considera que es el material. Dando así la región de búsqueda para seleccionar el tipo de material, teniendo como opciones ciertos metales, compuestos y cerámicos. Se descarta los materiales cerámicos por tener poca dureza, seleccionando dentro de los materiales compuestos, la fibra de carbono y del grupo de los metales, el aluminio, véase Figura 3.7.

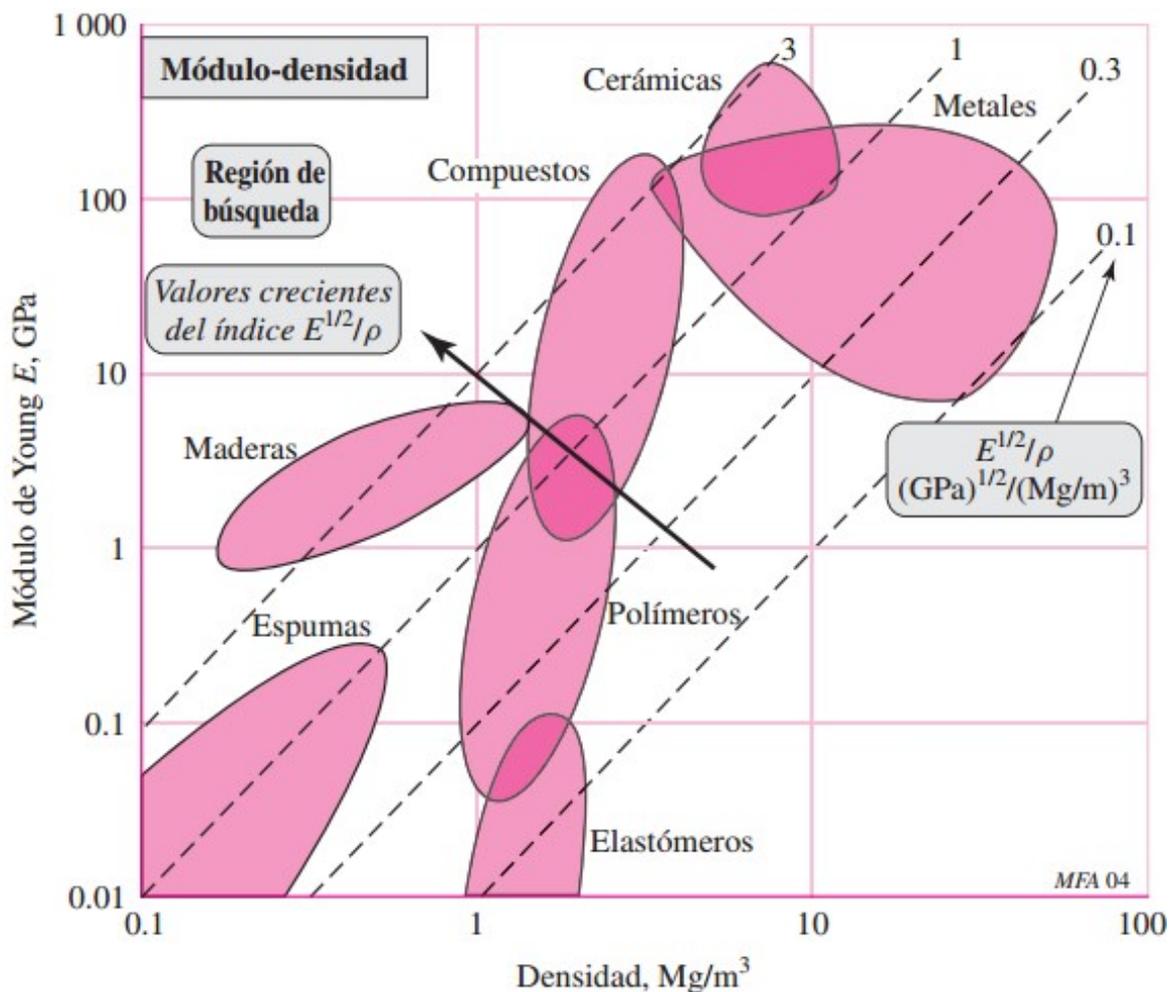


Figura 3.6: Gráfica Esquemática  $E$  contra  $\rho$ .

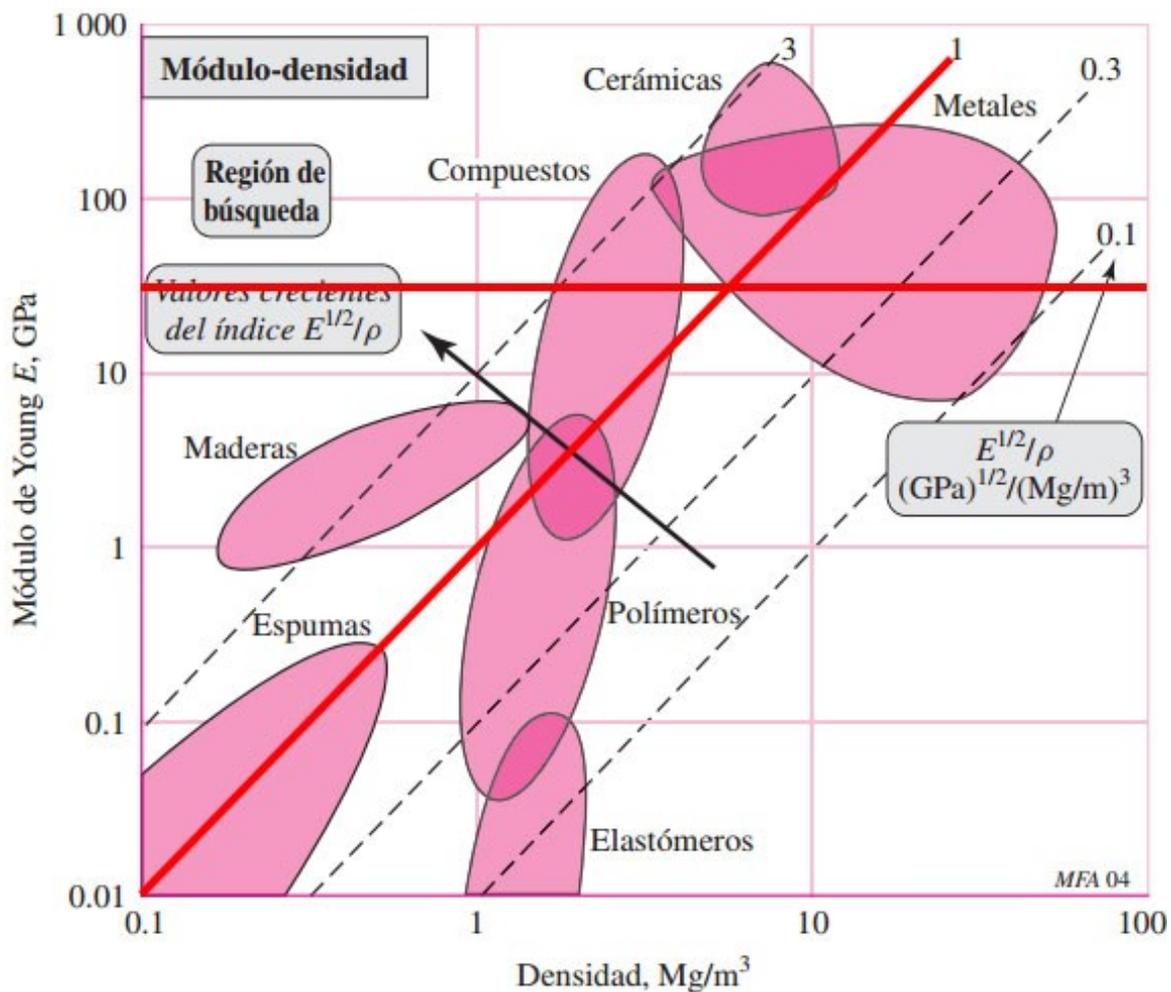


Figura 3.7: Región de búsqueda.

### 3.1.5. Generando alternativas

Se realiza un método gráfico, cuyo objetivo es generar la gama completa de soluciones de diseño alternativas para un producto, y por lo tanto ampliar la búsqueda de posibles nuevas soluciones. El procedimiento es el siguiente:

- En listar las características o funciones.
- Por cada función se colocará una solución.
- Se realiza la matriz morfológica, la cual tendrá las posibles soluciones de las subfunciones (columna de componentes).
- Se identificará las características o funciones.
- Por cada función se colocará una solución.

- Se identificará las factibles combinaciones de las soluciones factibles combinaciones de las soluciones.

En la Tabla 3.2 de muestra la carta morfológica de acuerdo a cada una de las características, mientras en la Tabla 3.3 se muestra las combinaciones posibles del proyecto, en un total de 18 opciones.

Tabla 3.2: Carta morfológica

<b>Características</b>	<b>1</b>	<b>2</b>	<b>3</b>
Tipo de motor	Gasolina	Diésel	
Material de base	Fibra de carbono	Aluminio	
Generador	Corriente directa	Corriente alterna	Motor eléctrico
Computadora	NI myRio	Odroid	Raspberry

Tabla 3.3: Total de combinaciones posibles de los componentes del sistema de generación

<b>Criterios</b>	<b>Tipo de motor</b>	<b>Material de base</b>	<b>Generador</b>	<b>Computadora</b>
Opción 1	Gasolina	Aluminio	Corriente alterna	NI myRio
Opción 2	Gasolina	Aluminio	Corriente directa	NI myRio
Opción 3	Gasolina	Aluminio	Motor eléctrico	NI myRio
Opción 4	Gasolina	Aluminio	Corriente alterna	Odroid
Opción 5	Gasolina	Aluminio	Corriente directa	Odroid
Opción 6	Gasolina	Aluminio	Motor eléctrico	Odroid
Opción 7	Gasolina	Aluminio	Corriente alterna	Raspberry
Opción 8	Gasolina	Aluminio	Corriente directa	Raspberry
Opción 9	Gasolina	Aluminio	Motor eléctrico	Raspberry
Opción 10	Diésel	Aluminio	Corriente alterna	NI myRio
Opción 11	Diésel	Aluminio	Corriente directa	NI myRio
Opción 12	Diésel	Aluminio	Motor eléctrico	NI myRio
Opción 13	Diésel	Aluminio	Corriente alterna	Odroid
Opción 14	Diésel	Aluminio	Corriente directa	Odroid
Opción 15	Diésel	Aluminio	Motor eléctrico	Odroid
Opción 16	Diésel	Aluminio	Corriente alterna	Raspberry
Opción 17	Diésel	Aluminio	Corriente directa	Raspberry
Opción 18	Diésel	Aluminio	Motor eléctrico	Raspberry

### 3.1.6. Evaluando alternativas

El objetivo es evaluar las alternativas de los diseños propuestos. El procedimiento es el siguiente:

- Listar los objetivos.
- Ponderar los objetivos.
- Asignar el factor de peso (la suma total debe ser de 1.0)
- Establecer los parámetros o calificaciones para los objetivos.

La Opción número 3 (subrayada) de la Tabla 3.4, se elige como la mejor opción de acuerdo a la metodología de Nigel Cross, por lo cual se utilizara esa opción para la elaboración del sistema de generación de energía. A partir del análisis del estado del arte y de la metodología utilizada se selecciona una configuración en serie, ver Figura 1.4, para sí evitar un mayor peso y mejor rendimiento para el sistema.

Tabla 3.4: Evaluación de alternativas del sistema de generación de energía

Criterios	Reparación	Costo	Tamaño y peso	Consumo	Resistencia a la fatiga	Absorción de impactos	Conexión con ventilador incluido	Ponderación
Opción 1	8	7	9.5	8	10	9.5	10	8.85
Opción 2	8	7	9.5	8	10	9.5	10	8.85
<b>Opción 3</b>	<b>8</b>	<b>8</b>	<b>9.5</b>	<b>8</b>	<b>10</b>	<b>9.5</b>	<b>10</b>	<b>9</b>
Opción 4	8	8	9.5	7	10	9.5	5	8.14
Opción 5	8	8	9.5	7	10	9.5	5	8.14
Opción 6	8	8	9.5	7	10	9.5	5	8.14
Opción 7	8	7.8	9.5	7.5	10	9.5	5	8.18
Opción 8	8	7.8	9.5	7.5	10	9.5	5	8.18
Opción 9	8	7.8	9.5	7.5	10	9.5	5	8.18
Opción 10	9	7	8	8	10	9.5	10	8.78
Opción 11	9	7	8	8	10	9.5	10	8.78
Opción 12	9	7	8	8	10	9.5	10	8.78
Opción 13	9	8.2	8	7	10	9.5	5	8.1
Opción 14	9	8.2	8	7	10	9.5	5	8.1
Opción 15	9	8.2	8	7	10	9.5	5	8.1
Opción 16	9	8.5	8	7.5	10	9.5	5	8.21
Opción 17	9	8.5	8	7.5	10	9.5	5	8.21
Opción 18	9	8.5	8	7.5	10	9.5	5	8.21

## 3.2. Instrumentación del SGE

En esta sección se explica los pasos a seguir para la instrumentación del prototipo, así como la programación de algunos componentes utilizados que fueron seleccionados a partir de la metodología utilizada, como se muestra en la sección 3.1.

### 3.2.1. Diseño del SGE

En la Figura 3.8, se observa la vista isométrica del diseño en CAD (por sus siglas en inglés Computer-Aided Design) del sistema de generación, así como algunos componentes del sistema, como motor/generador, motor de combustión y puente rectificador de diodos. Por otro lado en la Figura 3.9 y en la Figura 3.10, se presenta la vista superior y lateral del SGE, donde se indican las medidas en milímetros del diseño. Mientras en la Figura 3.11, se observa la plataforma experimental realizada, donde se observa los componentes utilizados en el SGE, el MCI acoplado en serie al motor/generador, el puente rectificador de diodos, el sensor de voltaje, la myRio, así como el motor de carga.

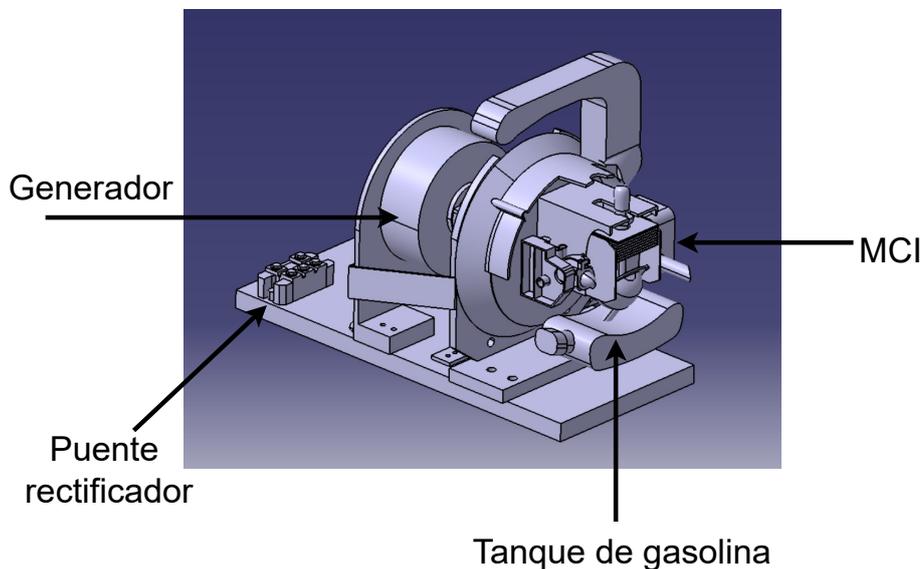


Figura 3.8: Vista isométrica del diseño en CAD del sistema físico.

### 3.2.2. Conexión de los Componentes

El SGE de la Figura 3.12, muestra el diagrama de bloques del sistema, este se compone de una tarjeta myRIO-1900 de National Instruments utilizada para la adquisición y proce-

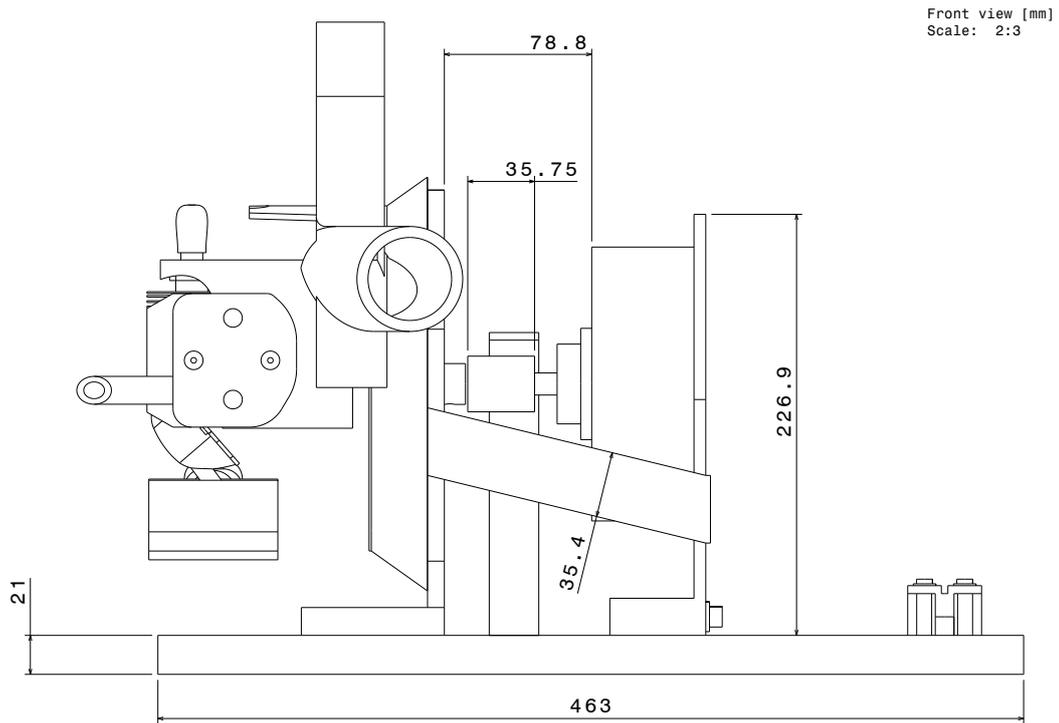


Figura 3.9: Vista lateral del diseño del sistema de generación.

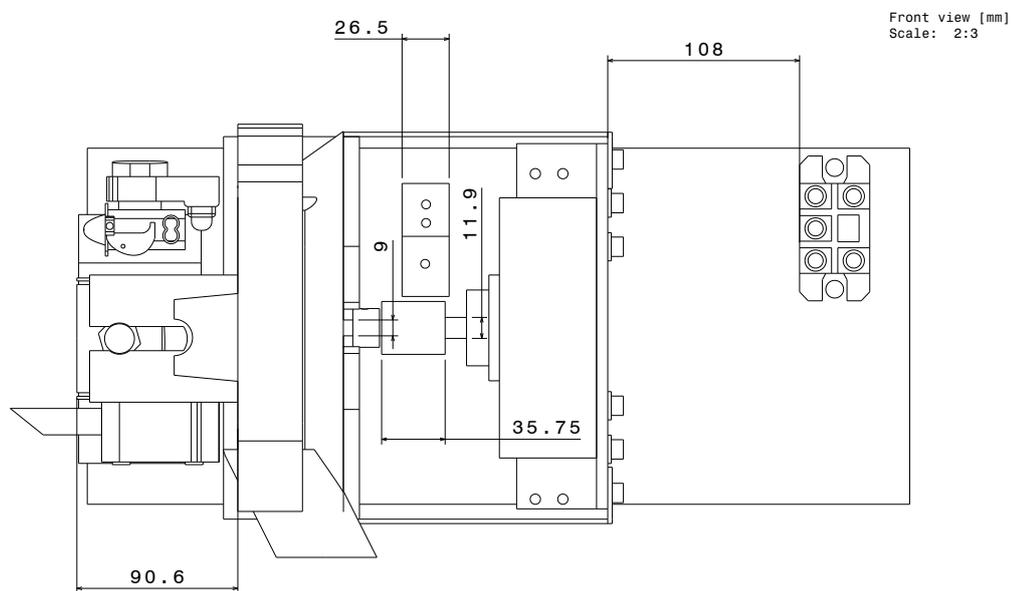


Figura 3.10: Vista superior del diseño del sistema de generación.

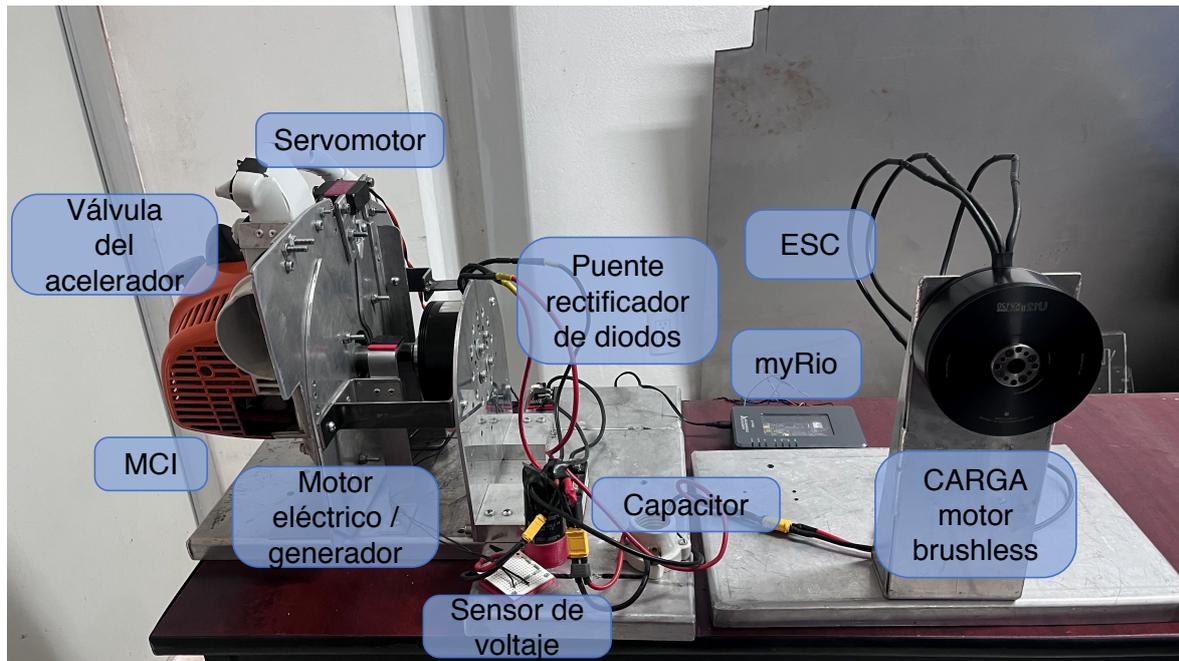


Figura 3.11: Plataforma experimental.

samiento 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.

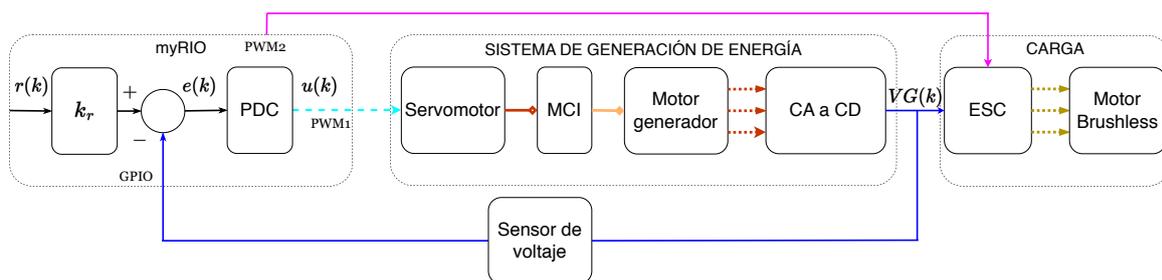


Figura 3.12: Diagrama de bloques del SGE.

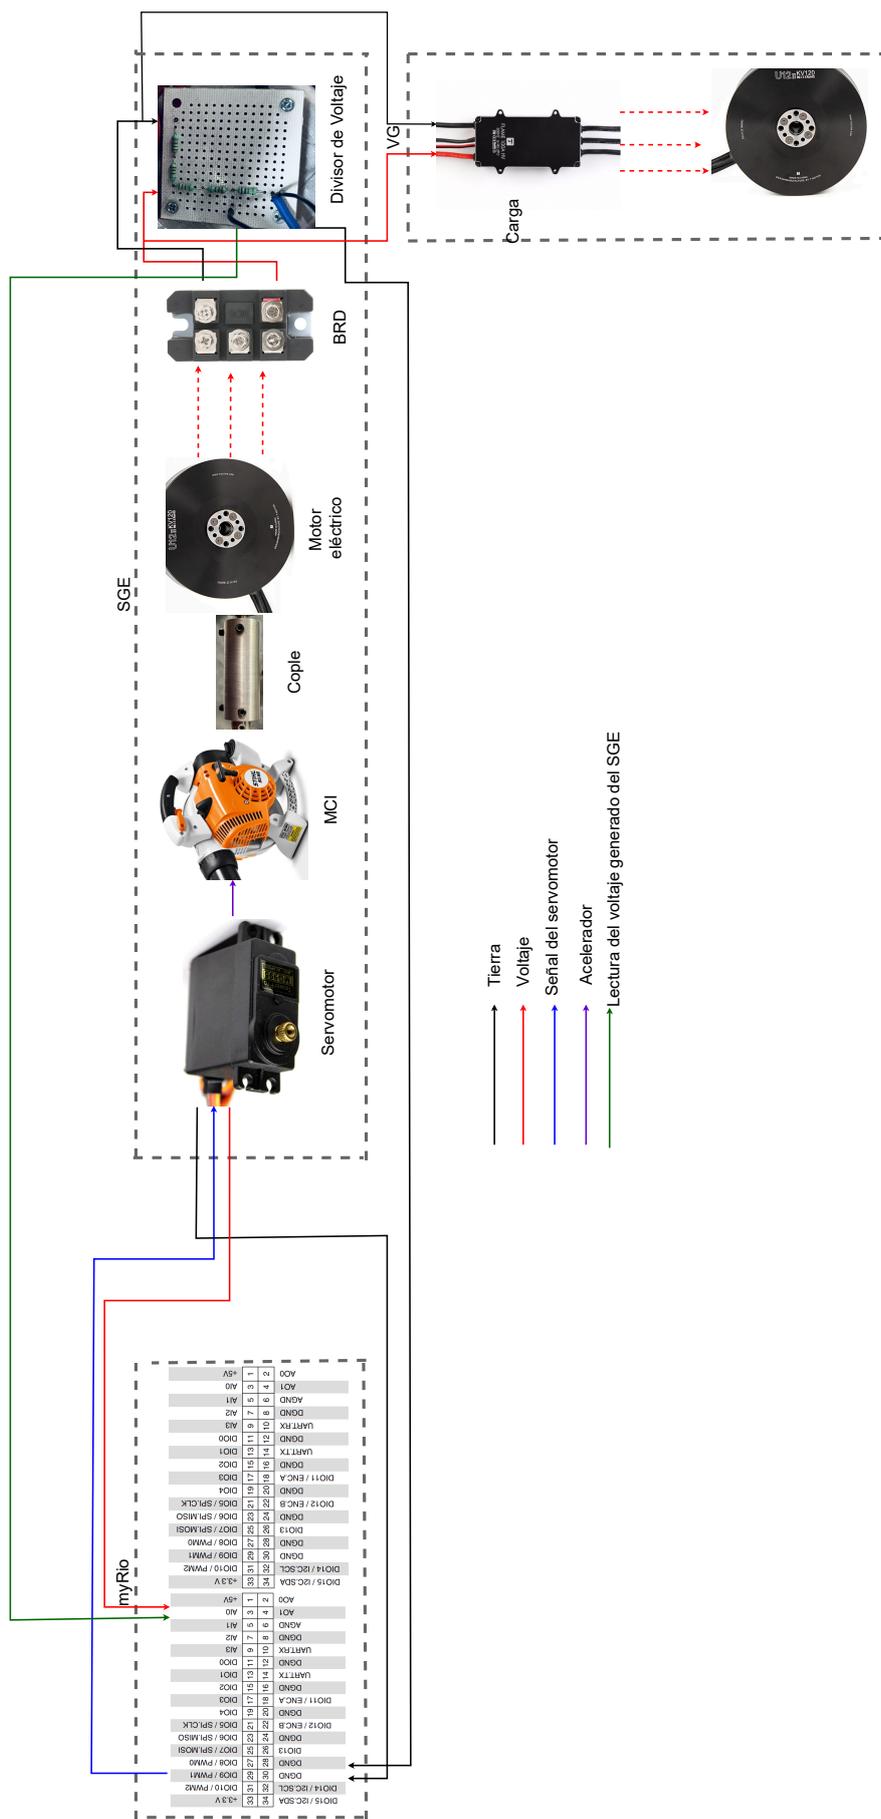


Figura 3.13: Diagrama de conexiones del sistema de generación de energía.

### Motor de combustión interna

El motor de gasolina utilizado es de una sopladora de la marca Stihl cuyo modelo es el modelo Stihl-2MIX g86, el cual es un motor monocilíndrico de 1.1 HP / 0.8 kW y 22.2 cm<sup>3</sup>, cuyo funcionamiento es de 2 tiempos, ver Figura 3.14. El cual cuenta con un bomba de gasolina para un arranque sencillo, bajo nivel de vibraciones, bajo consumo de combustible y emisiones de gases escasas, como indica [117]. Los detalles técnicos se muestran en la Tabla 3.5.



Figura 3.14: Motor de combustión interna utilizado.

Tabla 3.5: Detalles Técnicos del MCI.

Motor	Stihl 2-MIX
Potencia	1.1 HP/0.8 kW
Cilindrada	27.2 cm <sup>3</sup>
Peso	4.4 Kg
Capacidad del deposito de combustible	0.44 ml

### Motor Eléctrico/Generador

El motor sin escobillas (brushless en inglés) fue utilizado para desempeñar como generador es el U12KV120 de T-Motor, ver Figura 3.15, el cual ofrece 5500 g de empuje. Sus otras características es que con ese valor de empuje el torque es de 1.9 Nm, con una corriente de 14.5 A, con 2548 RPMs y con una eficiencia de de 7.9 g/W. Es capaz de operar en condiciones climáticas extremas, como lo indica [118]. Otras especificaciones del motor se muestran en la Tabla 3.6.



Figura 3.15: Motor U12KV120.

Tabla 3.6: Especificaciones del U12KV120

Constante de revoluciones	KV120
Dimensiones del motor	106.8×47.6 mm
Cable	Cable estañado de 90 mm
Diámetro de flecha	15 mm
Corriente de vacío	1.5 A
Máxima potencia	4560 W
Peso	778 g
Resistencia interna	22 m $\omega$
Configuración	36N42P
Voltaje (LiPo)	10-14S
Corriente pico	95 A

## NI myRIO

El myRIO-1900 de National Instruments es un dispositivo de entradas/salidas reconfigurable portátil que puede usar para diseñar sistemas de control, como se muestra en la Figura 3.16. Incluye entradas analógicas, salidas analógicas, líneas de E/S digitales, LEDs un push-button, un acelerómetro interno, un FPGA Xilinx y un procesador dual-core ARM Cortex-A9, [119].



Figura 3.16: Dispositivo Embebido NI myRio.

## Puente de diodos (BRD)

El rectificador de diodos es un circuito que se usa cuando se necesita convertir la corriente alterna (CA) en corriente directa (DC), como se observa en la Figura 3.17. El rectificador utilizado cuenta con las siguientes características:

Tabla 3.7: Especificaciones del puente de diodos usado.

Material	Plástico, Metal
Corriente rectificada máxima	100 A
Voltaje máximo	1600 V
Fase	Trifásica
Tamaño	8 × 4 × 3cm/ 3.1 × 1.6 × 1.2in



Figura 3.17: Puente de diodos trifásico.

### Divisor de voltaje

La caída de voltaje en cualquier resistencia en serie es proporcional a la magnitud de la resistencia. La caída de voltaje total en todas las resistencias debe ser igual al voltaje aplicado por la fuente de acuerdo con la Ley de Voltaje de Kirchhoff, [120]. Se considere el circuito de la Figura 3.18.

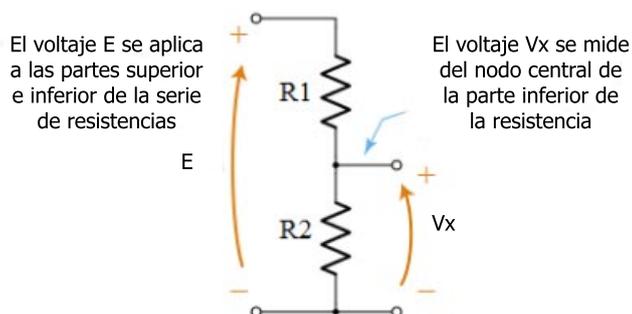


Figura 3.18: Ejemplo de divisor de voltaje.

La elevación de voltaje de la fuente  $E_V$  se obtiene de la siguiente manera

$$E_V = V_1 + V_2 + \dots + V_n \quad (3.10)$$

La regla del divisor de voltaje permite determinar el voltaje en cualquier resistencia en serie en un solo paso, sin calcular primero la corriente. Se ha visto que para cualquier número de resistencias en serie la corriente en el circuito se determina mediante la ley de Ohm como

$I = \frac{E_V}{R}$  donde la suma de las resistencias dan una resistencia total ( $R_T$ ). Al aplicar de nuevo la ley de Ohm, la caída de voltaje en cualquier resistencia en el circuito en serie se calcula como

$$V_x = IR_x \quad (3.11)$$

Al sustituir  $R_T$  en la ecuación anterior se obtiene la regla del divisor de voltaje para n resistencias como una sola ecuación

$$V_x = \frac{R_x}{R_T} E_V \quad (3.12)$$

Para el divisor de voltaje aplicado en el sistema, se debe de considerar que  $v_{sal}$  máximo debe de ser de cinco volts, de acuerdo a la tarjeta myRio, [119] y el voltaje máximo generado por el SGE es de 70 volts. Por lo tanto, el valor de las resistencias conectadas en serie son de cuatro resistencias de  $33 K\Omega$  y una de  $10 K\Omega$ .

---

# Modelado Difuso Takagi-Sugeno (T-S)

---

En este capítulo se explica sobre el procedimiento del algoritmo del modelado T-S con las premisas en forma de clustering y así como sus consecuentes lineales. Con esta técnica se realiza 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 (ya que en el estado de arte investigado no existe un modelo matemático como tal que incluya un MCI acoplado con un motor/generador, tomando encuentra datos de entrada y de salida para la identificación del modelo del sistema). Con dicha estrategia, se busca evitar la necesidad de derivar un modelo matemático complejo, es decir no se están considerando las demás propiedades del MCI, como las propiedades termodinámicas.

## 4.1. Introducción

Muchos autores modelan los sistemas de vehículos que utilizan MCI considerando las propiedades termodinámicas, como [121] y [122], o considerando el retardo de la chispa como se menciona en [123].

Se ha llegado a considerar el modelo matemático del MCI para el control de la velocidad u otra variable. En [124] mencionó que Powell, Dobner, Powers, Coats y Fruechte desarrollaron algunos de los modelos de motores para estudios del control de la velocidad de ralentí, basados en parte en modelos anteriores simples aunque fundamentales de Hazell y Flower. El desarrollo del modelo comienza con una descripción no lineal de la dinámica del par de combustión del motor. Dicho modelo se basa en una combinación de primer principio, leyes

físicas y datos de estado estacionario obtenidos empíricamente para el flujo de aire en masa del motor.

Como se muestra en [125–127], durante el ralentí, el motor debe generar un par que compense las pérdidas del ciclo de combustión y la fricción del motor. Por lo tanto, el par requerido depende en gran medida de las cargas variables y del estado del motor en las fases posteriores al arranque, durante el calentamiento y el funcionamiento normal, y especialmente las temperaturas del motor tienen un efecto significativo. Debido a las muchas perturbaciones, la velocidad de ralentí debe controlarse mediante retroalimentación, el valor de referencia para el controlador de velocidad de ralentí generalmente depende de la temperatura ambiental y del motor, y de las cargas auxiliares.

Una adecuada estrategia de control para este tipo de sistemas con variaciones paramétricas y con perturbaciones no lineales en la carga, son los controladores difusos debido a su naturaleza de compensar estas variaciones. Para poder usar este tipo de controladores, es necesario la construcción del sistema difuso, para esto principalmente hay dos métodos basados en reglas difusas: los sistemas Mamdani y T-S. En el modelo difuso lingüístico (Mamdani), el antecedente como el consecuente son proposiciones difusas, es decir, son sistemas basados en el conocimiento. Mientras que el modelo difuso T-S, el antecedente es una proposición difusa y el consecuente es una función matemática, que puede tener la arquitectura en espacio de estado, como se indica en [128].

## 4.2. Modelado

Los sistemas difusos consisten en tres partes importantes: variables lingüísticas, funciones de membresía y reglas, [129]. Las variables lingüísticas representan, en palabras, las variables de entrada y las variables de salida del sistema que desea controlar. Un controlador difuso requiere al menos una variable lingüística de entrada y una variable lingüística de salida. Los términos lingüísticos representan, categorías para los valores de una variable lingüística. Las funciones de membresía o grados de pertenencia son funciones numéricas correspondientes a términos lingüísticos. Una función de pertenencia representa el grado de pertenencia de variables lingüísticas dentro de sus términos lingüísticos. Se manejan en intervalos entre 0 y 1.

---

Uno de los algoritmos de agrupación más simples es el algoritmo de clustering de vecindad más cercano. En este algoritmo, se coloca el primer dato como el centro del primer grupo. Luego, si las distancias de un dato a los centros del grupo son menores que un valor preespecificado, se coloca este dato en el grupo cuyo centro es el más cercano a este dato; de lo contrario, se establece este dato como un nuevo centro del cluster. A continuación se explica el método clustering que se piensa utilizar para la construcción del sistema, tal como se indica en [129–131]. Hay dos métodos para realizar la agrupación difusa donde se usan conjuntos difusos para definir límites suaves para separar los datos en grupos. Son los métodos de c-means junto con mínimos cuadrados para entrenar los sistemas difusos T-S, y el método de vecindad más cercano para entrenar sistemas difusos estándar.

En el enfoque fuzzy c-means, se utiliza la optimización para elegir los clusters y, por lo tanto, los parámetros de la función de membresía de la premisa. Los parámetros consiguientes se eligen utilizando el enfoque de mínimos cuadrados por consecuentes.

Fuzzy c-means es un algoritmo iterativo utilizado para encontrar grados de membresía  $\mu_{ik}$  (escalares) y centros de agrupamiento ( $c_i$ ). La función objetivo que permite describir los centros de cluster esta dada por la ecuación (4.1).

$$J(U, c) = \sum_{k=1}^N \sum_{i=1}^c (\mu_{ik})^m \|z_k - c_i\|_I^2 \quad (4.1)$$

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 (numero de reglas),  $Z = \{z_1, z_2, \dots, z_N\}$  es la matriz de aprendizaje con mediciones experimentales entrada-salida, que se desean clasificar con  $U = [\mu_{ik}]$ ,  $\mu_{ik} \in [0, 1]$  y  $c = [c_1, c_2, \dots, c_c]$  es el vector de centros a determinar. Se calculan la distancias Euclidianas de cada muestra de las mediciones, respecto de los centroides, como se indica en la ecuación (4.2):

$$D_{ikI}^2 = \|z_k - c_i\|_I^2 = (z_k - c_i)^T I (z_k - c_i). \quad (4.2)$$

donde  $I$  es la matriz identidad. La solución de la función objetivo (4.1) para las funciones de

pertenencia de cada cluster esta dada por (4.3) y (4.4) de forma iterativa

$$\mu_i(k) = \frac{1}{\sum_{j=1}^c \left(\frac{D_{ikI}}{D_{jkI}}\right)^{(2/m-1)}} \quad (4.3)$$

$$c_i = \frac{\sum_{k=1}^N (\mu_{ik})^m z_k}{\sum_{k=1}^N (\mu_{ik})^m} \quad (4.4)$$

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

La construcción de un modelo difuso T-S a partir de datos experimentales se resuelve en dos pasos, como indica en [131, 132]:

- Identificación de la estructura
- Estimación de parámetros

En el paso de identificación de la estructura, se determinan las variables antecedente y consecuente del modelo. A partir de secuencias en el tiempo de los datos disponibles, se construye una matriz  $X \in \mathbb{R}^{N \times n}$  dada como:

$$X = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1n} \\ x_{21} & x_{22} & \cdots & x_{2n} \\ \vdots & \vdots & \cdots & \vdots \\ x_{N1} & x_{N2} & \cdots & x_{Nn} \end{bmatrix} \quad (4.5)$$

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

$$Y = [y_1, \dots, y_N]^T \quad (4.6)$$

el cual se desea aproximar con la ecuación lineal:

$$\hat{y} = \theta X \quad (4.7)$$

donde  $N$  es el número de muestras,  $n$  es el número de vectores o estados, se conforma la matriz  $z$  de datos, ecuación (4.8), para hacer el aprendizaje con los elementos de la matriz  $X$

---

y  $\theta$  son los parámetros consecuentes lineales a identificar.

$$z = [X; Y] \quad (4.8)$$

Los parámetros consecuentes de cada regla se obtienen como una estimación de mínimos cuadrados, con la aproximación de (4.7), definiendo  $\Gamma_i \in \mathbb{R}^{N \times N}$  una matriz que contiene en su diagonal principal los valores de disparo normalizados de la  $i$ -ésima regla difusa, y que da una ponderación a la solución del algoritmo de mínimos cuadrados (4.9), se realiza la identificación de los parámetros consecuentes lineales  $\theta_i$  para cada  $i$ -ésima regla usando:

$$\theta = [X^T \Gamma_i X]^{-1} X^T \Gamma_i Y \quad (4.9)$$

Esta es una solución óptima que proporciona el mínimo error de predicción de  $Y$ , con la búsqueda del vector de parámetros  $\theta$ .

### 4.2.1. Modelo Lingüístico Difuso

De acuerdo con [133] y [31], se considera un sistema difuso T-S con  $R_i$  reglas, en cada  $i$ -ésima regla la premisa es un centro de cluster  $c_i$ , en tiempo discreto en espacio de estado representado por la ecuación (4.10). Las reglas describen las relaciones entre las variables lingüísticas de entrada y salida en función de sus términos lingüísticos.

$$R_i : \text{Si } z_k \text{ is } c_i \text{ Entonces } \begin{cases} x^i(k+1) = A_i x(k) + B_i U(k) \\ y(k) = C_i x(k) \end{cases} \quad (4.10)$$

donde  $x(k+1)$  es el vector de estados en el instante  $(k+1)$ ,  $A_i \in \mathbb{R}^{n \times n}$  es la matriz de ganancias 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 el vector de ganancias de los actuadores,  $C_i \in \mathbb{R}^{q \times n}$ ,  $u(k) \in \mathbb{R}^m$  es la excitación del sistema y  $y(k) \in \mathbb{R}^q$ . Cada ecuación consecuyente es representada por  $A_i x(k) + B_i u(k)$  es llamada subsistema.

### 4.2.2. Defuzificación

Por último, la defuzificación es el proceso de convertir los grados de pertenencia de las variables lingüísticas de salida dentro de sus términos lingüísticos en valores numéricos

nítidos, [8], [133], [132]. Hay varias formas de realizar la defuzificación: centro de gravedad (CDG) y centro promedio (CP), en este trabajo se usa el método de CP. 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, dada como:

$$x(k+1) = \sum_{i=1}^R \sum_{j=1}^R h_i(z(k)) h_j(z(k)) \{A_i x(k) + B_i u(k)\} \quad (4.11)$$

$$y(k) = \frac{\sum_{i=1}^R w_i(z(k)) \{C_i(k)\}}{\sum_{i=1}^R w_i(z(k))} \quad (4.12)$$

$$y(k) = \sum_{i=1}^R h_i(z(k)) \{C_i x(k)\} \quad (4.13)$$

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, cuyas ecuaciones son las siguientes:

$$w_i(z(k)) = \prod_{i=1}^p \mu_{ik}(z(k)) \quad (4.14)$$

$$h_i(z(k)) = \frac{w_i(z(k))}{\sum_{i=1}^R w_i(z(k))} \quad (4.15)$$

$\sum_{i=1}^R \mu_i = 1$  para toda  $k$ , que es una propiedad convexa de los algoritmos de clustering.

# PSO y Estrategia de Control

---

En este capítulo de tesis se explica el algoritmo de PSO para obtener los valores óptimos del parámetro difuso ( $m$ ), el algoritmo para el modelado difuso T-S con las premisas en forma de clustering y consecuentes lineales.

## 5.1. PSO

### 5.1.1. Antecedentes

La optimización de enjambre de partículas, en inglés Particle Swarm Optimization (PSO), es un algoritmo de búsqueda estocástica paralela propuesto por primera vez por Kennedy y Eberhart, como indica [134]. La idea principal de diseño del algoritmo PSO está estrechamente relacionada con dos investigaciones: una es el algoritmo evolutivo, al igual que el algoritmo evolutivo; PSO también utiliza un modo de enjambre que lo hace buscar simultáneamente una gran región en el espacio de solución de la función objetivo optimizada. La otra es la vida artificial, es decir, estudia los sistemas artificiales con características de vida, tal cual se menciona en [135].

El algoritmo PSO se puede resumir de la siguiente manera: el algoritmo PSO es un tipo de proceso de búsqueda basado en enjambre, en el que cada individuo se denomina partícula definida como una solución potencial del problema optimizado en el espacio de búsqueda D-dimensional, y puede memorizar la posición óptima del enjambre y la propia, así como la velocidad. En cada generación, la información de las partículas se combina para ajustar la velocidad de cada dimensión, que se utiliza para calcular la nueva posición de la partícula. Las

partículas cambian de estado constantemente en el espacio de búsqueda multidimensional, hasta alcanzar el equilibrio o estado óptimo, o más allá de los límites de cálculo. La conexión única entre las diferentes dimensiones del espacio del problema se introduce a través de las funciones objetivo. Numerosas evidencias empíricas han demostrado que este algoritmo es una herramienta de optimización eficaz. El diagrama de flujo del algoritmo PSO se muestra en la Figura 5.1.

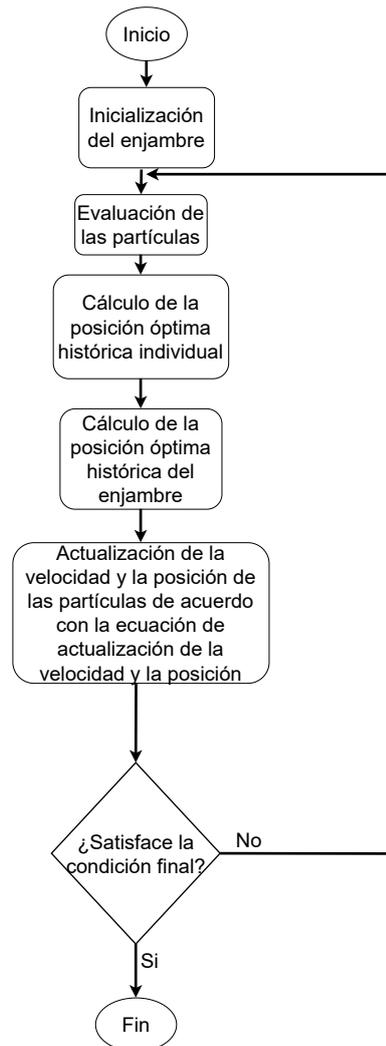


Figura 5.1: Diagrama de flujo del algoritmo de optimización de enjambre de partículas.

Como indica [136], el algoritmo mantiene una población de partículas, donde cada partícula representa una solución potencial a un problema de optimización. Sea  $s$  el tamaño del enjambre. Cada partícula  $i$  se puede representar como un objeto con varias características. A estas características se les asignan los siguientes símbolos:

- $x_i$  = La posición actual de la partícula.

- $V_i$ = La velocidad actual de la partícula.
- $y_i$ = La mejor posición personal de la partícula.

La mejor posición personal asociada con la partícula  $i$  es la mejor posición que ha visitado la partícula (un valor anterior de  $x_i$ ), lo que arroja el valor de aptitud más alto para esa partícula. Para una tarea de minimización, se considera que una posición que produce un valor de función más pequeño tiene una aptitud más alta. El símbolo  $f$  se utilizará para indicar la función objetivo que se minimiza. La ecuación de actualización para la mejor posición personal se presenta en la ecuación (5.1), con la dependencia del paso de tiempo  $t$  hecha explícita.

$$y_i(t+1) = \begin{cases} y_i(t) & \text{if } f(x_i(t+1)) \geq f(y_i(t)) \\ x_i(t+1) & \text{if } f(x_i(t+1)) < f(y_i(t)) \end{cases} \quad (5.1)$$

Existen dos versiones del PSO, llamadas modelos gbest y lbest [137]. La diferencia entre los dos algoritmos se basa en el conjunto de partículas con las que una determinada partícula interactuará directamente, donde se utilizará el símbolo  $\hat{y}$  para representar esta interacción. La definición de  $\hat{y}$ , tal como se utiliza en el modelo gbest, se presenta en la ecuación (5.2).

$$\begin{aligned} \hat{y}(t) &\in \{y_0(t), y_1(t), \dots, y_s(t)\} \mid f(\hat{y}(t)) \\ &= \min \{f(y_0(t)), f(y_1(t)), \dots, f(y_s(t))\} \end{aligned} \quad (5.2)$$

El algoritmo utiliza dos secuencias aleatorias independientes,  $r_1 \sim U(0, 1)$  y  $r_2 \sim U(0, 1)$ . Estas secuencias se utilizan para efectuar la naturaleza estocástica del algoritmo, como se muestra a continuación en la ecuación (5.3). Los valores de  $r_1$  y  $r_2$  están escalados por constantes  $0 < c_1, c_2 \leq 2$ . Estas constantes se denominan coeficientes de aceleración e influyen el tamaño máximo del paso que una partícula puede tomar en una sola iteración. El paso de actualización de velocidad se especifica por separado para cada dimensión  $j \in 1 \dots n$ , de modo que  $v_{i,j}$  denota la  $j$ -ésima dimensión del vector de velocidad asociado con la  $i$ -ésima partícula. La ecuación de actualización de velocidad

$$V_{i,j}(t+1) = V_{i,j}(t) + c_1 r_{1,j}(t) [y_{i,j}(t) - x_{i,j}(t)] + c_2 r_{2,j}(t) [\hat{y}_j(t) - x_{i,j}(t)] \quad (5.3)$$

De la definición de la ecuación de actualización de velocidad queda claro que  $c_2$  regula

el tamaño de paso máximo en la dirección de la mejor partícula global, y  $c_1$  regula el tamaño de paso en la dirección de la mejor posición personal de esa partícula. El valor de  $v_{i,j}$  está sujeto al rango  $[-v_{max}, v_{max}]$  para reducir la probabilidad de que la partícula abandone el espacio de búsqueda. Si el espacio de búsqueda está definido por los límites  $[-x_{max}, x_{max}]$ , entonces el valor de  $v_{max}$  normalmente se establece de modo que  $v_{max} = k \times x_{max}$ , donde  $0.1 \leq k \leq 1.0$ . La posición de cada partícula se actualiza utilizando el nuevo vector de velocidad para esa partícula, de modo que

$$x_i(t+1) = x_i(t) + V_i(t+1) \quad (5.4)$$

## 5.2. Diseño del Controlador Difuso

Un enfoque para estabilizar el sistema T-S es el compensador paralelo distribuido (PDC). En el sistema difuso del controlador, el consecuente de cada regla es una ley de control diseñada para controlar el sistema lineal en el consecuente correspondiente del sistema difuso del modelo, como indica [133], [31]. En el PDC con asignación de polos, se proponen los eigenvalores de  $(A_i - B_i K_i)$ .

Ya sea el modelo del sistema es de la forma para sistemas de tiempo continuo o para sistemas de tiempo discreto, propiedades como estabilidad, tiempo de subida, tiempo de establecimiento, sobre impulso, etc., del sistema dependen de los polos del sistema, que son los valores propios de la matriz dinámica  $A$ . Si los valores propios no son los deseados, se pueden mover a las ubicaciones deseadas a través de la retroalimentación de estado completo si el sistema es controlable, es decir, si

$$C_o = \begin{bmatrix} B & AB & A^2B & \dots & A^{n-1}B \end{bmatrix} \quad (5.5)$$

es no singular. La matriz  $C$  es la matriz de controlabilidad. El polinomio característico de  $A$  es

$$|\lambda I - A| = \lambda^n + d_{n-1}\lambda^{n-1} + \dots + d_1\lambda + d_0 \quad (5.6)$$

Los eigenvalores de  $A$  son las raíces del polinomio. La ley de control de retro de estado es

$$u(k) = -Kx(k) \quad (5.7)$$

El resultado del sistema en lazo cerrado es

$$\dot{x}(k) = (A - BK)x(k) \quad (5.8)$$

Se desean los eigenvalores en lazo cerrado  $\mu_1, \mu_2, \dots, \mu_n$ . Estos son los eigenvalores deseados de  $A - BK$ . El polinomio característico de  $A - BK$  es

$$(\lambda - \mu_1)(\lambda - \mu_2) \cdots (\lambda - \mu_n) = \lambda^n + \lambda_{n-1}\lambda^{n-1} + \cdots + \delta_1\lambda + \delta_0 \quad (5.9)$$

Se define

$$W = \begin{bmatrix} d_1 & d_2 & \cdots & d_{n-1} & 1 \\ d_2 & d_3 & \cdots & 1 & 0 \\ \vdots & \vdots & \cdots & \vdots & \vdots \\ d_{n-1} & 1 & \cdots & 0 & 0 \\ 1 & 0 & \cdots & 0 & 0 \end{bmatrix} \quad (5.10)$$

Por lo que  $K$  se obtiene de la siguiente manera

$$K = [\delta_0 - d_0, \delta_1 - d_1, \dots, \delta_{n-2} - d_{n-2}, \delta_{n-1} - d_{n-1}] T^{-1} \quad (5.11)$$

con

$$T = C_o W \quad (5.12)$$

El controlador difuso PDC es no lineal, donde  $\mu_i(z(k))$  es el grado de disparo normalizado de la  $i$ -ésima regla, para el caso de premisas identificadas con algún algoritmo de clustering. Donde  $K_i$  es el vector de ganancias de la  $i$ -ésima regla.

$$u(k) = - \sum_{i=1}^R h_i(z(k)) K_i x(k) \quad (5.13)$$

En la Figura 5.2 se observa el diagrama del sistema de lazo cerrado del sistema de generación de energía. La planta es el sistema de generación, donde  $VG$  es el voltaje generado del SGE. La tarjeta myRio incluye a  $r(k)$  es la referencia del voltaje deseado,  $k_r$  es la ganancia de precompensación,  $e(k)$  es el error del sistema y  $u(k)$  es la entrada de control.

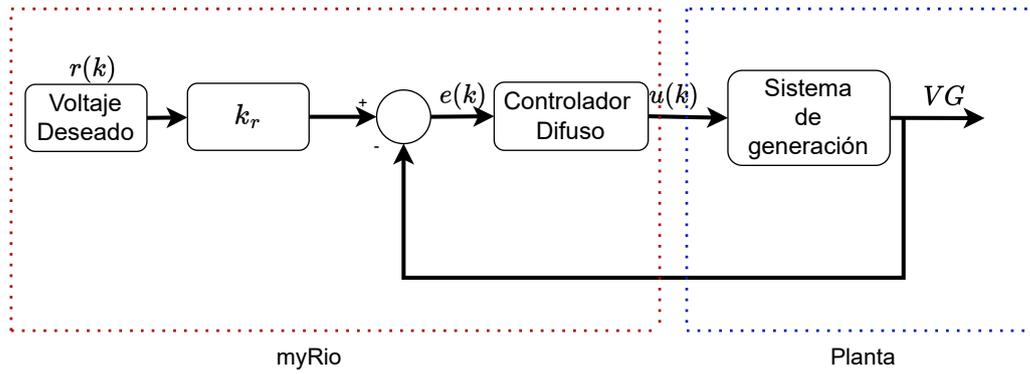


Figura 5.2: Diagrama de lazo cerrado del sistema.

### 5.2.1. Ganancia de precompensación

El sistema completo consta de la dinámica de la planta, la cual consideramos como un sistema lineal, las ganancias del controlador  $K$  y  $k_r$ , como indica en [138]. El objetivo del controlador de retroalimentación es regular la salida del sistema de manera que siga a la entrada de referencia. Considerando la ecuación (5.14) la retroalimentación, se puede escribir como

$$u(k) = - \sum_{i=1}^R h_i(z(k)) K_i x(k) + k_r r(k) \quad (5.14)$$

donde  $r(k)$  es la señal de voltaje deseado. Se tiene en cuenta que  $k_r(k)$  no afecta la estabilidad del sistema (que está determinada por los valores propios de  $(A - BK)$ ) pero sí afecta la solución de estado estacionario. En particular, el punto de equilibrio y la salida de estado estable para el sistema en lazo cerrado están dados por

$$x_e = - (A - BK)^{-1} B k_r r(k), \quad y_e = C x_e \quad (5.15)$$

por eso  $k_r$  debe ser elegida tal que  $y_e = r$ . La ganancia de precompensación es

$$k_r = - \frac{1}{C (A - BK)^{-1} B} \quad (5.16)$$

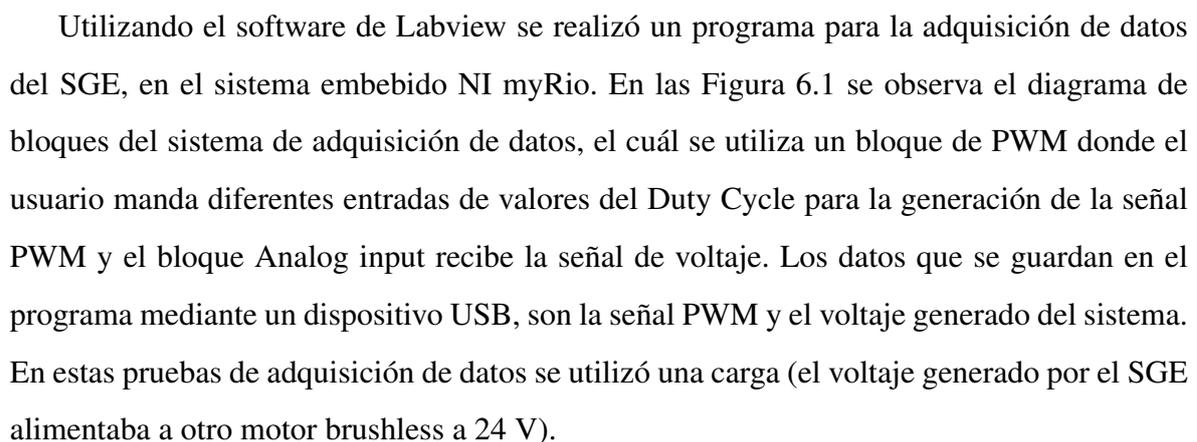
# Resultados en Simulación y Experimentales

---

Para la construcción del SGE, se considera un sistema SISO (por sus siglas en inglés, Single Input-Single Output), donde la entrada es la señal PWM del servomotor y la salida del voltaje generado. En esta etapa se trabajó con la identificación del sistema, utilizando la identificación del modelado difuso T-S. Los programas utilizados fueron Labview y Matlab.

## 6.1. Adquisición de Datos

Utilizando el software de Labview se realizó un programa para la adquisición de datos del SGE, en el sistema embebido NI myRio. En la Figura 6.1 se observa el diagrama de bloques del sistema de adquisición de datos, el cual se utiliza un bloque de PWM donde el usuario manda diferentes entradas de valores del Duty Cycle para la generación de la señal PWM y el bloque Analog input recibe la señal de voltaje. Los datos que se guardan en el programa mediante un dispositivo USB, son la señal PWM y el voltaje generado del sistema. En estas pruebas de adquisición de datos se utilizó una carga (el voltaje generado por el SGE alimentaba a otro motor brushless a 24 V).

La modulación de ancho de pulso (PWM) es una técnica que permite ajustar el valor promedio del voltaje que va al dispositivo encendiendo y apagando la energía a un ritmo rápido, [139]. El voltaje promedio depende del ciclo de trabajo, o la cantidad de tiempo que la señal está encendida versus la cantidad de tiempo que la señal está apagada en un solo período de tiempo. En la Figura 6.2 expone algunos trenes de pulsos del Duty Cycle: 25 %, 



50 % y 90 %, también se muestra el ancho de pulso ( $T_{On}$ ) y el periodo del Duty Cycle.

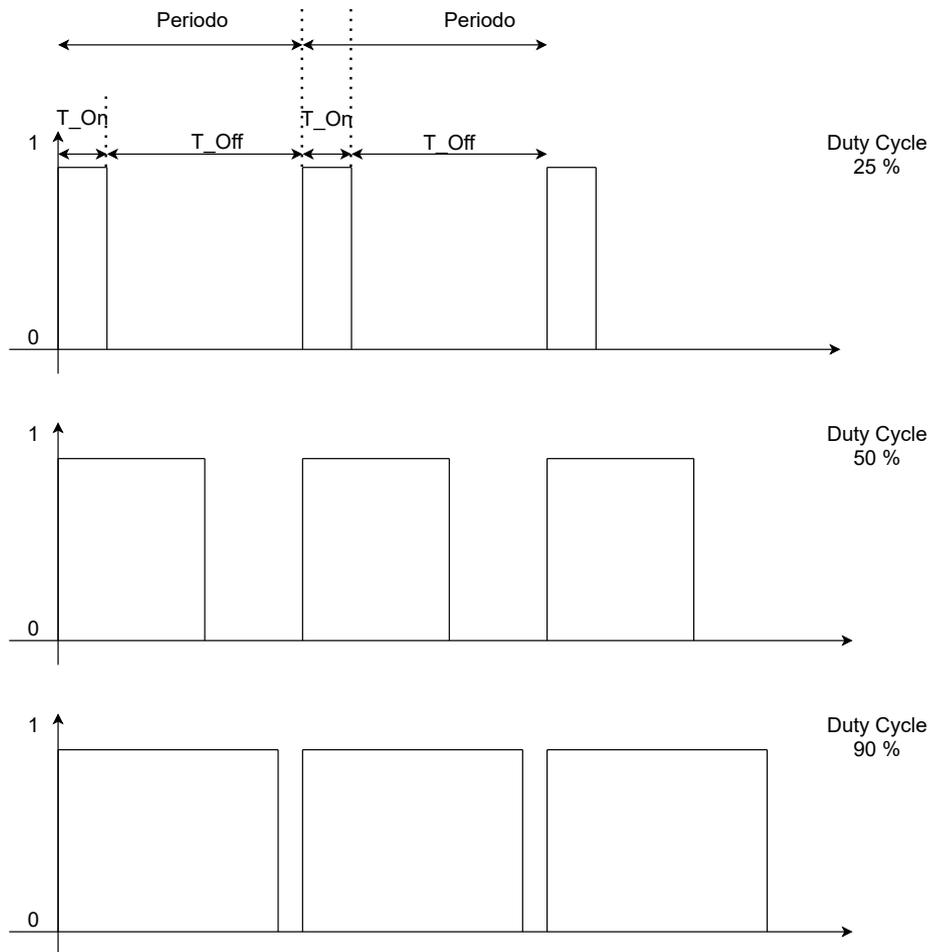


Figura 6.2: Trenes de pulso del Duty Cycle.

Para calcular el Duty Cycle de la señal de PWM se utilizan las siguientes ecuaciones:

$$\begin{aligned} \text{Periodo} &= T_{On} + T_{Off} \\ \text{Duty Cycle} &= \left( \frac{T_{On}}{T_{On} + T_{Off}} \right) 100 \% \end{aligned} \quad (6.1)$$

En la Figura 6.3 se muestra el diagrama de bloques en lazo abierto del prototipo desarrollado para la identificación del SGE. Se definió que la señal de PWM generada mediante el uso de la tarjeta myRio fuese la entrada y el voltaje del sistema adquirido ( $V_{adq}$ ) por el motor/generador fuese la salida del sistema a identificar. En la tarjeta myRio se guarda los datos de la señal de referencia (en este caso la señal PWM mandada) y  $V_{adq}$ .

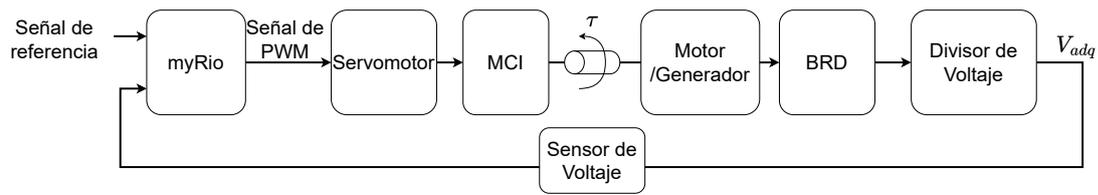


Figura 6.3: Diagrama de bloques en lazo abierto del SGE.

## 6.2. Identificación, Simulaciones y Control

La metodología aplicada para identificar el modelo del sistema, se explicó en la subsección 6.1. A continuación se muestra el diagrama de flujo de la adquisición de datos del sistema de generación de energía.

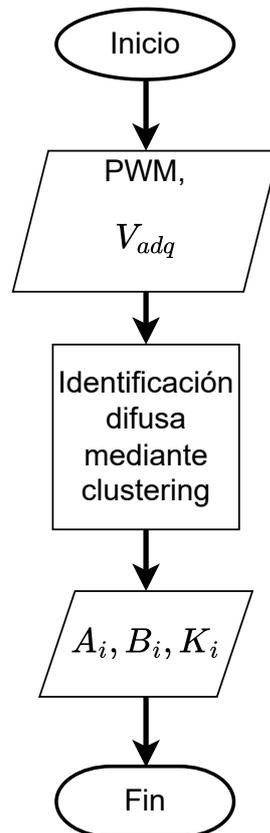


Figura 6.4: Diagrama de flujo de la identificación del sistema para la obtención del modelo difuso en Matlab.

Para diseñar el controlador se utiliza un control PDC, explicado en la subsección 5.2. En la Figura 6.5 se observa el diagrama de flujo del controlador difuso, donde se indica el proceso que se lleva a cabo para la regulación del voltaje y adquisición de datos.

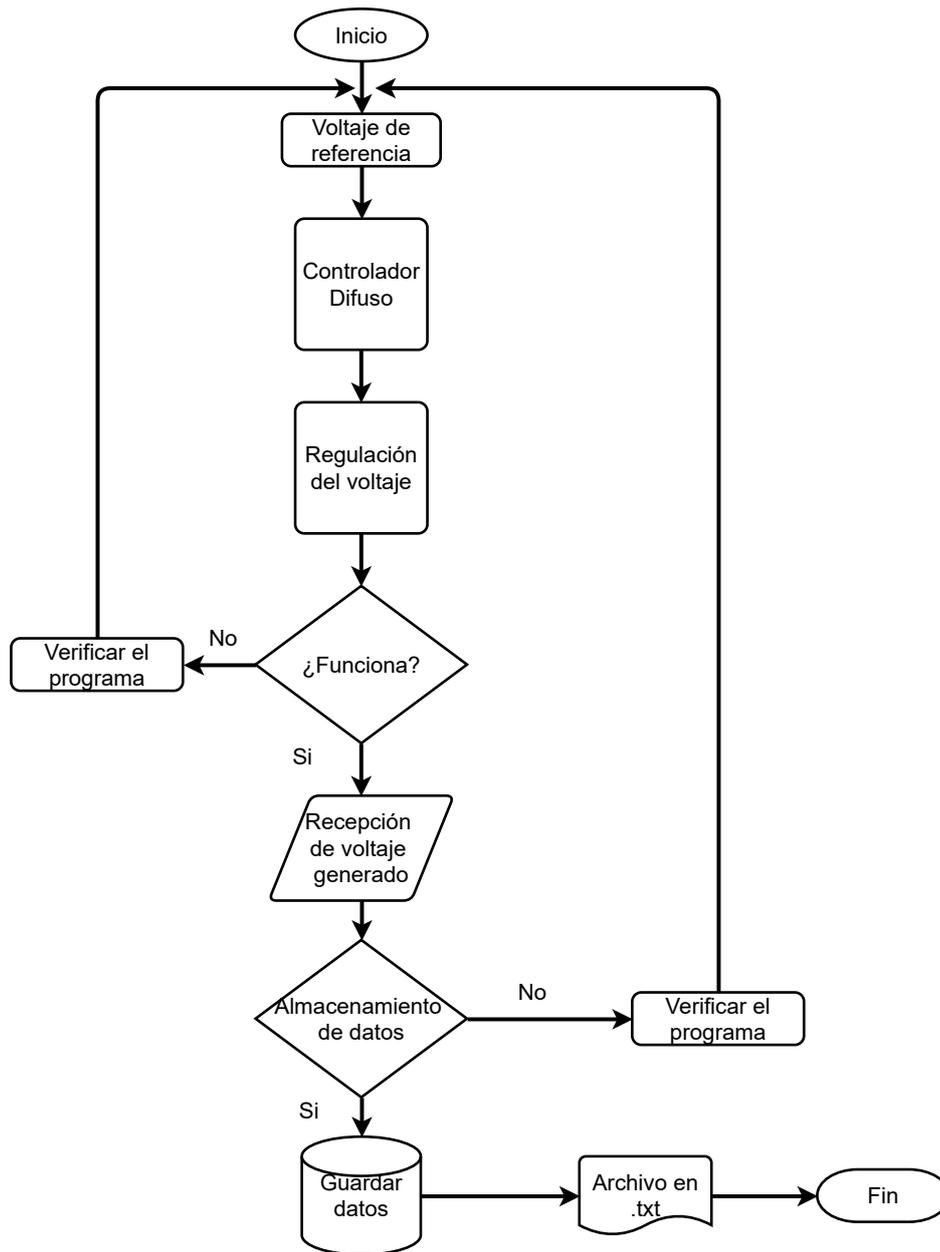


Figura 6.5: Diagrama de flujo del controlador difuso en Matlab.

### 6.2.1. Selección de polos

La localización de los polos y ceros en el plano  $z$  está relacionada con la localización de los polos y ceros en el plano  $s$ . Por lo tanto, la estabilidad del sistema en lazo cerrado en tiempo discreto lineal e invariante en el tiempo puede determinarse con base en las posiciones de los polos y ceros de la función de transferencia en lazo cerrado. El comportamiento dinámico del sistema de control en tiempo discreto depende del período de muestreo  $T$ , como

indica [140]. Las variables complejas  $z$  y  $s$  quedan relacionadas mediante la ecuación:

$$z = e^{Ts} \quad (6.2)$$

Esto significa que un polo en el plano  $s$  puede quedar localizado en el plano  $z$  mediante la transformación  $z = e^{Ts}$ . Dado que la variable compleja  $s$  está formada de una parte real  $\sigma$  y una parte imaginaria  $\omega$ , se tiene

$$s = \sigma + j\omega \quad (6.3)$$

y

$$z = e^{T(\sigma + j\omega)} = e^{T\sigma} e^{jT\omega} = e^{T\sigma} e^{j(T\omega + 2\pi k)} \quad (6.4)$$

De esta ecuación indica que los polos y los ceros en el plano  $s$ , donde las frecuencias difieran en múltiplos enteros de la frecuencia de muestreo  $\frac{2\pi}{T}$ , corresponden a las mismas localizaciones en el plano  $z$ .

Para un sistema de espacio de estados con función de transferencia  $G(s) = C(sI - A) - 1B + D$ , los polos de la función de transferencia son los valores propios de la matriz  $A$  en el modelo de espacio de estados. Una forma fácil de ver esto es notar que el valor de  $G(s)$  no está acotado cuando  $s$  es un eigenvalor del sistema, ya que este es precisamente el conjunto de puntos donde el polinomio característico  $\lambda(s) = \det(sI - A) = 0$  (y por tanto  $sI - A$  es no invertible). De ello se deduce que los polos de un sistema de espacio de estados dependen solo de la matriz  $A$ , que representa la dinámica intrínseca del sistema, como se señala en [141].

En la Figura 6.6a), en la franja primaria, la secuencia de los puntos 1 – 2 – 3 – 4 – 5 – 1 en el plano  $s$ , tal como se muestra mediante los números encerrados en un círculo, entonces esta trayectoria corresponde al círculo unitario con centro en el origen del plano  $z$ , como se muestra en la Figura 6.6b). Los puntos correspondientes 1, 2, 3, 4, 5 del plano  $z$  se muestran mediante números encerrados en un círculo en la Figura 6.6b):

### 6.2.2. Parámetro difuso

De acuerdo a la literatura, nos indica que uno puede seleccionar el parámetro difuso ( $m$ ), cumpliendo que  $m > 1$ . Se usa el algoritmo PSO para encontrar el valor óptimo de  $m$ . En

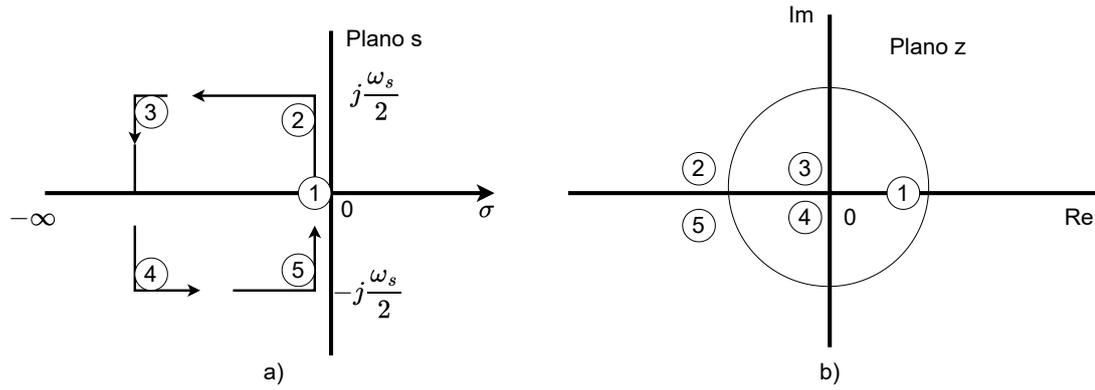


Figura 6.6: Diagramas que muestran la correspondencia entre la franja primaria  $s$  y el círculo unitario en el plano  $z$ : a)trayectoria en el plano  $s$ , b)trayectoria correspondiente en el plano  $z$ .

la Figura 6.7, se muestra el diagrama de flujo para la obtención del parámetro óptimo  $m$ , el cual se observa el uso del algoritmo PSO (véase el algoritmo utilizado en el Apéndice 7.1), al igual el uso de fuzzy c-means y mínimos cuadrados para la obtención de los parámetros consecuentes, de acuerdo al Capítulo 4 .

En la Tabla 6.1, se muestran los valores utilizados en el algoritmo PSO, así como la cotas del parámetro.

Tabla 6.1: Parámetros utilizados en el algoritmo PSO y valor obtenido del parámetro  $m$ .

Valor obtenido	Cotas	Número de partículas	Coficiente de inercia $\omega$	$c_1, c_2$	Número de iteraciones
2.9786	1.1-3	300	0.0917	0.5959	50

De acuerdo con ,  $c_1$  y  $c_2$  se calculan de la siguiente manera

$$\xi = \frac{2 * \kappa}{|2 - \phi - \sqrt{\phi^2 - 4\phi}|} \tag{6.5}$$

donde  $\phi = \phi_1 + \phi_2$ , la cual está acotada como  $\geq 4$  y  $0 \leq \kappa \leq 1$ . Por lo tanto  $c_1$  y  $c_2$  se obtienen como

$$\begin{aligned} c_1 &= \xi\phi_1 \\ c_2 &= \xi\phi_2 \end{aligned} \tag{6.6}$$

La función de costo utilizada está basada en el error cuadrático medido (RMSE, por sus

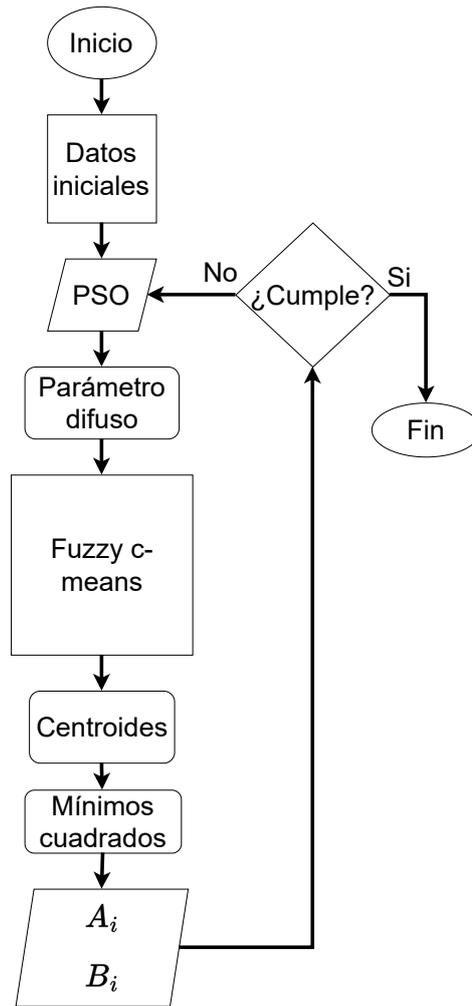


Figura 6.7: Diagrama de flujo para la obtención del parámetro difuso.

siglas en inglés) de la salida del sistema definida como:

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (V_{adq} - VI)^2}{N}} \quad (6.7)$$

donde  $V_{adq}$  es el voltaje del sistema adquirido y  $VI$  es la salida del sistema identificada a través del modelado difuso. El RMSE mide la cantidad de error que hay entre dos conjuntos de datos, por lo que es elegida como función de costo para el parámetro  $m$ , porque el parámetro interviene al momento de hacer la identificación del sistema, ecuaciones (4.3) y (4.11). En la Figura 6.8 se muestra el valor de la función de costo utilizada en la optimización del parámetro  $m$ , evaluado según el valor de la partícula con el mejor costo en cada iteración. El valor RMSE fue de 2.0513 y el valor  $m$  óptimo es de 2.7915, donde el valor  $m$  es bueno ya que está dentro del rango establecido de cotas, se indica en la Tabla 6.1.

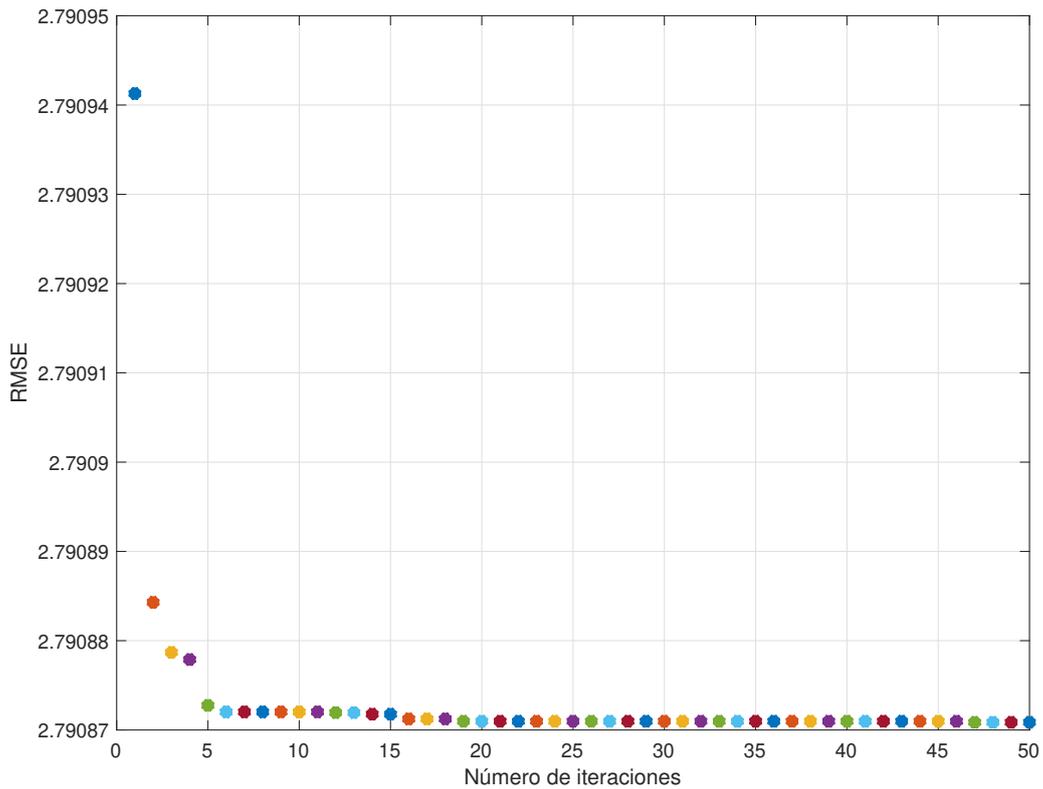


Figura 6.8: Valor de la función de costo utilizada en la optimización del parámetro  $m$ .

Tabla 6.2: Parámetros utilizados en el algoritmo PSO y valores obtenidos para cada subsistema.

Valores Obtenidos	Cotas	Número de partículas	Coefficiente de inercia $\omega$	$c_1, c_2$	Número de iteraciones
0.22,0.89	[0.01,0.9]	300	0.3820	0.9549	50

### 6.2.3. Polos del sistema

En esta etapa, usando el PSO se deben de obtener las ganancias óptimas del sistema de generación. Llegando a utilizar el parámetro óptimo  $m$ . En la Figura 6.9, se observa el diagrama de flujo para obtención de las ganancias óptimas de la ley de control, que al igual para obtención del parámetro  $m$  también se utilizó el algoritmo PSO, como se indica en el Apéndice 7.1 y al metodología del modelado difuso. En la Tabla 6.2, se muestran los valores utilizados en el algoritmo PSO, así como las cotas de las ganancias.

Para el proceso de optimización de los polos del sistema en lazo cerrado (donde el valor de RMSE es de 21.7869), acotando los límites de búsqueda en el rango [0.01 0.9], de manera que los polos obtenidos estuvieran sobre el eje real del círculo unitario, garantizando estabi-

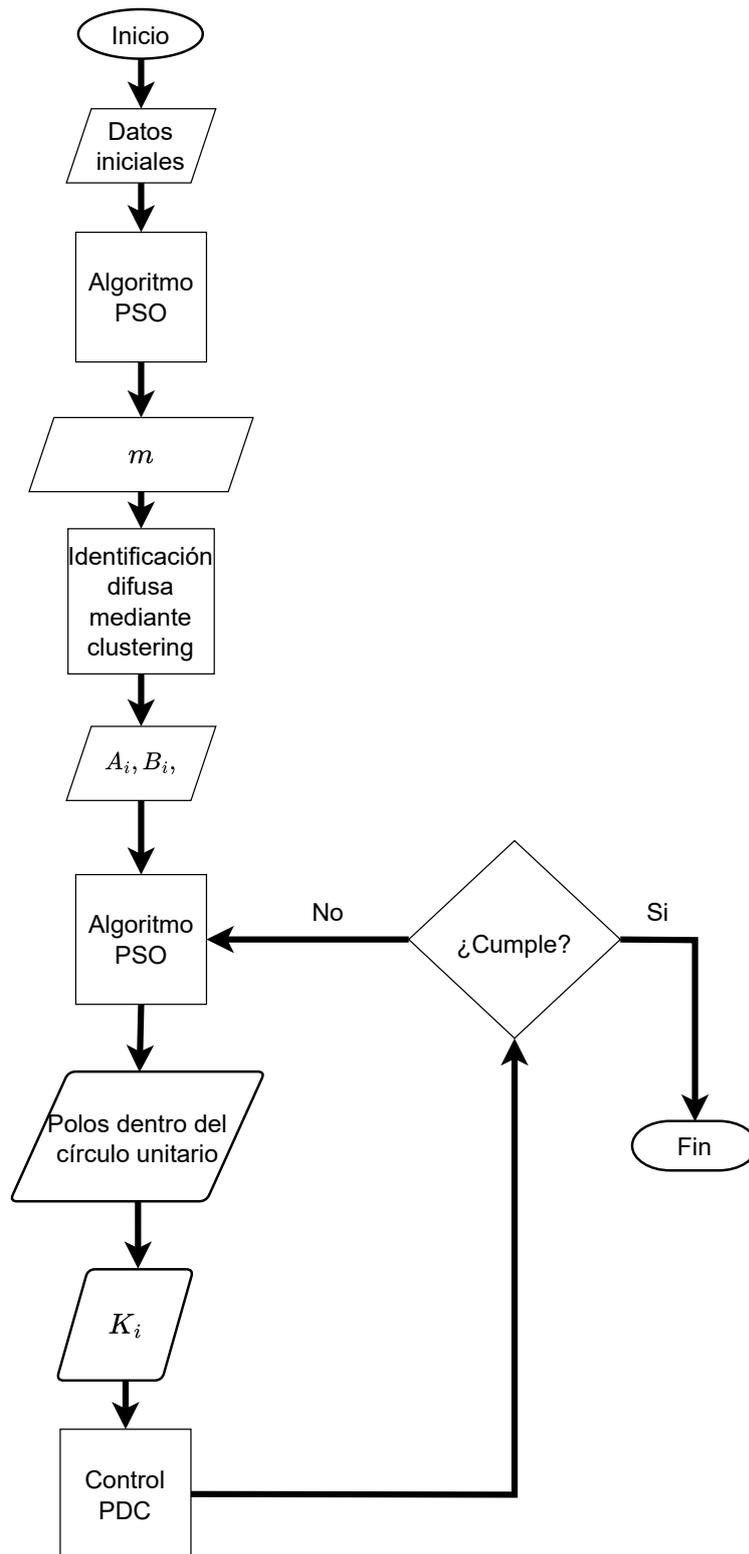


Figura 6.9: Diagrama de flujo para la obtención de las ganancias de cada subsistema.

lidad para el sistema discreto. La función objetivo utilizada fue la ecuación (6.8), donde  $r(k)$  es la referencia del voltaje deseado y  $VG(k)$  es el voltaje generado en lazo cerrado.

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (r(k) - VG(k))^2}{N}} \quad (6.8)$$

En la Figura 6.10 se muestra el valor de la función de costo utilizada en la optimización de los polos del sistema, evaluado según el valor de la partícula con el mejor costo en cada iteración.

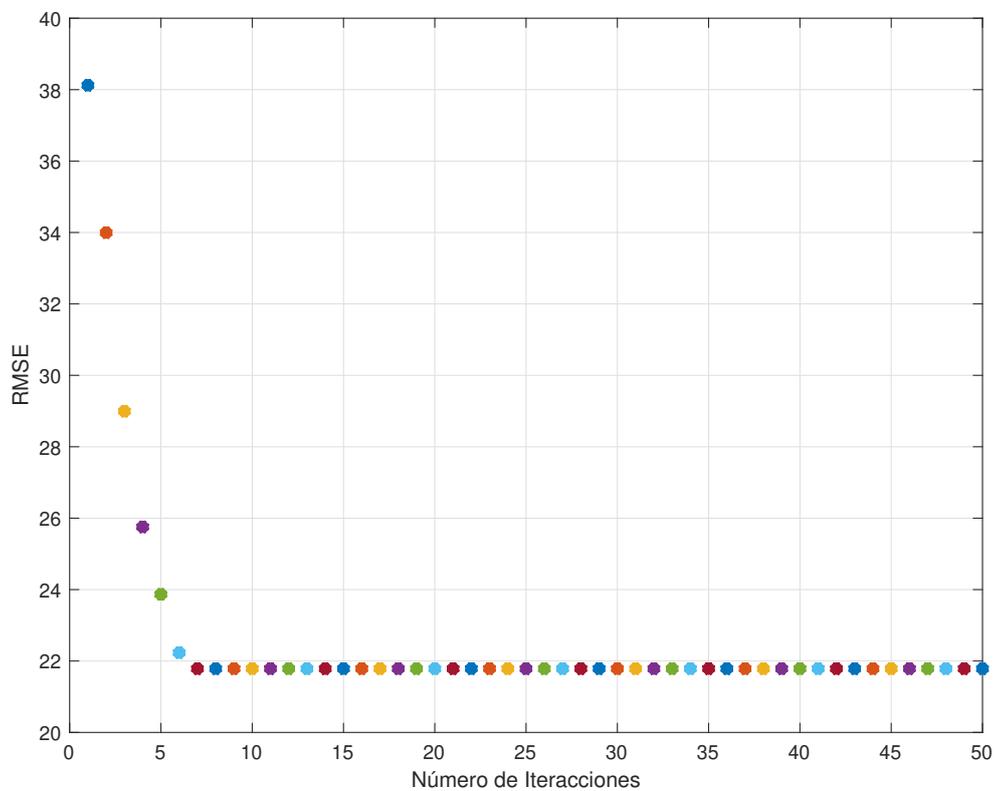


Figura 6.10: Valor de la función de costo utilizada en la optimización de los polos de cada subsistema.

#### 6.2.4. Construcción del Sistema T-S

El Algoritmo 1 muestra el pseudocódigo utilizado para la obtención del parámetro  $m$ , así como de los polos de los cuatro submodelos del sistema discreto obtenido, la identificación del sistema y las señal de control.

Para la obtención del modelo identificado, se propone cuatro clusters o reglas difusas. La

---

**Algorithm 1** Identificación del sistema difuso, optimización de parámetros y control.

---

```

PWM1, VG ← Cargar open_loop_experimental_data.txt
Z ← [VG(k − 1), VG(k), PWM1]
c ← 4                                ▷ Número de reglas o clusters
N ← Número total de datos
function FUZZY C-MEANS(Z, c)
    Calcular los centros c
end function
return c
for i ← 1 to c do                    ▷ Obtención de consecuentes
    Ai, Bi ← Ecuación (4.9)           ▷ Mínimos cuadrados
end for
return Ai, Bi
function ALGORITMO PSO                    ▷ Sistema en lazo abierto
    for m ← 1.1 to 3 do                 ▷ Parámetro difuso m
        Optimizar m usando Eq. (6.7)     ▷ Función objetivo
    end for
end function
return m
function ALGORITMO PSO                    ▷ Sistema en lazo cerrado
    for pi ← 0.01 to 0.9 do           ▷ Polos pi
        Optimizar pi usando Ecuación. (6.8) ▷ Función objetivo
    end for
end function
return pi
Calcular Ki para cada ci usando asignación de polos
function CONTROL PDC(Ai, Bi, c, c, Ki, m, x1(0), x2(0))
    for i ← 1 to N do
        Calcular las distancias euclidianas usando (4.2)
        Calcular los grados de pertenecía usando (4.3)
        Calcular la estrategia de control usando (5.14)
        Realizar la defuzificación usando (4.11)
    end for
end function

```

---

Figura 6.11 ilustra los cuatro clusters de los datos de aprendizaje  $X = [x_1 \ x_2 \ u]$ , correspondientes a  $V_{acq}(k - 2)$  y  $V_{acq}(k - 1)$ , y la entrada del sistema. En la Tabla 6.3 se muestran las coordenadas de los centroides, con respecto a los cuatro subsistemas.

Tabla 6.3: Valores de las coordenadas para cada centroide.

Centroide	$x_1$	$x_2$	$u$
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

---

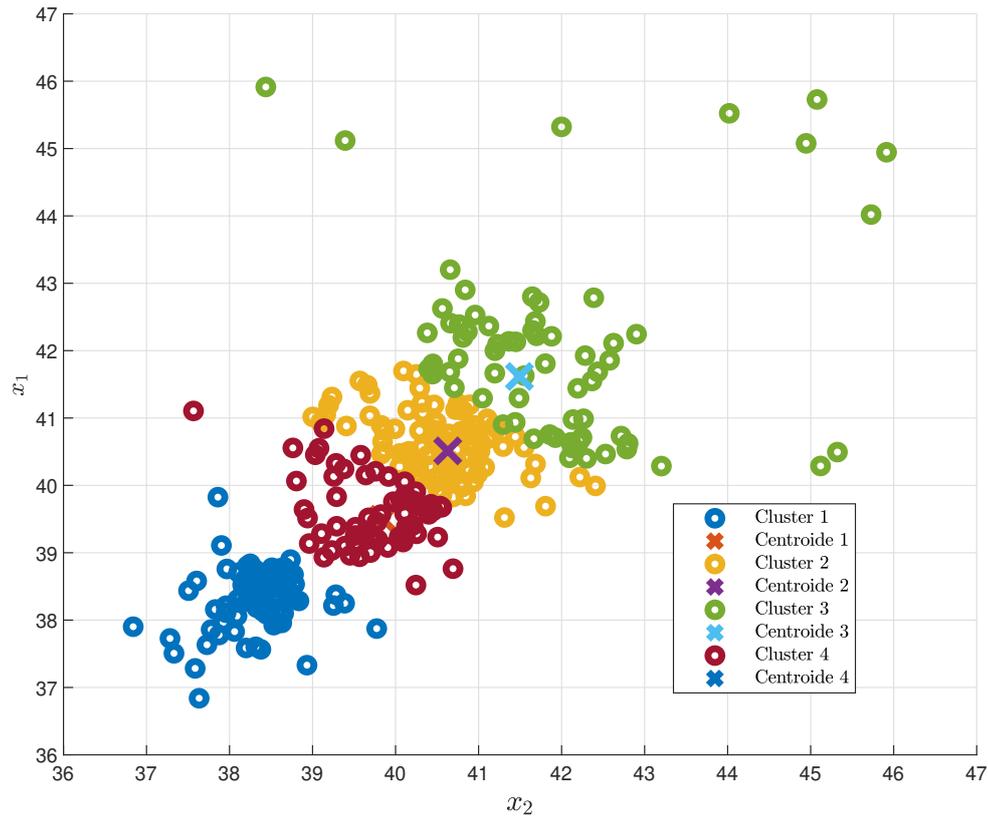


Figura 6.11: Ubicación de los clusters y centroides del sistema.

Se propone identificar un sistema de segundo orden descrito por el modelo, de acuerdo a las ecuaciones (6.9) y (6.10):

$$x^i(k+2) = a_1^i x(k+1) + a_2^i x(k) + b^i u(k) \quad (6.9)$$

$$y^i(k) = C_i x(k) \quad (6.10)$$

donde  $a_1^i$ ,  $a_2^i$  y  $b^i$  son escalares, se hace una asignación de variables del sistema en forma de espacio estado con:  $x_2^i(k+1) = x^i(k+2)$ ,  $x_2^i(k) = x_1^i(k+1)$  y  $x_1^i(k) = y^i(k)$ , de esta forma  $C = \begin{bmatrix} 0 & 1 \end{bmatrix}$ .

Así se obtiene la estructura en espacio de estado que es el consecuente de la  $i$ -ésima regla difusa, como se muestra en la ecuación (6.11). Esto implica hacer identificación de los parámetros consecuentes con el algoritmo de mínimos cuadrados, ecuación (4.9), de forma

local.

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

$$y^i(k) = \underbrace{\begin{bmatrix} 0 & 1 \end{bmatrix}}_{C_i} \begin{bmatrix} x_1(k) \\ x_2(k) \end{bmatrix} \quad (6.11)$$

Las matrices (6.12) y (6.13), son el resultado de la identificación paramétrica.

$$A_1 = \begin{bmatrix} 0 & 1 \\ \theta_1^1 & \theta_1^2 \end{bmatrix}, \quad A_2 = \begin{bmatrix} 0 & 1 \\ \theta_2^1 & \theta_2^2 \end{bmatrix}, \quad A_3 = \begin{bmatrix} 0 & 1 \\ \theta_3^1 & \theta_3^2 \end{bmatrix}, \quad A_4 = \begin{bmatrix} 0 & 1 \\ \theta_4^1 & \theta_4^2 \end{bmatrix} \quad (6.12)$$

$$B_1 = \begin{bmatrix} 0 \\ \theta_1^3 \end{bmatrix}, \quad B_2 = \begin{bmatrix} 0 \\ \theta_2^3 \end{bmatrix}, \quad B_3 = \begin{bmatrix} 0 \\ \theta_3^3 \end{bmatrix}, \quad B_4 = \begin{bmatrix} 0 \\ \theta_4^3 \end{bmatrix} \quad (6.13)$$

En la Tabla 6.4 se muestran los valores obtenidos por el método de estimación de mínimos cuadrados por consecuentes, para los cuatro subsistemas discretos identificados, es decir, para las cuatro reglas difusas, cuya ecuación es discreta se indica en la ecuación (4.10).

Tabla 6.4: Parámetros obtenidos por mínimos cuadrados por consecuentes.

Parámetros	Valores
$\theta_1^1$	0.1466
$\theta_2^1$	0.1911
$\theta_3^1$	0.1347
$\theta_4^1$	0.1614
$\theta_1^2$	-0.0997
$\theta_2^2$	-0.1065
$\theta_3^2$	-0.0990
$\theta_4^2$	-0.1053
$\theta_1^3$	64.4829
$\theta_2^3$	59.7786
$\theta_3^3$	65.2492
$\theta_4^3$	63.2293

Se obtiene  $A = h_1A_1 + h_2A_2 + h_3A_3 + h_4A_4$  y  $B = h_1B_1 + h_2B_2 + h_3B_3 + h_4B_4$ . La base de reglas para el sistema se muestra en las ecuaciones (6.14), (6.15), (6.16) y (6.17).

$$R_1 : \text{ Si } z_k \text{ es } c_1 \text{ Entonces } \begin{bmatrix} x_1^1(k+1) \\ x_2^1(k+1) \end{bmatrix} = \begin{bmatrix} 0 & 1 \\ 0.1466 & -0.0997 \end{bmatrix} \begin{bmatrix} x_1(k) \\ x_2(k) \end{bmatrix} + \begin{bmatrix} 0 \\ 64.4829 \end{bmatrix} u(k) \quad (6.14)$$

$$R_2 : \text{ Si } z_k \text{ es } c_2 \text{ Entonces } \begin{bmatrix} x_1^2(k+1) \\ x_2^2(k+1) \end{bmatrix} = \begin{bmatrix} 0 & 1 \\ 0.1911 & -0.1065 \end{bmatrix} \begin{bmatrix} x_1(k) \\ x_2(k) \end{bmatrix} + \begin{bmatrix} 0 \\ 59.7786 \end{bmatrix} u(k) \quad (6.15)$$

$$R_3 : \text{ Si } z_k \text{ es } c_3 \text{ Entonces } \begin{bmatrix} x_1^3(k+1) \\ x_2^3(k+1) \end{bmatrix} = \begin{bmatrix} 0 & 1 \\ 0.1347 & -0.0990 \end{bmatrix} \begin{bmatrix} x_1(k) \\ x_2(k) \end{bmatrix} + \begin{bmatrix} 0 \\ 65.2492 \end{bmatrix} u(k) \quad (6.16)$$

$$R_4 : \text{ Si } z_k \text{ es } c_4 \text{ Entonces } \begin{bmatrix} x_1^4(k+1) \\ x_2^4(k+1) \end{bmatrix} = \begin{bmatrix} 0 & 1 \\ 0.1614 & -0.1053 \end{bmatrix} \begin{bmatrix} x_1(k) \\ x_2(k) \end{bmatrix} + \begin{bmatrix} 0 \\ 63.2293 \end{bmatrix} u(k) \quad (6.17)$$

La Figura 6.12 muestra la respuesta del sistema en lazo abierto contra la respuesta obtenida del sistema difuso identificado. Se observa que la señal del modelo difuso es suave con respecto a la señal real del voltaje del generador eléctrico, una de las razones es por la naturaleza lineal de los modelos identificados de manera óptima en las premisas como en los consecuentes, así como el efecto de la defuzificación que es un promedio (denominador) con la suma de los disparos de las reglas, como se muestra en la ecuación (4.11). Mientras que en la parte inferior de la Figura 6.12 se presenta las señales PWM: PWM1 es la señal del servomotor y PWM2 es la señal del motor de carga. En el Apéndice 7.1, se muestra el código en lazo abierto utilizado para la comparación del voltaje generado y el voltaje identificado.

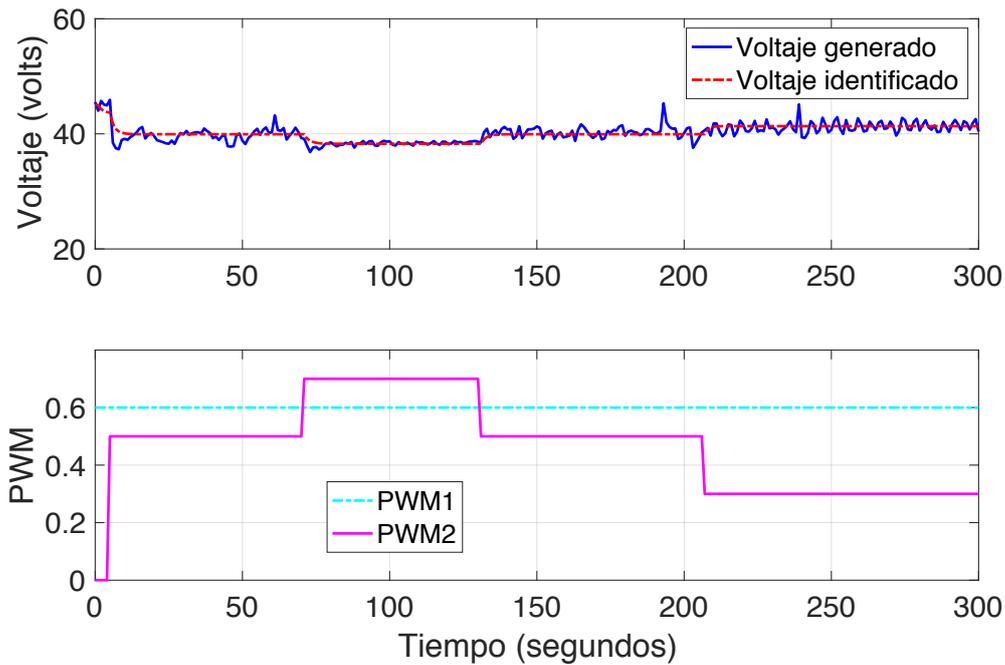


Figura 6.12: Salida aproximada del modelo difuso y voltaje del generador eléctrico en lazo abierto.

Para validar la discordancia del modelo obtenido se calculó la calidad de la identificación (QoF) mediante la ecuación (6.18), dividiendo el error cuadrático medio (RMSE) del modelo identificado entre la salida cuadrática media (MSO), la cual debe de ser mucho menor que uno [142], resultando un  $QoF = 6.1264 \times 10^{-4}$ .

$$\frac{RMSE}{MSO} = \frac{\frac{1}{N} \|\theta X - Y\|^2}{\frac{1}{N} \|Y\|^2} \quad (6.18)$$

### 6.2.5. Control PDC

Para lograr la estabilización del sistema T-S se utilizó la técnica de control basada en el compensador paralelo distribuido (PDC, por sus siglas en inglés). En este esquema, el consecuente de cada regla es una ley de control diseñada para controlar el sistema lineal obtenido como el consecuente del modelo difuso identificado [31, 133]. En el enfoque PDC con asignación de polos, se proponen los valores propios de  $(A_i - B_i K_i)$ . El controlador difuso PDC está dado por la ecuación (5.13). Las ganancias de retro de estado se determinaron mediante la metodología explicada en la subsección 5.2, usando los polos obtenidos en la subsección 6.2.3. En la Tabla 6.5 se muestra las ganancias obtenidas de cada regla. De igual manera, en el Apéndice 7.1 se presenta el código en simulación del sistema en lazo cerrado del SGE para la regulación del voltaje, así como la señal de control diseñada.

Tabla 6.5: Valores de las ganancias de cada submodelo.

Ganancias	Valores	
$K_1$	-0.0141	-0.0023
$K_2$	-0.0145	-0.0026
$K_3$	-0.0153	-0.0032
$K_4$	-0.0139	-0.0021

La Figura 6.13 muestra los resultados de simulación numérica de la regulación de voltaje a diferentes valores de entrada en la que se aprecia que el controlador PDC es capaz de regular el voltaje deseado definido por escalones de 30, 25 y 40 volts, con pequeños sobreimpulsos. La Figura 6.14 muestra la señal de control aplicada al SGE, la cual está restringida a valores en un rango de  $[0, 1]$ , dado que ésta corresponde al valor PWM enviado al servomotor acoplado a la valvula de aceleración del MCI.

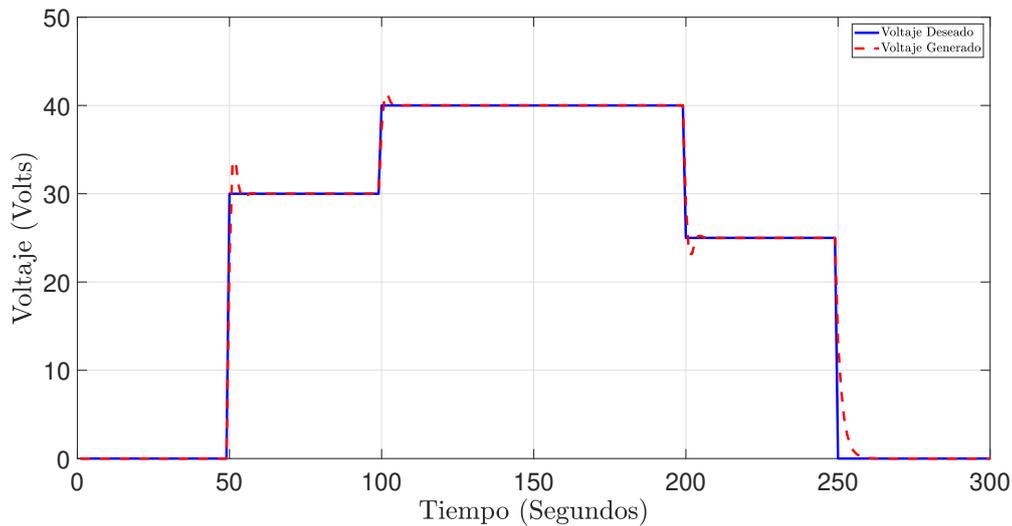


Figura 6.13: Regulación del voltaje del SGE.

### 6.2.6. Análisis de Estabilidad

Se realiza la prueba de estabilidad del sistema difuso global en lazo cerrado con el controlador PDC difuso. De acuerdo al teorema de [31] y también lo menciona [133] donde:

**Teorema 1.** *El equilibrio de un sistema difuso, ecuación (4.11), es globalmente asintóticamente estable si existe una matriz  $P$  definida positiva tal que*

$$(A_i - B_i K_j)^T P (A_i - B_i K_j) - P < 0, \quad i, j = 1, 2, \dots, Re \quad (6.19)$$

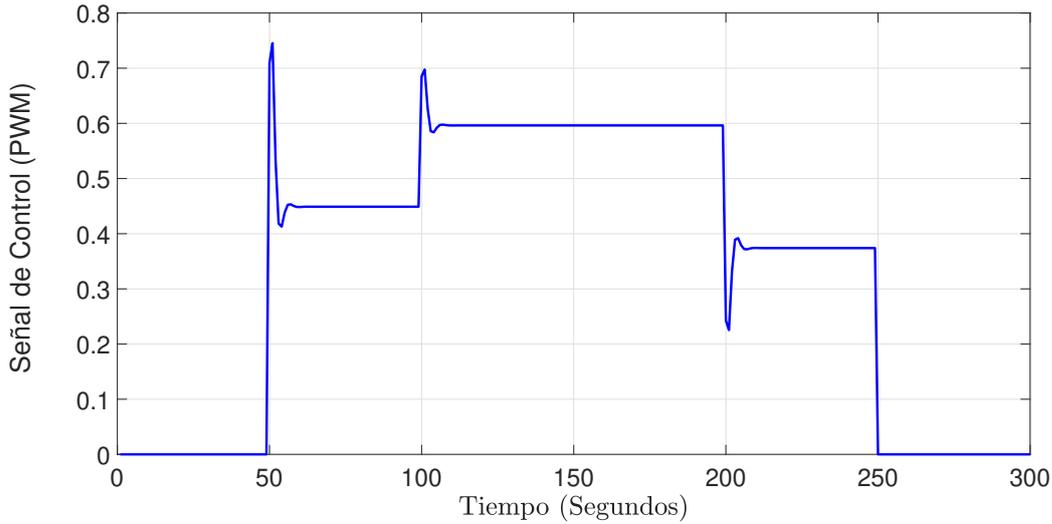


Figura 6.14: Señal de control del sistema en lazo cerrado.

*es decir, tiene que existir una matriz  $P$  común para todos los subsistemas*

El modelo difuso está 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, proponiendo la forma cuadrática de Lyapunov para sistemas discretos, que se indican en el Teorema 1.

La condición de estabilidad del Teorema 1 es expresada en LMI's (por sus siglas en inglés Desigualdades Matriciales Lineales). La estabilidad de la ecuación (6.19) equivale a 16 desigualdades ((6.20)-(6.35)) para el sistema, que son las siguientes:

$$(A_1 - B_1 k_1)^T P (A_1 - B_1 k_1) - P < 0 \quad (6.20)$$

$$(A_1 - B_1 k_2)^T P (A_1 - B_1 k_2) - P < 0 \quad (6.21)$$

$$(A_1 - B_1 k_3)^T P (A_1 - B_1 k_3) - P < 0 \quad (6.22)$$

$$(A_1 - B_1 k_4)^T P (A_1 - B_1 k_4) - P < 0 \quad (6.23)$$

$$(A_2 - B_2 k_1)^T P (A_2 - B_2 k_1) - P < 0 \quad (6.24)$$

$$(A_2 - B_2 k_2)^T P (A_2 - B_2 k_2) - P < 0 \quad (6.25)$$

$$(A_2 - B_2 k_3)^T P (A_2 - B_2 k_3) - P < 0 \quad (6.26)$$

$$(A_2 - B_2k_4)^T P (A_2 - B_2k_4) - P < 0 \quad (6.27)$$

$$(A_3 - B_3k_1)^T P (A_3 - B_3k_1) - P < 0 \quad (6.28)$$

$$(A_3 - B_3k_2)^T P (A_3 - B_3k_2) - P < 0 \quad (6.29)$$

$$(A_3 - B_3k_3)^T P (A_3 - B_3k_3) - P < 0 \quad (6.30)$$

$$(A_3 - B_3k_4)^T P (A_3 - B_3k_4) - P < 0 \quad (6.31)$$

$$(A_4 - B_3k_1)^T P (A_4 - B_4k_1) - P < 0 \quad (6.32)$$

$$(A_4 - B_3k_2)^T P (A_4 - B_4k_2) - P < 0 \quad (6.33)$$

$$(A_4 - B_3k_3)^T P (A_4 - B_4k_3) - P < 0 \quad (6.34)$$

$$(A_4 - B_3k_4)^T P (A_4 - B_4k_4) - P < 0 \quad (6.35)$$

Usando el Toolbox de Matlab LMI Control, se obtuvo a la matriz  $P$  dada por:

$$P = \begin{bmatrix} 0.5257 & -0.0015 \\ -0.0015 & 0.0033 \end{bmatrix} \quad (6.36)$$

la cual es simétrica y definida positiva, con lo que se cumple con las desigualdades, ecuación (6.19), por lo cual es globalmente asintóticamente estable en el sistema.

### 6.3. Pruebas experimentales

En las pruebas experimentales se utilizó al igual que al momento de adquisición de datos, un motor sin escobillas como carga, el cual es el mismo modelo del motor/generador: T-Motor U12KV120, véase Figura 6.15, para la regulación del voltaje.



Figura 6.15: Motor U12 utilizado en las pruebas experimentales del SGE.

La Figura 6.16 muestra los resultados obtenidos de la realización de pruebas experimentales con la planta física del SGE. Se presenta tanto el voltaje obtenido mediante la prueba física como el obtenido de la simulación con el modelo identificado ante un voltaje de referencia constante a 40 volts. Para validar los resultados del sistema de control PDC difuso, se perturbó el sistema físico con una carga eléctrica no lineal (un motor brushless). A esta carga eléctrica se le aplicaron distintos valores de velocidad, a través de la señal PWM2 mediante de un controlador electrónico de velocidad (ESC, por sus siglas en inglés), como se muestra en la Figura 6.16, esto con la intención de someter al controlador difuso a la variación de diferentes potencias de consumo por una carga dinámica no lineal. Es posible apreciar que el controlador es capaz de regular el voltaje tanto en simulación como en la prueba física al valor del voltaje de referencia. El voltaje de referencia se definió como constante dado que el sistema de generación propuesto busca reemplazar a un banco de baterías, en aplicaciones donde el voltaje suministrado debe de mantenerse fijo. El seguimiento del modelo difuso del sistema de generación de energía en lazo cerrado en tiempo real logra un  $QoF= 3.4763e 04$  dado por la ecuación (6.18). El  $QoF$  es mucho menor que 1, aún cuando el SGE está

sometido a ruido en su 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).

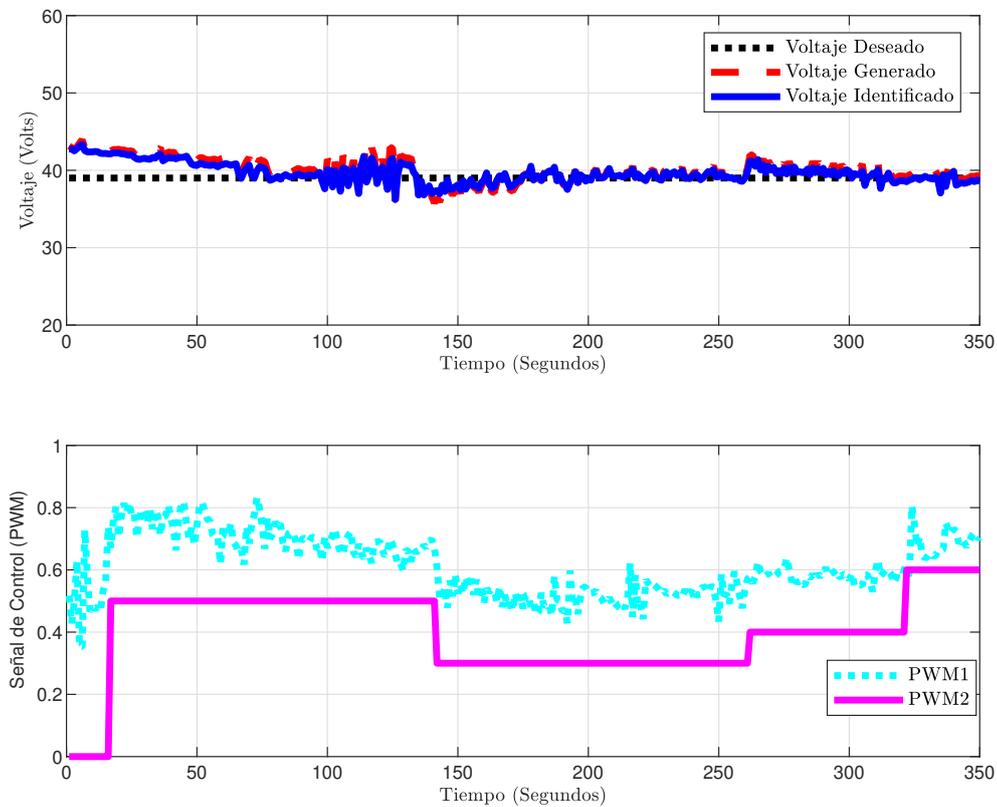


Figura 6.16: Prueba física de regulación del voltaje del SGE y valores de la carga en la prueba física.

También se utilizó el software de Labview para las pruebas físicas, donde se tomó en cuenta los resultados obtenidos en simulación. En la Figura 6.17 se presenta el control PDC utilizando los datos de los centroides obtenidos en la Tabla 6.3, así como las ganancias de cada subsistema de acuerdo a la Tabla 6.5, el número de reglas, el parámetro  $m$  y la estructura de espacio de estado, ecuación (6.11). Los datos que se almacenan en una usb en la myRio son el voltaje generado, la señal de control, el PWM del motor de carga y el voltaje deseado.



# Conclusiones

---

Con los datos propuestos de entrada-salida (PWM y voltaje del generador eléctrico) se identificó un modelo difuso del tipo Takagi-Sugeno con los consecuentes de las reglas difusas. La identificación del modelo del SGE evita la necesidad de derivar 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 motor/generador eléctrico acoplado mecánicamente y una carga eléctrica, con presencia de zonas muertas, con ruido en la señal de salida y no linealidades en la carga eléctrica.

La estrategia de optimización basada en el algoritmo PSO, permitió determinar tanto el parámetro difuso  $m$  óptimo, como la selección de los polos dentro del círculo unitario en el sistema discreto identificado utilizando datos experimentales de la planta.

La estrategia de control PDC, basada en el modelo T-S, permitió regular el voltaje generado por el SGE a un valor constante ante distintos valores de carga utilizando un motor sin escobillas. Los resultados obtenidos tanto en pruebas numéricas como experimentales demostraron que los algoritmos difusos propuestos permiten identificar y controlar un sistema de generación de energía basado en un motor de combustión interna y un motor de generación eléctrico.

## 7.1. Trabajo Futuro

Como trabajo futuro de este proyecto es aplicar el SGE realizado a un vehículo no tripulado, ya sea en UAV o UGV, ya que una de sus limitantes actuales en este tipo de vehículos

es la dependencia de energía eléctrica. Por lo que resulta necesario contar con un sistema de generación de energía para aumentar el tiempo de vuelo y poder transportar mayores cargas útiles.

---

# Glosario

---

- **Fuzzy c-means:** Es un algoritmo iterativo utilizado para encontrar grados de membresía y clusters.
- **Motor de combustión Interna:** Es una máquina donde se quema un combustible para producir trabajo y esa combustión tiene lugar dentro de la propia máquina que genera el trabajo.
- **Puente rectificador de diodos:** Es un circuito que se usa cuando se necesita convertir la corriente alterna en corriente directa.
- **PSO:** es un tipo de proceso de búsqueda basado en enjambre, en el que cada individuo se denomina partícula.
- **NI myRIO:** Es un dispositivo de entradas/salidas reconfigurable portátil que puede usar para diseñar sistemas de control.
- **Antecedente:** Es una preposición difusa.
- **Consecuente:** Es una función matemática, que puede tener la arquitectura en espacio de estado.
- **Defuzificación:** Es el proceso de convertir los grados de pertenencia de las variables lingüísticas de salida dentro de sus términos lingüísticos en valores numéricos.



# Bibliografía

---

- [1] L. Boggero, S. Corpino, A. De Martin, G. Evangelista, M. Fioriti, and M. Sorli, “A virtual test bench of a parallel hybrid propulsion system for uavs,” *Aerospace*, vol. 6, no. 7, p. 77, 2019.
- [2] J. Lieh, E. Spahr, A. Behbahani, and J. Hoying, “Design of hybrid propulsion systems for unmanned aerial vehicles,” in *47th AIAA/ASME/SAE/ASEE Joint Propulsion Conference & Exhibit*, p. 6146, 2011.
- [3] M. Ehsani, K. V. Singh, H. O. Bansal, and R. T. Mehrjardi, “State of the art and trends in electric and hybrid electric vehicles,” *Proceedings of the IEEE*, vol. 109, no. 6, pp. 967–984, 2021.
- [4] C. C. Chan, “The state of the art of electric, hybrid, and fuel cell vehicles,” *Proceedings of the IEEE*, vol. 95, no. 4, pp. 704–718, 2007.
- [5] C. C. Chan, A. Bouscayrol, and K. Chen, “Electric, hybrid, and fuel-cell vehicles: Architectures and modeling,” *IEEE transactions on vehicular technology*, vol. 59, no. 2, pp. 589–598, 2009.
- [6] G. Pistoia, *Electric and hybrid vehicles: Power sources, models, sustainability, infrastructure and the market*. Elsevier, 2010.
- [7] R. Zaccone, U. Campora, and M. Martelli, “Optimisation of a diesel-electric ship propulsion and power generation system using a genetic algorithm,” *Journal of Marine Science and Engineering*, vol. 9, no. 6, p. 587, 2021.

- 
- [8] Y. Xie, A. Savvaris, and A. Tsourdos, “Fuzzy logic based equivalent consumption optimization of a hybrid electric propulsion system for unmanned aerial vehicles,” *Aerospace Science and Technology*, vol. 85, pp. 13–23, 2019.
- [9] M. Aliramezani, C. R. Koch, and M. Shahbakhti, “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*, vol. 88, p. 100967, 2022.
- [10] J. Gao, T.-C. Chang, and R. Yao, “An adaptive intelligent system to minimize energy use for a parallel hybrid electric vehicle,” *Microsystem Technologies*, vol. 27, pp. 1483–1496, 2021.
- [11] A. N. Bhatt and N. Shrivastava, “Application of artificial neural network for internal combustion engines: A state of the art review,” *Archives of Computational Methods in Engineering*, vol. 29, no. 2, pp. 897–919, 2022.
- [12] S. M. Mahmoudi, A. Maleki, and D. R. Ochbelagh, “Optimization of a hybrid energy system with/without considering back-up system by a new technique based on fuzzy logic controller,” *Energy Conversion and Management*, vol. 229, p. 113723, 2021.
- [13] Y. Shen, P. Cui, X. Wang, X. Han, and Y.-X. Wang, “Variable structure battery-based fuel cell hybrid power system and its incremental fuzzy logic energy management strategy,” *International Journal of Hydrogen Energy*, vol. 45, no. 21, pp. 12130–12142, 2020.
- [14] Z. Yang, D. Konovalov, M. Radchenko, R. Radchenko, H. Kobalava, A. Radchenko, and V. Kornienko, “Analysis of efficiency of thermopressor application for internal combustion engine,” *Energies*, vol. 15, no. 6, p. 2250, 2022.
- [15] G. Di Giovine, L. Mariani, D. Di Battista, R. Cipollone, and F. Fremondi, “Modeling and experimental validation of a triple-screw pump for internal combustion engine cooling,” *Applied Thermal Engineering*, vol. 199, p. 117550, 2021.
- [16] Z. U. A. Zafar, N. Ali, and C. Tunç, “Mathematical modeling and analysis of fractional-order brushless dc motor,” *Advances in Difference Equations*, vol. 2021, pp. 1–25, 2021.
-

- 
- [17] Y. Liu, H. Zhu, and B. Xu, “Mathematical modelling and control of bearingless brushless direct current machine with motor and generator double modes for flywheel battery,” *IET Power Electronics*, vol. 15, no. 13, pp. 1249–1263, 2022.
- [18] G. Ferrari, A. Onorati, and G. D’Errico, *Internal combustion engines*. Società Editrice Esculapio, 2022.
- [19] N. Valenzuela Balcarce, “Diseño de un motor de combustión interna para una moto de competición,” 2021.
- [20] J. Pellicer Cloquell, *Cálculo y sintonizado de un sistema de escape para un motor de combustión interna alternativo de cuatro tiempos*. PhD thesis, Universitat Politècnica de València, 2020.
- [21] M. H. Sadraey, *Aircraft design: A systems engineering approach*. John Wiley & Sons, 2012.
- [22] A. J. Keane, A. Sóbester, and J. P. Scanlan, *Small unmanned fixed-wing aircraft design: a practical approach*. John Wiley & Sons, 2017.
- [23] A. A. L. Mecánica, “Vehículos híbridos.” <https://es.scribd.com/document/411413172/Hibridos-Aficionados-a-La-Mecanica>, 2021.
- [24] L. Cwojdzński and M. Adamski, “Power units and power supply systems in uav,” *Aviation*, vol. 18, no. 1, pp. 1–8, 2014.
- [25] P. Droppa and M. Cúttová, “Design of hybrid propulsion and its configuration in unmanned ground vehicle,” in *2021 International Conference on Military Technologies (ICMT)*, pp. 1–4, IEEE, 2021.
- [26] J. Gundlach, *Designing unmanned aircraft systems*. American Institute of Aeronautics & Astronautics, 2014.
- [27] P. Erhart, A. Jean-Jaques, and F. Deibel, “Upgraded electric propulsion systems for aecv,” *Magnet-Motor GmbH*, 2002.
- [28] K. Chau and Y. Wong, “Overview of power management in hybrid electric vehicles,” *Energy conversion and management*, vol. 43, no. 15, pp. 1953–1968, 2002.
-



- [39] S. UV, “Sullivan. acutronic power systems.” <https://www.sullivanuv.com/>, 2019.
- [40] B. Xu, J. Shi, S. Li, H. Li, and Z. Wang, “Energy consumption and battery aging minimization using a q-learning strategy for a battery/ultracapacitor electric vehicle,” *Energy*, vol. 229, p. 120705, 2021.
- [41] J. Zhu, L. Chen, X. Wang, and L. Yu, “Bi-level optimal sizing and energy management of hybrid electric propulsion systems,” *Applied Energy*, vol. 260, p. 114134, 2020.
- [42] L. Bian, X. Che, L. Chengyang, D. Jiageng, and H. Hui, “Parameter optimization of unmanned surface vessel propulsion motor based on bas-pso,” *International Journal of Advanced Robotic Systems*, vol. 19, no. 2, p. 17298814211040688, 2022.
- [43] L. Wogi, A. Thelkar, T. Tahiro, T. Ayana, S. Urooj, and S. Laguech, “Particle swarm optimization based optimal design of six-phase induction motor for electric propulsion of submarines,” *Energies*, vol. 15, no. 9, p. 2994, 2022.
- [44] S. Nolan, C. E. Jones, P. J. Norman, and G. M. Burt, “Sizing of superconducting cables for turbo-electricdistributed propulsion aircraft using a particle swarm optimization approach,” *IEEE Transactions on Transportation Electrification*, vol. 8, no. 4, pp. 4789–4798, 2022.
- [45] X.-h. Liu, D. Zhang, J. Zhang, T. Zhang, and H. Zhu, “A path planning method based on the particle swarm optimization trained fuzzy neural network algorithm,” *Cluster Computing*, pp. 1–15, 2021.
- [46] N. Bakhshinezhad, S. Mir Mohammad Sadeghi, A. R. Fathi, and H. Mohammadi Darniali, “Adaptive particularly tunable fuzzy particle swarm optimization algorithm,” *Iranian Journal of Fuzzy Systems*, vol. 17, no. 1, pp. 65–75, 2020.
- [47] N. Dhanachandra and Y. J. Chanu, “An image segmentation approach based on fuzzy c-means and dynamic particle swarm optimization algorithm,” *Multimedia tools and applications*, vol. 79, no. 25-26, pp. 18839–18858, 2020.
- [48] D. Sánchez, P. Melin, and O. Castillo, “Comparison of particle swarm optimization variants with fuzzy dynamic parameter adaptation for modular granular neural net-
-

- works for human recognition,” *Journal of Intelligent & Fuzzy Systems*, vol. 38, no. 3, pp. 3229–3252, 2020.
- [49] C. Pozna, R.-E. Precup, E. Horváth, and E. M. Petriu, “Hybrid particle filter–particle swarm optimization algorithm and application to fuzzy controlled servo systems,” *IEEE Transactions on Fuzzy Systems*, vol. 30, no. 10, pp. 4286–4297, 2022.
- [50] J. C. Bezdek, *Pattern recognition with fuzzy objective function algorithms*. Springer Science & Business Media, 2013.
- [51] J. C. Bezdek, “A physical interpretation of fuzzy isodata,” in *Readings in Fuzzy Sets for Intelligent Systems*, pp. 615–616, Elsevier, 1993.
- [52] K.-L. Wu, “Analysis of parameter selections for fuzzy c-means,” *Pattern Recognition*, vol. 45, no. 1, pp. 407–415, 2012.
- [53] K. Zhou, C. Fu, and S. Yang, “Fuzziness parameter selection in fuzzy c-means: The perspective of cluster validation,” *Science China Information Sciences*, vol. 57, pp. 1–8, 2014.
- [54] L. H. Manjarrez, J. C. Ramos-Fernández, E. S. Espinoza, and R. Lozano, “Estimation of energy consumption and flight time margin for a uav mission based on fuzzy systems,” *Technologies*, vol. 11, no. 1, p. 12, 2023.
- [55] F. Verbruggen, M. Salazar, M. Pavone, and T. Hofman, “Joint design and control of electric vehicle propulsion systems,” in *2020 European Control Conference (ECC)*, pp. 1725–1731, IEEE, 2020.
- [56] A. M. Hurwitz, J. M. Dotterweich, and T. A. Rocks, “Mobile robot battery life estimation: battery energy use of an unmanned ground vehicle,” in *Energy Harvesting and Storage: Materials, Devices, and Applications XI*, vol. 11722, pp. 24–40, SPIE, 2021.
- [57] Z. Zhang, J. Tang, and T. Zhang, “Experimental validation of hydrogen fuel-cell and battery-based hybrid drive without dc-dc for light scooter under two typical driving cycles,” *Energies*, vol. 15, no. 1, p. 69, 2022.
- [58] F. Polak, “Energy balance comparison of small unmanned vehicle equipped with electric and hybrid propulsion system,” *Combustion Engines*, vol. 59, no. 3, 2020.
-

- 
- [59] C. Friedrich and P. A. Robertson, “Hybrid-electric propulsion for aircraft,” *Journal of Aircraft*, vol. 52, no. 1, pp. 176–189, 2015.
- [60] P. Gramatikov, “Electric motor-generators for unmanned aerial vehicles,” *Aerospace Research in Bulgaria*, vol. 29, pp. 1313–0927, 2017.
- [61] K. Merial, T. Beechner, and P. Yelvington, “Hybrid-electric, heavy-fuel propulsion system for small unmanned aircraft,” *SAE International Journal of Aerospace*, vol. 7, no. 1, p. 126, 2014.
- [62] J. Sliwinski, A. Gardi, M. Marino, and R. Sabatini, “Hybrid-electric propulsion integration in unmanned aircraft,” *Energy*, vol. 140, pp. 1407–1416, 2017.
- [63] Š. Riss, “Development of a hybrid power unit for unmanned aerial vehicles,” *Czech Technical University in Prague, Prague*, 2017.
- [64] O. Schmitz and M. Hornung, “Methods for simulation and analysis of hybrid electric propulsion systems,” *CEAS Aeronautical Journal*, vol. 6, pp. 245–256, 2015.
- [65] R. Glasscock, J. Y. Hung, L. F. Gonzalez, and R. A. Walker, “Design, modelling and measurement of a hybrid powerplant for unmanned aerial systems,” *Australian Journal of Mechanical Engineering*, vol. 6, no. 2, pp. 69–78, 2008.
- [66] M. Abdul Sathar Eqbal, N. Fernando, M. Marino, and G. Wild, “Hybrid propulsion systems for remotely piloted aircraft systems,” *Aerospace*, vol. 5, no. 2, p. 34, 2018.
- [67] D. F. Finger, F. Gönnen, C. Braun, and C. Bil, “On aircraft design under the consideration of hybrid-electric propulsion systems,” in *The Proceedings of the 2018 Asia-Pacific International Symposium on Aerospace Technology (APISAT 2018) 9th*, pp. 1261–1272, Springer, 2019.
- [68] B. Lu, Q. Yu, X. Fu, Y. Shi, and M. Cai, “Parameter matching of hybrid coaxial rotors and multi-rotor uav’s power system,” in *2016 IEEE International Conference on Aircraft Utility Systems (AUS)*, pp. 1099–1104, IEEE, 2016.
- [69] Y. Xie, A. Savvaris, and A. Tsourdos, “Sizing of hybrid electric propulsion system for retrofitting a mid-scale aircraft using non-dominated sorting genetic algorithm,” *Aerospace Science and Technology*, vol. 82, pp. 323–333, 2018.
-

- 
- [70] F. G. Harmon, A. A. Frank, and S. S. Joshi, “The control of a parallel hybrid-electric propulsion system for a small unmanned aerial vehicle using a cmac neural network,” *Neural Networks*, vol. 18, no. 5-6, pp. 772–780, 2005.
- [71] N. A. Vu, D. K. Dang, and T. Le Dinh, “Electric propulsion system sizing methodology for an agriculture multicopter,” *Aerospace science and technology*, vol. 90, pp. 314–326, 2019.
- [72] E. M. Coates, A. Wenz, K. Gryte, and T. A. Johansen, “Propulsion system modeling for small fixed-wing uavs,” in *2019 International Conference on Unmanned Aircraft Systems (ICUAS)*, pp. 748–757, IEEE, 2019.
- [73] D. F. Finger, C. Braun, and C. Bil, “Comparative assessment of parallel-hybrid-electric propulsion systems for four different aircraft,” *Journal of Aircraft*, vol. 57, no. 5, pp. 843–853, 2020.
- [74] K. J. Moody, C. Replogle, and K. P. Rouser, “Design, characterization, and integration of a turboelectric power system for small unmanned multirotor aircraft,” in *AIAA Propulsion and Energy 2019 Forum*, p. 4460, 2019.
- [75] M. Singh, S. Das, and S. K. Mishra, “Static obstacles avoidance in autonomous ground vehicle using fuzzy logic controller,” in *2020 International Conference for Emerging Technology (INCET)*, pp. 1–6, IEEE, 2020.
- [76] B. Song, Y. Xiao, and L. Xu, “Design of fuzzy pi controller for brushless dc motor based on pso–gsa algorithm,” *Systems Science & Control Engineering*, vol. 8, no. 1, pp. 67–77, 2020.
- [77] W. Bo, G. Haipeng, L. Hao, and Z. Wei, “Particle swarm optimization-based fuzzy pid controller for stable control of active magnetic bearing system,” in *Journal of Physics: Conference Series*, vol. 1888, p. 012022, IOP Publishing, 2021.
- [78] C. Chen, J. Xu, G. Lin, Y. Sun, and D. Gao, “Fuzzy adaptive control particle swarm optimization based on ts fuzzy model of maglev vehicle suspension system,” *Journal of Mechanical Science and Technology*, vol. 34, pp. 43–54, 2020.
-

- 
- [79] H. Dong and J. Xi, "Model predictive longitudinal motion control for the unmanned ground vehicle with a trajectory tracking model," *IEEE Transactions on Vehicular Technology*, vol. 71, no. 2, pp. 1397–1410, 2021.
- [80] Y. Shekhar and A. U. Ahmad, "A novel control strategy of electric vehicle with hybrid energy storage system using interval type 2.0 fuzzy logic controller," 2022.
- [81] J. Guo, L. Li, K. Li, and R. Wang, "An adaptive fuzzy-sliding lateral control strategy of automated vehicles based on vision navigation," *Vehicle system dynamics*, vol. 51, no. 10, pp. 1502–1517, 2013.
- [82] C. Balerna, N. Lanzetti, M. Salazar, A. Cerofolini, and C. Onder, "Optimal low-level control strategies for a high-performance hybrid electric power unit," *Applied Energy*, vol. 276, p. 115248, 2020.
- [83] J. Xu, A. Alsabbagh, and C. Ma, "Prediction-based game-theoretic strategy for energy management of hybrid electric vehicles," *IEEE Journal of Emerging and Selected Topics in Industrial Electronics*, vol. 3, no. 1, pp. 79–89, 2021.
- [84] M. K. Park, J. M. Lee, W. H. Kang, J. M. Choi, and K. H. Lee, "Predictive model for pv power generation using rnn (lstm)," *Journal of Mechanical Science and Technology*, vol. 35, pp. 795–803, 2021.
- [85] N. B. Kumar, "Design and implementation of hybrid energy storage system (hess) for electric vehicle by using fuzzy logic controller,"
- [86] B. Rasheed, M. Usama, and A. Safdar, "Robust artificial intelligence approach to stabilize and control propeller driven hybrid ugv," in *2022 2nd International Conference on Artificial Intelligence (ICAI)*, pp. 91–94, IEEE, 2022.
- [87] A. K. Yadav, P. Gaur, S. K. Jha, J. Gupta, and A. Mittal, "Optimal speed control of hybrid electric vehicles," *Journal of Power Electronics*, vol. 11, no. 4, pp. 393–400, 2011.
- [88] X. Zhang, L. Liu, and Y. Dai, "Fuzzy state machine energy management strategy for hybrid electric uavs with pv/fuel cell/battery power system," *International Journal of Aerospace Engineering*, vol. 2018, 2018.
-

- 
- [89] G. Papalambrou, S. Samokhin, S. Topaloglou, N. Planakis, N. Kyrtatos, and K. Zenger, “Model predictive control for hybrid diesel-electric marine propulsion,” *IFAC-PapersOnLine*, vol. 50, no. 1, pp. 11064–11069, 2017.
- [90] L. Karunarathne, J. T. Economou, and K. Knowles, “Fuzzy logic control strategy for fuel cell/battery aerospace propulsion system,” in *2008 IEEE Vehicle Power and Propulsion Conference*, pp. 1–5, IEEE, 2008.
- [91] B.-J. Rhee and S. Won, “A new fuzzy lyapunov function approach for a takagi–sugeno fuzzy control system design,” *Fuzzy sets and systems*, vol. 157, no. 9, pp. 1211–1228, 2006.
- [92] R. B. Shaik and E. V. Kannappan, “Application of adaptive neuro-fuzzy inference rule-based controller in hybrid electric vehicles,” *Journal of Electrical Engineering & Technology*, vol. 15, pp. 1937–1945, 2020.
- [93] J. Lv, C. Qu, S. Du, X. Zhao, P. Yin, N. Zhao, and S. Qu, “Research on obstacle avoidance algorithm for unmanned ground vehicle based on multi-sensor information fusion,” *Mathematical Biosciences and Engineering*, vol. 18, no. 2, pp. 1022–1039, 2021.
- [94] A. Sala and C. Ariño, “Asymptotically necessary and sufficient conditions for stability and performance in fuzzy control: Applications of polya’s theorem,” *Fuzzy sets and systems*, vol. 158, no. 24, pp. 2671–2686, 2007.
- [95] H. Kerkeni, T.-M. Guerra, and J. Lauber, “Controller and observer designs for discrete ts models using an efficient lyapunov function,” in *International Conference on Fuzzy Systems*, pp. 1–7, IEEE, 2010.
- [96] L. A. Mozelli, R. M. Palhares, F. Souza, and E. M. Mendes, “Reducing conservativeness in recent stability conditions of ts fuzzy systems,” *Automatica*, vol. 45, no. 6, pp. 1580–1583, 2009.
- [97] Z. Lendek, T.-M. Guerra, and J. Lauber, “Controller design for ts models using delayed nonquadratic lyapunov functions,” *IEEE Transactions on Cybernetics*, vol. 45, no. 3, pp. 439–450, 2014.
-

- [98] P. Husek, "Recursive least square approximation using monotonic fuzzy systems," in *2016 IEEE International Symposium on Intelligent Control (ISIC)*, pp. 1–6, IEEE, 2016.
- [99] S.-J. Huang and G.-H. Yang, "Fault estimation for fuzzy delay systems: A minimum norm least squares solution approach," *IEEE Transactions on Cybernetics*, vol. 47, no. 9, pp. 2389–2399, 2016.
- [100] X. Chang, W. Li, and J. Farrell, "A c-means clustering based fuzzy modeling method," in *Ninth IEEE International Conference on Fuzzy Systems. FUZZ-IEEE 2000 (Cat. No. 00CH37063)*, vol. 2, pp. 937–940, IEEE, 2000.
- [101] Q. Ren, L. Baron, and M. Balazinski, "Type-2 takagi-sugeno-kang fuzzy logic modeling using subtractive clustering," in *NAFIPS 2006-2006 Annual Meeting of the North American Fuzzy Information Processing Society*, pp. 120–125, IEEE, 2006.
- [102] X.-J. Zeng and M. G. Singh, "Fuzzy bounded least squares method for the identification of fuzzy systems," in *Proceedings of 6th International Fuzzy Systems Conference*, vol. 1, pp. 403–408, IEEE, 1997.
- [103] T. A. Johansen, R. Shorten, and R. Murray-Smith, "On the interpretation and identification of dynamic takagi-sugeno fuzzy models," *IEEE Transactions on Fuzzy systems*, vol. 8, no. 3, pp. 297–313, 2000.
- [104] L. B. Hamouda, M. Ayadi, and N. Langlois, "Fuzzy fault tolerant predictive control for a diesel engine air path," *International Journal of Control, Automation and Systems*, vol. 14, pp. 443–451, 2016.
- [105] W. Gritli, H. Gharsallaoui, M. Benrejeb, and P. Borne, "Electronic throttle valve takagi-sugeno fuzzy control based on nonlinear unknown input observers," *INTERNATIONAL JOURNAL OF COMPUTERS COMMUNICATIONS & CONTROL*, vol. 13, no. 5, pp. 808–823, 2018.
- [106] İ. Eski and Ş. Yıldırım, "Neural network-based fuzzy inference system for speed control of heavy duty vehicles with electronic throttle control system," *Neural Computing and Applications*, vol. 28, pp. 907–916, 2017.
-

- [107] D. Khair, J. Lauber, T. Floquet, G. Colin, T. M. Guerra, and Y. Chamaillard, “Robust takagi–sugeno fuzzy control of a spark ignition engine,” *Control Engineering Practice*, vol. 15, no. 12, pp. 1446–1456, 2007.
- [108] P. Hušek and K. Narenathreyas, “Aircraft longitudinal motion control based on takagi–sugeno fuzzy model,” *Applied Soft Computing*, vol. 49, pp. 269–278, 2016.
- [109] N. Togun and S. Baysec, “Nonlinear identification of a spark ignition engine torque based on anfis with narx method,” *Expert Systems*, vol. 33, no. 6, pp. 559–568, 2016.
- [110] N. Shrivastava and Z. M. Khan, “Application of soft computing in the field of internal combustion engines: a review,” *Archives of Computational Methods in Engineering*, vol. 25, pp. 707–726, 2018.
- [111] M. S. Jie, E. J. Mo, G. Y. Hong, and K. W. Lee, “Fuzzy logic controller for turbo-jet engine of unmanned aircraft,” in *Knowledge-Based Intelligent Information and Engineering Systems: 10th International Conference, KES 2006, Bournemouth, UK, October 9-11, 2006. Proceedings, Part I 10*, pp. 29–36, Springer, 2006.
- [112] A. Elbatal, M. M. Elkhatib, and A. M. Youssef, “Intelligent autopilot design based on adaptive neuro-fuzzy technique and genetic algorithm,” in *2020 12th International Conference on Electrical Engineering (ICEENG)*, pp. 377–382, IEEE, 2020.
- [113] N. Cross, *Engineering design methods: strategies for product design*. John Wiley & Sons, 2021.
- [114] D. Ullman, *EBOOK: The Mechanical Design Process*. McGraw Hill, 2009.
- [115] J. E. Shigley, J. K. Nisbett, and R. G. Budynas, *Diseño en ingeniería mecánica de Shigley*. McGraw-Hill Interamericana, 2019.
- [116] M. F. Ashby, *Materials Selection in Mechanical Design*. Oxford: Elsevier Butterworth-Heinemann, 2005.
- [117] “Bg86, howpublished = <https://stihl.com.mx/catalogo-de-productos/sopladoras/sopladoras-de-gasolina-de-mano/sopladora-bg-86>, note = Accessed: 2023-02-27.”
-

- [118] “U12 kv120, howpublished = [https://store.tmotor.com/goods-736-u12%\\$e2%\\$85%\\$a1+kv120.html](https://store.tmotor.com/goods-736-u12%$e2%$85%$a1+kv120.html), note = Accessed: 2019-10-10.”
- [119] N. Instruments, “User guide and specifications ni myrio-1900,” *creado, en este caso se guarda en la raíz del disco duro en la carpeta*, 2018.
- [120] A. Robbins and W. C. Miller, *Análisis de circuitos: teoría y práctica*. Cengage Learning Editores, 2008.
- [121] A. K. Yadav and P. Gaur, “Intelligent modified internal model control for speed control of nonlinear uncertain heavy duty vehicles,” *ISA transactions*, vol. 56, pp. 288–298, 2015.
- [122] Z. Georgios, “Mathematical and numerical modeling of flow and combustion processes in a spark ignition engine,” *Department of Applied Mathematics*, 2005.
- [123] X. Li and S. Yurkovich, “Sliding mode control of delayed systems with application to engine idle speed control,” *IEEE Transactions on Control Systems Technology*, vol. 9, no. 6, pp. 802–810, 2001.
- [124] D. Hrovat and J. Sun, “Models and control methodologies for ic engine idle speed control design,” *Control Engineering Practice*, vol. 5, no. 8, pp. 1093–1100, 1997.
- [125] H. Bayraktar, “Mathematical modeling of spark-ignition engine cycles,” *Energy sources*, vol. 25, no. 7, pp. 651–666, 2003.
- [126] L. Guzzella and C. Onder, *Introduction to modeling and control of internal combustion engine systems*. Springer Science & Business Media, 2009.
- [127] R. Isermann, “Engine modeling and control,” *Berlin: Springers Berlin Heidelberg*, vol. 1017, 2014.
- [128] R. Babuška, “Fuzzy systems, modeling and identification,” *Delft University of Technology, Department of Electrical Engineering Control Laboratory, Mekelweg*, vol. 4, 1996.
- [129] K. M. Passino, S. Yurkovich, and M. Reinfrank, *Fuzzy control*, vol. 42. Addison-wesley Reading, MA, 1998.
-

- 
- [130] L.-X. Wang, *A course in fuzzy systems and control*. Prentice-Hall, Inc., 1996.
- [131] T. Takagi and M. Sugeno, “Fuzzy identification of systems and its applications to modeling and control,” *IEEE transactions on systems, man, and cybernetics*, no. 1, pp. 116–132, 1985.
- [132] M. Setnes, R. Babuska, and H. B. Verbruggen, “Rule-based modeling: Precision and transparency,” *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, vol. 28, no. 1, pp. 165–169, 1998.
- [133] J. H. Lilly, *Fuzzy control and identification*. John Wiley & Sons, 2011.
- [134] R. Eberhart and J. Kennedy, “A new optimizer using particle swarm theory,” in *MHS’95. Proceedings of the sixth international symposium on micro machine and human science*, pp. 39–43, Ieee, 1995.
- [135] D. Wang, D. Tan, and L. Liu, “Particle swarm optimization algorithm: an overview,” *Soft computing*, vol. 22, pp. 387–408, 2018.
- [136] F. Van Den Bergh *et al.*, *An analysis of particle swarm optimizers*. PhD thesis, University of Pretoria, 2007.
- [137] R. Eberhart, P. Simpson, and R. Dobbins, *Computational intelligence PC tools*. Academic Press Professional, Inc., 1996.
- [138] K. J. Åström and R. M. Murray, *Feedback systems: an introduction for scientists and engineers*. Princeton university press, 2021.
- [139] J. Rantung and H. Luntungan, “Dc motor pid controller with pwm feedback,” *Jurnal Tekno Mesin*, vol. 6, no. 1, 2020.
- [140] A. Astolfi, “Stability of dynamical systems-continuous, discontinuous, and discrete systems (by michel, an et al.; 2008)[bookshelf],” *IEEE Control Systems Magazine*, vol. 29, no. 1, pp. 126–127, 2009.
- [141] A. N. Michel, L. Hou, and D. Liu, *Stability of dynamical systems*. Springer, 2008.
- [142] J. P. Hespanha, “Advanced undergraduate topics in control systems design,” 2019.
-

# Algoritmos del Sistema de Lazo Abierto y Cerrado en Matlab

---

```
1 clc
2 clear all
3 close all
4
5 %% Datos adquiridos de labview
6 load('datos_adquiridos_pwm_voltaje_carga_para_la_identificacion.mat')
7
8 %% Parámetros de simulación
9 Ti = 0; T = 0.1; Tf = 500;
10 t = [Ti:T:Tf]; %Tiempo
11 lt = length(t);
12
13 %% Datos
14 X = [PWM Voltaje];
15 n = 301; %Número total de datos
16
17 %% Entrada del sistema
18 Ue = X(:,1);
19
20 %% Salida del sistema
21 Y = X(:,2);
22
23 %% Matriz de regresion
24 for k=2:n
25     Ue(k) = X(k-1,1);
```

```
26     x1(k) = X(k-1,2);
27 end
28
29 Z = [x1' x2' Ue];
30
31 %% Influencia del grado de pertenencia
32 m = 2.9931; %rms = 2.0442
33
34 %% Número de reglas y clusters
35 Re = 4;
36 it = 100; %número de iteraciones difuso
37 me = 1e-5; %minimo error de convergencia de c-means
38 verbose = false;
39
40 %% Condiciones iniciales
41 zz(1,:) = [0 0 0 0];
42 zz(2,:) = [0 0 0 0];
43 % zz(3,:) = [0 0 0 0];
44
45 Xg(1) = 45;
46 Xg(2) = 45;
47
48
49 Xg1(1) = 45;
50 Xg1(2) = 45;
51 Xg2(1) = 45;
52 Xg2(2) = 45;
53
54
55
56
57 %% Fuzzy c-means tercer orden (4 clusters)
58 options = fcmOptions(NumClusters=Re, Exponent=m, MaxNumIteration=it,
    MinImprovement=me, Verbose=verbose);
59 [centers,U] = fcm(Z,options);
60
61 %% Se calculan los parametros consecuentes lineales (Least-squares
    estimation of consequents
62 for i=1:Re
```

```

63     theta(i,:) = ((Z'*diag(U(i,:))*Z)^-1)*Z'*diag(U(i,:))*Y;
64 end
65
66
67 %% Sistema
68 A1 = [0 1; theta(1,1) theta(1,2)];
69 B1 = [0;theta(1,3)];
70
71 A2 = [0 1; theta(2,1) theta(2,2)];
72 B2 = [0;theta(2,3)];
73
74 A3 = [0 1; theta(3,1) theta(3,2)];
75 B3 = [0;theta(3,3)];
76
77 A4 = [0 1; theta(4,1) theta(4,2)];
78 B4 = [0;theta(4,3)];
79
80
81 %%
82 for k=3:n
83
84     %% Vector de cada instante
85     zz(k,:) = [Xg(k-2) Xg(k-1) Ue(k)];
86
87     %% Grados de pertenencia
88     for i=1:Re
89         %%Suma de distancias euclidianas
90         %D(i) = sqrt((zz(k,:) - centers(i,:)) * (zz(k,:) - centers(i,:))
91         ');
91         D(i) = norm(zz(k,:) - centers(i,:));
92     end
93
94     for i=1:Re
95         s(i) = 0;
96         for j=1:Re
97             s(i) = s(i) + D(i)/D(j);
98         end
99         mu(i,k) = 1/(s(i)^(2/(m - 1)));
100    end

```

```

101
102     %% Pesos %Fuzzy control systems design and analysis: a linear matrix
inequality approach
103     for j=1:Re
104         w(j) = prod(mu(j,k), 'all'); %2.7
105     end
106
107     for i=1:Re
108         h(i,k) = w(i)/(w(1) + w(2) + w(3) + w(4));
109     end
110
111     %% Sistema
112     A = A1*h(1,k) + A2*h(2,k) + A3*h(3,k) + A4*h(4,k);
113     B = B1*h(1,k) + B2*h(2,k) + B3*h(3,k) + B4*h(4,k);
114
115     %% Defuzificación
116     suma = 0;
117     aprox = 0;
118     for i=1:Re
119         for e=1:2
120             suma = suma + h(i,k)*(A(e,:)*[Xg(k-2);Xg(k-1)] + B(e)*Ue(k);
121             aprox = aprox + h(i,k);
122         end
123     end
124
125     Xg(k) = suma/aprox;
126
127 end
128
129 figure(1)
130 plot(Y)
131 hold on
132 plot(Xg)
133 ylabel('Voltaje (Volts)', 'Interpreter', 'latex', 'fontweight', 'bold', '
fontsize', 16)
134 legend('Voltaje Adquirido', 'Modelo Identificado', 'Interpreter', 'latex'
, 'fontweight', 'bold', 'fontsize', 16)
135 xlabel('Tiempo (Segundos)', 'Interpreter', 'latex', 'fontweight', 'bold', '
fontsize', 16)

```

```
136
137 figure (2)
138 maxU = max(U);
139 index = cell(Re,1);
140 for i=1:Re
141     index{i} = find(U(i,:) == maxU);
142 end
143 hold on
144 for i=1:Re
145     plot(Z(index{i},1),Z(index{i},2),"o")
146     plot(centers(i,1),centers(i,2),"xk",MarkerSize=15,LineWidth=3)
147 end
148 hold off
```

Listing 1: Programa de lazo abierto del SGE.

Ubicación del archivo en .mat de los adquiridos en lazo abierto: [https://cinvestav365-my.sharepoint.com/:u:/g/personal/eduardo\\_espinoza\\_cinvestav\\_mx/EWqn0GB2wDRHmOyhj1ttaPcB6yO7NVWYTOuq9bTf\\_wiAQA?e=pc5jCm](https://cinvestav365-my.sharepoint.com/:u:/g/personal/eduardo_espinoza_cinvestav_mx/EWqn0GB2wDRHmOyhj1ttaPcB6yO7NVWYTOuq9bTf_wiAQA?e=pc5jCm)

---

```
1 clc
2 clear all
3 close all
4
5 %% Datos adquiridos de labview
6 load('datos_adquiridos_pwm_voltaje_carga_para_la_identificacion.mat')
7
8 %% Parámetros de simulación
9 Ti = 0; T = 0.1; Tf = 500;
10 t = [Ti:T:Tf]; %Tiempo
11 lt = length(t);
12
13 %% Datos
14 X = [PWM Voltaje Corriente Carga];
15 n = 301; %Número total de datos
16
17 %% Entrada del sistema
18 Ue = X(:,1);
19
20 %% Salida del sistema
21 Y = X(:,2);
22
23 %% Perturbación
24 co = X(:,3);
25
26 %% Matriz de regresion
27 for k=2:n
28     Ue(k) = X(k-1,1);
29     x1(k) = X(k-1,2);
30 end
31
32 for k=3:n
33     x2(k) = X(k-2,2);
34 end
35
36
37 Z = [x1' x2' Ue];
38
39 %% Influencia del grado de pertenecia
```

```
40 m = 2.9786; %rms = 2.0365 2.9931;
41
42 %% Número de reglas y clusters
43 Re = 4;
44 it = 100; %número de iteraciones difuso
45 me = 1e-5; %minimo error de convergencia de c-means
46 verbose = false;
47
48 %% Condiciones iniciales
49 u1(1) = 0;
50 u2(1) = 0;
51
52 u(1) = 0;
53 u(2) = 0;
54
55 zz(1,:) = [0 0 0];
56 zz(2,:) = [0 0 0];
57 zz(3,:) = [0 0 0];
58
59 error(1) = 0;
60 error(2) = 0;
61 error(3) = 0;
62
63 ref(1) = 0;
64 ref(2) = 0;
65 ref(3) = 0;
66
67 Xg(1) = 0;
68 Xg(2) = 0;
69 Xg(3) = 0;
70
71
72 Xg1(1) = 0;
73 Xg1(2) = 0;
74 Xg1(3) = 0;
75 Xg2(1) = 0;
76 Xg2(2) = 0;
77 Xg2(3) = 0;
78
```

```

79
80 %% Fuzzy c-means tercer orden (4 clusters)
81 options = fcmOptions(NumClusters=Re, Exponent=m, MaxNumIteration=it,
    MinImprovement=me, Verbose=verbose);
82 [centers,U] = fcm(Z,options);
83
84 %% Se calculan los parametros consecuentes lineales
85 for i=1:Re
86     theta(i,:) = ((Z'*diag(U(i,:))*Z)^-1)*Z'*diag(U(i,:))*Y;
87 end
88
89
90 %% Sistema
91 A1 = [0 1; theta(1,1) theta(1,2)];
92 B1 = [0;theta(1,3)];
93
94 A2 = [0 1; theta(2,1) theta(2,2)];
95 B2 = [0;theta(2,3)];
96
97 A3 = [0 1; theta(3,1) theta(3,2)];
98 B3 = [0;theta(3,3)];
99
100 A4 = [0 1; theta(4,1) theta(4,2)];
101 B4 = [0;theta(4,3)];
102
103 %% Polos PSO
104 P_D1 = [-0.9 0.9]; %rms=21.7869
105 P_D2 = [0.9 -0.9];
106 P_D3 = [-0.9 0.9];
107 P_D4 = [-0.9 0.9];
108
109
110
111 %% Ganancias
112 %Sintonización de las ganancias del primer subsistema
113 L1 = poly(P_D1); %Polinomio característico P_D2
114 ran1 = rank(ctrb(A1,B1));
115 q1 = poly(A1); %Polinomio característico de A2
116 W1 = [q1(:,2) 1];

```

```

117     1 0];
118 Con1 = [B1 A1*B1]; %Matriz de Controlabilidad
119 T1 = Con1*W1;
120 K1 = [L1(:,3)-q1(:,3) L1(:,2)-q1(:,2)]*(T1^-1);
121
122 %Verificar que los eigenvalores del lazo cerrado...
123     están en la localización deseada
124 k1 = place(A1,B1,P_D1);
125 A_CL1 = A1 - B1*k1;
126 Loc1 = eig(A_CL1);
127
128 %Sintonización de las ganancias del segundo subsistema
129 L2 = poly(P_D2); %Polinomio característico P_D2
130 ran2 = rank(ctrb(A2,B2));
131 q2 = poly(A2); %Polinomio característico de A2
132 W2 = [q2(:,2) 1;
133     1 0];
134 Con2 = [B2 A2*B2]; %Matriz de Controlabilidad
135 T2 = Con2*W2;
136 K2 = [L2(:,3)-q2(:,3) L2(:,2)-q2(:,2)]*(T2^-1);
137
138 %Verificar que los eigenvalores del lazo cerrado están en la localización
139     deseada
140 k2 = place(A2,B2,P_D2);
141 A_CL2 = A2 - B2*k2;
142 Loc2 = eig(A_CL2);
143
144 %Sintonización de las ganancias del tercer subsistema
145 L3 = poly(P_D3); %Polinomio característico P_D3
146 ran3 = rank(ctrb(A3,B3));
147 q3 = poly(A3); %Polinomio característico de A3
148 W3 = [q3(:,2) 1;
149     1 0];
150 Con3 = [B3 A3*B3]; %Matriz de Controlabilidad
151 T3 = Con3*W3;
152 K3 = [L3(:,3)-q3(:,3) L3(:,2)-q3(:,2)]*(T3^-1);
153
154 %Verificar que los eigenvalores del lazo cerrado están en la localización
155     deseada

```

```
154 k3 = place(A3,B3,P_D3);
155 A_CL3 = A3 - B3*k3;
156 Loc3 = eig(A_CL3);
157
158 %Sintonización de las ganancias del cuarto subsistema
159 L4 = poly(P_D4); %Polinomio característico P_D2
160 ran4 = rank(ctrb(A4,B4));
161 q4 = poly(A4); %Polinomio característico de A2
162 W4 = [q4(:,2) 1;
163        1 0];
164 Con4 = [B4 A4*B4]; %Matriz de Controlabilidad
165 T4 = Con4*W4;
166 K4 = [L4(:,3)-q4(:,3) L4(:,2)-q4(:,2)]*(T4^-1);
167
168 %Verificar que los eigenvalores del lazo cerrado están en la localización
    deseada
169 k4 = place(A4,B4,P_D4);
170 A_CL4 = A4 - B4*k4;
171 Loc4 = eig(A_CL4);
172
173 N = 2.291725153402352;
174 %%
175 for k=3:n
176
177     % ref(k) = 40;
178
179     if k<50
180         ref(k)=0;
181     elseif k<100
182         ref(k)=30;
183     elseif k<200
184         ref(k)=40;
185     elseif k<250
186         ref(k)=25;
187     else
188         ref(k) = 0;
189     end
190
191     error(k) = N*ref(k) - Xg(k-2);
```

```

192
193 %% Vector de cada instante
194 zz(k,:) = [Xg(k-2) Xg(k-1) u(k-1)];
195
196 %% Grados de pertenencia
197 for i=1:Re
198     %Suma de distancias euclidianas
199     %D(i) = sqrt((zz(k,:) - centers(i,:)) * (zz(k,:) - centers(i,:))
200     ');
201     D(i) = norm(zz(k,:) - centers(i,:));
202 end
203
204 for i=1:Re
205     s(i) = 0;
206     for j=1:Re
207         s(i) = s(i) + D(i)/D(j);
208     end
209     mu(i,k) = 1/(s(i)^(2/(m-1)));
210 end
211
212 %% Pesos
213 for j=1:Re
214     w(j) = prod(mu(j,k), 'all');
215 end
216
217 for i=1:Re
218     h(i,k) = w(i)/(w(1) + w(2) + w(3) + w(4));
219 end
220
221 %% Control (Discrete-Time Parallel Distributed Pole Placement)
222 u1(k) = -(K1*h(1,k)) * [error(k); Xg(k-1)];
223 u2(k) = -(K2*h(2,k)) * [error(k); Xg(k-1)];
224 u3(k) = -(K3*h(3,k)) * [error(k); Xg(k-1)];
225 u4(k) = -(K4*h(4,k)) * [error(k); Xg(k-1)];
226
227 u(k) = u1(k) + u2(k) + u3(k) + u4(k);
228
229 if u(k) > 1

```

```
230     u(k) = 1;
231 end
232
233 if u(k)<0
234     u(k) = 0;
235 end
236
237 %% Sistema
238 A = A1*h(1,k) + A2*h(2,k) + A3*h(3,k) + A4*h(4,k);
239 B = B1*h(1,k) + B2*h(2,k) + B3*h(3,k) + B4*h(4,k);
240 % G = G1*h(1,k) + G2*h(2,k) + G3*h(3,k) + G4*h(4,k);
241
242 %% Defuzificación
243 suma = 0;
244 aprox = 0;
245 for i=1:Re
246     for e=1:2
247         suma = suma + h(i,k)*(A(e,:) * [Xg(k-2);Xg(k-1)] + B(e)*u(k));
248         aprox = aprox + h(i,k);
249     end
250 end
251
252
253 Xg(k) = suma/aprox;
254
255 if Xg(k)<0
256     Xg(k) = 0;
257 end
258
259
260 end
261
262 %% Estabilidad del sistema
263 setlmis([])
264 P = lmivar(1,[2,1]);
265 Q = lmivar(1,[2,1]);
266 R = lmivar(1,[1,1]);
267 %se definen LMIs
268 lmiterm([-1 1 1 P],1,1);
```

```

269 lmiterm([-2 1 1 Q],1,1);
270 lmiterm([-2 1 1 R],1,1);
271 %LMI del sistema
272 lmiterm([4 1 1 P],A',1,'s'); %P>0
273 lmiterm([4 1 1 Q],1,1); %Q>0
274 lmiterm([4 1 2 -P],1,B);
275 lmiterm([4 2 2 R],-1,1); %R>0
276
277 LMIs = getlmis;
278 [TMIN,XFEAS] = feasp(LMIs);
279
280 Q = dec2mat(LMIs,XFEAS,Q);
281 P = dec2mat(LMIs,XFEAS,P);
282 R = dec2mat(LMIs,XFEAS,R);
283
284 try chol(P)
285     disp('Matriz es definida simétrica y positiva.')
286 catch ME
287     disp('Matriz no es definida simétrica y positiva')
288 end
289
290 %% Figuras
291
292 %Funciones de pertenencia
293 figure(1)
294 plot(U')
295 ylabel('Grados de pertenencia','Interpreter','latex','fontweight','bold',
        'fontsize',16)
296 xlabel('Tiempo (Segundos)','Interpreter','latex','fontweight','bold',
        'fontsize',16)
297 grid
298 print(gcf,'foo.png','-dpng','-r300');
299
300 %Regulación del Voltaje
301 figure(2)
302 plot(ref,'LineWidth',3)
303 hold on
304 plot(Xg,'LineWidth',3)
305 grid on

```

```
306 ylabel('Voltaje (Volts)', 'Interpreter', 'latex', 'fontweight', 'bold', 'fontsize', 16)
307 legend('Voltaje Deseado', 'Voltaje Generado', 'Interpreter', 'latex', 'fontweight', 'bold', 'fontsize', 16)
308 xlabel('Tiempo (Segundos)', 'Interpreter', 'latex', 'fontweight', 'bold', 'fontsize', 16)
309 hold off
310
311 %Control PD Difuso
312 figure(3)
313 plot(u, 'LineWidth', 3)
314 ylabel('Señal de Control (PWM)', 'Interpreter', 'latex', 'fontweight', 'bold', 'fontsize', 16)
315 xlabel('Tiempo (Segundos)', 'Interpreter', 'latex', 'fontweight', 'bold', 'fontsize', 16)
316 grid on
317 print(gcf, 'foo.png', '-dpng', '-r300');
```

Listing 2: Programa de lazo cerrado del SGE.

# Algoritmos PSO para la obtención del parámetro óptimo difuso y los polos óptimos del sistema en Matlab

---

```
1 function z=error_rms_m(x)
2
3 %% Datos adquiridos de labview
4 load('datos_adquiridos_pwm_voltaje_carga_para_la_identificacion.mat')
5
6 %% Parámetros de simulación
7 Ti = 0; T = 0.1; Tf = 500;
8 t = [Ti:T:Tf]; %Tiempo
9 lt = length(t);
10
11 %% Datos
12 X = [PWM Voltaje];
13 n = 301; %Número total de datos
14
15 %% Entrada del sistema
16 Ue = X(:,1);
17
18 %% Salida del sistema
19 Y = X(:,2);
20
21 %% Matriz de regresion
22 for k=2:n
23     Ue(k) = X(k-1,1);
```

```
24     x1(k) = X(k-1,2);
25 end
26
27 for k=3:n
28     x2(k) = X(k-2,2);
29 end
30
31 for k=4:n
32     x3(k) = X(k-3,2);
33 end
34
35 Z = [x2' x1' Ue];
36
37 %% Número de reglas y clusters
38 Re = 4;
39 it = 100; %número de iteraciones difuso
40 me = 1e-5; %minimo error de convergencia de c-means
41 verbose = false;
42
43 %% Condiciones iniciales
44 zz(1,:) = [0 0 0];
45 zz(2,:) = [0 0 0];
46
47 Xg(1) = 25;
48 Xg(2) = 25;
49
50
51 Xg1(1) = 45;
52 Xg1(2) = 45;
53 Xg2(1) = 45;
54 Xg2(2) = 45;
55
56
57 %% Fuzzy c-means tercer orden (4 clusters)
58 options = fcmOptions(NumClusters=Re, Exponent=x, MaxNumIteration=it,
    MinImprovement=me, Verbose=verbose);
59 [centers,U] = fcm(Z,options);
60
61 %% Se calculan los parametros consecuentes lineales (Least-squares
```

```

        estimation of consequents
62 for i=1:Re
63     theta(i,:) = ((Z'*diag(U(i,:))*Z)^-1)*Z'*diag(U(i,:))*Y; %ecuación 38
        Fuzzy Systems, Modeling and Identification
64 end
65
66
67 %% Sistema
68
69 A1 = [0 1; theta(1,1) theta(1,2)];
70 B1 = [0;theta(1,3)];
71
72 A2 = [0 1; theta(2,1) theta(2,2)];
73 B2 = [0;theta(2,3)];
74
75 A3 = [0 1; theta(3,1) theta(3,2)];
76 B3 = [0;theta(3,3)];
77
78 A4 = [0 1; theta(4,1) theta(4,2)];
79 B4 = [0;theta(4,3)];;
80
81
82
83
84 %%
85 for k=3:n
86
87     %% Vector de cada instante
88     zz(k,:) = [Xg(k-2) Xg(k-1) Ue(k)];
89
90     %% Grados de pertenencia
91     for i=1:Re
92         %Suma de distancias euclidianas
93         %D(i) = sqrt((zz(k,:) - centers(i,:)) * (zz(k,:) - centers(i,:))
94         ');
94         D(i) = norm(zz(k,:) - centers(i,:));
95     end
96
97     for i=1:Re
    
```

```

98     s(i) = 0;
99     for j=1:Re
100         s(i) = s(i) + D(i)/D(j);
101     end
102     mu(i,k) = 1/(s(i)^(2/(x - 1)));
103     end
104
105     %% Pesos %Fuzzy control systems design and analysis: a linear matrix
inequality approach
106     for j=1:Re
107         w(j) = prod(mu(j,k), 'all'); %2.7
108     end
109
110     for i=1:Re
111         h(i,k) = w(i)/(w(1) + w(2) + w(3)); %2.7
112     end
113
114     %% Sistema
115     A = A1*h(1,k) + A2*h(2,k) + A3*h(3,k);
116     B = B1*h(1,k) + B2*h(2,k) + B3*h(3,k);
117
118     %% Defuzificación
119     suma = 0;
120     aprox = 0;
121     for i=1:Re
122         for e=1:2
123             suma = suma + h(i,k)*(A(e,:) * [Xg(k-2); Xg(k-1)] + B(e) * Ue(k);
124             aprox = aprox + h(i,k);
125         end
126     end
127
128     Xg(k) = suma/aprox;
129
130
131 end
132
133 %% RMS
134 e = Voltaje' - Xg;
135 rms = sqrt(mean(e.^2));

```

```

136
137 %% Función de costo
138 z = rms;
139 end
    
```

Listing 3: Función Objetivo del parametro difuso optimo.

```

1 clc
2 clear all
3 close all
4
5 %% Problem definition
6 %cost function defined
7 CostFunction = @(x) error_rms_m(x);
8 %number of unknown variables
9 nVar = 1;
10 %matrix size of decision variables
11 VarSize = [1,nVar];
12 %lower bound of decision variables
13 VarMin = 1.1;
14 %upper bound of decision variables
15 VarMax = 3;
16
17 %% Parameters of PSO
18 % Clerc and Kennedy 2002
19 Kappa = 1; %0<=kappa<=1
20 phi1 = 6.5;
21 phi2 = 6.5;
22 Phi = phi1 + phi2; %>=4
23 xi = 2*Kappa/abs(2 - Phi -sqrt(Phi^2 - 4*Phi));
24
25 MaxIt = 50; % Maximum Number of Iterations
26 nPop = 300; % Population Size (Swarm Size)
27 w = xi; % Inertia Coefficient 0.9 1
28 wdamp = 1; % Damping Ratio of Inertia Coefficient
29 c1 = xi*phi1; % Personal Acceleration Coefficient
30 c2 = xi*phi2; % Social Acceleration Coefficient
31 ShowIterInfo = true; % Flag for Showing Iteration Informatin
32
33 MaxVelocity = 0.2*(VarMax - VarMin);
    
```

```

34 MinVelocity = -MaxVelocity;
35
36 %% Initialization
37 %creating a template for the particles
38 empty_particle.Position = gpuArray([]);
39 empty_particle.Velocity = gpuArray([]);
40 empty_particle.Cost = gpuArray([]);
41 empty_particle.Best.Position = gpuArray([]);
42 empty_particle.Best.Cost = gpuArray([]);
43
44 %creating a population array
45 particle = repmat(empty_particle,nPop,1);
46
47 %creating a global best for refernce
48 GlobalBest.Cost = inf;
49
50 %initialize population members
51 for i=1:nPop
52     %Generate random solution
53     particle(i).Position = unifrnd(VarMin,VarMax,VarSize);
54
55     %initialize velocity
56     particle(i).Velocity = zeros(VarSize);
57
58     %Evaluation
59     particle(i).Cost = CostFunction(particle(i).Position);
60
61     %update the personal cost
62     particle(i).Best.Position = particle(i).Position;
63     particle(i).Best.Cost = particle(i).Cost;
64
65     %update the global best
66     if particle(i).Best.Cost<GlobalBest.Cost
67         GlobalBest = particle(i).Best;
68     end
69 end
70 %array to hold best costs at each step
71 BestCosts = zeros(MaxIt,1);
72

```

```
73 %% Main Loop of PSO
74 for it=1:MaxIt
75     for i=1:nPop
76         %update velocity
77         particle(i).Velocity = w*particle(i).Velocity...
78             + c1*rand(VarSize).*(particle(i).Best.Position - particle(i).
79             Position)...
80             + c2*rand(VarSize).*(GlobalBest.Position - particle(i).
81             Position);
82
83         %update position
84         particle(i).Position = particle(i).Position + particle(i).
85             Velocity;
86
87         %evaluation
88         particle(i).Cost = CostFunction(particle(i).Position);
89
90         % plot (particle(i).Best.Position)
91         % hold on
92
93         %update personal best
94         if particle(i).Cost < particle(i).Best.Cost
95             particle(i).Best.Position = particle(i).Position;
96             particle(i).Best.Cost = particle(i).Cost;
97
98         %update global best
99         if particle(i).Best.Cost < GlobalBest.Cost
100             GlobalBest = particle(i).Best;
101         end
102     end
103
104     x(i) = particle(i).Best.Position(1);
105     g(i) = particle(i).Best.Cost;
106 end
107
108 %store the best cost value
109 BestCosts(it) = GlobalBest.Cost;
110 disp(['Iterations' num2str(it) ' BestCost--' num2str(BestCosts(it))])
111 w = w*wdamp;
112 % [globalmin,index] = min(BestCosts);
```

```

109
110 %     %the best position value
111     BestPosition(it) = GlobalBest.Position;
112     disp(['Iterations' num2str(it) 'BestPosition--' num2str(BestCosts(it)
113         )])
114
115
116     pause(.09)
117
118     % this is for one variable examples (sinfunc)
119         %plot(x,g,'*')
120         plot(it,particle(i).Best.Cost,'*')
121         xlabel('Fuzzy Parameter');
122         ylabel('RMS');
123         %axis([VarMin VarMax -2 2])
124         hold on
125
126
127     end
128
129 %% Results
130 figure(2);
131 plot(BestCosts,'LineWidth',2)
132 xlabel('Iteratsions');
133 ylabel('Best Cost');
134 grid on;
135
136 figure(3);
137 plot(BestPosition,'LineWidth',2)
138 xlabel('Iteratsions');
139 ylabel('Position');
140 grid on;
    
```

Listing 4: Algoritmo PSO del parametro difuso optimo.

```

1 function z= error_rms_polos(x)
2
3 %% Datos adquiridos de labview
4 load('datos_adquiridos_pwm_voltaje_carga_para_la_identificacion.mat')
    
```

```
5
6 %% Parámetros de simulación
7 Ti = 0; T = 0.1; Tf = 500;
8 t = [Ti:T:Tf]; %Tiempo
9 lt = length(t);
10
11 %% Datos
12 X = [PWM Voltaje];
13 n = 301; %Número total de datos
14
15 %% Entrada del sistema
16 Ue = X(:,1);
17
18 %% Salida del sistema
19 Y = X(:,2);
20
21 %% Matriz de regresion
22 for k=2:n
23     Ue(k) = X(k-1,1);
24     x1(k) = X(k-1,2);
25 end
26
27 for k=3:n
28     x2(k) = X(k-2,2);
29 end
30
31
32 Z = [x2' x1' Ue];
33
34 %% Influencia del grado de pertenecia
35 m = 2.9694; %rms=2.0365%1.9967;
36
37 %% Número de reglas y clusters
38 Re = 4;
39 it = 100; %número de iteraciones difuso
40 me = 1e-5; %minimo error de convergencia de c-means
41 verbose = false;
42
43 %% Condiciones iniciales
```

```
44 u1(1) = 0;
45 u2(1) = 0;
46 u3(1) = 0;
47 u4(1) = 0;
48
49 u1(2) = 0;
50 u2(2) = 0;
51 u3(2) = 0;
52 u4(2) = 0;
53
54 u(1) = 0;
55 u(2) = 0;
56
57 zz(1,:) = [0 0 0];
58 zz(2,:) = [0 0 0];
59 zz(3,:) = [0 0 0];
60
61 error(1) = 0;
62 error(2) = 0;
63 error(3) = 0;
64
65 ref(1) = 0;
66 ref(2) = 0;
67 ref(3) = 0;
68
69 Xg(1) = 0;
70 Xg(2) = 0;
71 Xg(3) = 0;
72
73
74
75 %% Fuzzy c-means tercer orden (4 clusters)
76 options = fcmOptions(NumClusters=Re, Exponent=m, MaxNumIteration=it,
    MinImprovement=me, Verbose=verbose);
77 [centers,U] = fcm(Z,options);
78
79 %% Se calculan los parametros consecuentes lineales (Least-squares
    estimation of consequents
80 for i=1:Re
```

```

81     theta(i,:) = ((Z'*diag(U(i,:))*Z)^-1)*Z'*diag(U(i,:))*Y; %ecuación 38
        Fuzzy Systems, Modeling and Identification
82 end
83
84
85 %% Sistema
86
87 A1 = [0 1; theta(1,1) theta(1,2)];
88 B1 = [0;theta(1,3)];
89
90 A2 = [0 1; theta(2,1) theta(2,2)];
91 B2 = [0;theta(2,3)];
92
93 A3 = [0 1; theta(3,1) theta(3,2)];
94 B3 = [0;theta(3,3)];
95
96 A4 = [0 1; theta(4,1) theta(4,2)];
97 B4 = [0;theta(4,3)];
98
99
100 %% Polos PSO
101 P_D1 = [x(1) x(2)];
102 P_D2 = [x(3) x(4)];
103 P_D3 = [x(5) x(6)];
104 P_D4 = [x(7) x(8)];
105
106 %% Ganancias
107 %Sintonización de las ganancias del primer subsistema
108 L1 = poly(P_D1); %Polinomio característico P_D2
109 ran1 = rank(ctrb(A1,B1));
110 q1 = poly(A1); %Polinomio característico de A2
111 W1 = [q1(:,2) 1;
112        1 0];
113 Con1 = [B1 A1*B1]; %Matriz de Controlabilidad
114 T1 = Con1*W1;
115 K1 = [L1(:,3)-q1(:,3) L1(:,2)-q1(:,2)]*(T1^-1); %Ganancias del primer
        sistema
116
117 %Sintonización de las ganancias del segundo subsistema
    
```

```

118 L2 = poly(P_D2); %Polinomio característico P_D2
119 ran2 = rank(ctrb(A2,B2));
120 q2 = poly(A2); %Polinomio característico de A2
121 W2 = [q2(:,2) 1;
122       1 0];
123 Con2 = [B2 A2*B2]; %Matriz de Controlabilidad
124 T2 = Con2*W2;
125 K2 = [L2(:,3)-q2(:,3) L2(:,2)-q2(:,2)]*(T2^-1); %Ganancias del segundo
        sistema
126
127 %Sintonización de las ganancias del tercer subsistema
128 L3 = poly(P_D3); %Polinomio característico P_D3
129 ran3 = rank(ctrb(A3,B3));
130 q3 = poly(A3); %Polinomio característico de A3
131 W3 = [q3(:,2) 1;
132       1 0];
133 Con3 = [B3 A3*B3]; %Matriz de Controlabilidad
134 T3 = Con3*W3;
135 K3 = [L3(:,3)-q3(:,3) L3(:,2)-q3(:,2)]*(T3^-1); %Ganancias del tercer
        sistema
136
137 %Sintonización de las ganancias del cuarto subsistema
138 L4 = poly(P_D4); %Polinomio característico P_D4
139 ran4 = rank(ctrb(A4,B4));
140 q4 = poly(A4); %Polinomio característico de A4
141 W4 = [q4(:,2) 1;
142       1 0];
143 Con4 = [B4 A4*B4]; %Matriz de Controlabilidad
144 T4 = Con4*W4;
145 K4 = [L4(:,3)-q4(:,3) L4(:,2)-q4(:,2)]*(T4^-1); %Ganancias del cuarto
        sistema
146
147 %%
148 for k=3:n
149
150     ref(k) = 40;
151     error(k) = ref(k) - Xg(k-2);
152
153     %% Vector de cada instante
    
```

```

154     zz(k,:) = [Xg(k-2) Xg(k-1) u(k-1)];
155
156     %% Grados de pertenencia
157     for i=1:Re
158         %Suma de distancias euclidianas
159         %D(i) = sqrt((zz(k,:) - centers(i,:)) * (zz(k,:) - centers(i,:))
160         ');
161         D(i) = norm(zz(k,:) - centers(i,:));
162     end
163
164     for i=1:Re
165         s(i) = 0;
166         for j=1:Re
167             s(i) = s(i) + D(i)/D(j);
168         end
169         mu(i,k) = 1/(s(i)^(2/(m - 1)));
170     end
171
172     %% Pesos %Fuzzy control systems design and analysis: a linear matrix
173     inequality approach
174     for j=1:Re
175         w(j) = prod(mu(j,k), 'all'); %2.7
176     end
177
178     for i=1:Re
179         h(i,k) = w(i)/(w(1) + w(2) + w(3) + w(4)); %2.7
180     end
181
182     %% Control (Discrete-Time Parallel Distributed Pole Placement)
183     u1(k) = -(K1*h(1,k)) * [error(k); Xg(k-1)];
184     u2(k) = -(K2*h(2,k)) * [error(k); Xg(k-1)];
185     u3(k) = -(K3*h(3,k)) * [error(k); Xg(k-1)];
186     u4(k) = -(K4*h(4,k)) * [error(k); Xg(k-1)];
187
188     u(k) = u1(k) + u2(k) + u3(k) + u4(k);
189
190     if u(k)>1
191         u(k) = 1;
192     end

```

```

191
192     if u(k) < 0
193         u(k) = 0;
194     end
195
196     %% Sistema
197     A = A1*h(1,k) + A2*h(2,k) + A3*h(3,k) + A4*h(4,k);
198     B = B1*h(1,k) + B2*h(2,k) + B3*h(3,k) + B4*h(4,k);
199
200     %% Defuzificación
201     suma = 0;
202     aprox = 0;
203     for i=1:
204         for e=1:2
205             suma = suma + h(i,k)*(A(e,:)*[Xg(k-2);Xg(k-1)] + B(e)*u(k));
206             %2.3
207             aprox = aprox + h(i,k);
208         end
209     end
210     Xg(k) = suma/aprox;
211
212 end
213
214 %% RMS
215 e = ref - Xg;
216 rms = sqrt(mean(e.^2));
217
218 %% Función de costo
219 z = rms;
220 end
    
```

Listing 5: Función Objetivo para polos optimos del sistema.

```

1 clc
2 clear all
3 close all
4
5 %% Problem Definiton
6 CostFunction1 = @(x) error_rms_polos(x);
    
```

```

7 nVar1 = 8;           % Number of Unknown (Decision) Variables for
    error_rms_polos
8 %matrix size of decision variables
9 VarSize1 = [1,nVar1];
10 VarMin1 = [0.01 0.01 0.01 0.01 0.01 0.01 0.01 0.01]; % Lower Bound of
    Decision Variables for error_rms_polos
11 VarMax1 = [0.9 0.9 0.9 0.9 0.9 0.9 0.9 0.9]; % Upper Bound of Decision
    Variables for error_rms_polos
12
13 %% Parameters of PSO
14 % Clerc and Kennedy 2002
15 Kappa1 = 1; %0<=kappa<=1
16 phi1 = 2.5; %9.5
17 phi2 = 2.5; %9.5
18 Phil = phi1 + phi2; %>=4
19 xil = 2*Kappa1/abs(2 - Phil - sqrt(Phil^2 - 4*Phil));
20
21 MaxIt1 = 50;       % Maximum Number of Iterations
22 nPop1 = 300;      % Population Size (Swarm Size)
23 w1 = xil;         % Intertia Coefficient
24 wdamp1 = 1;      % Damping Ratio of Inertia Coefficient
25 c3 = xil*phi1;    % Personal Acceleration Coefficient
26 c4 = xil*phi2;    % Social Acceleration Coefficient
27 ShowIterInfo = true; % Flag for Showing Iteration Informatin
28 p = 8;
29
30 MaxVelocity1 = 0.2*(VarMax1 - VarMin1);
31 MinVelocity1 = -MaxVelocity1;
32
33 %% Initialization
34 %creating a template for the particles
35 empty_particle1.Position = gpuArray([]);
36 empty_particle1.Velocity = gpuArray([]);
37 empty_particle1.Cost = gpuArray([]);
38 empty_particle1.Best.Position = gpuArray([]);
39 empty_particle1.Best.Cost = gpuArray([]);
40
41 % Create Population Array
42 particle1 = repmat(empty_particle1,nPop1,1);
    
```

```

43
44 % Initialize Global Best
45 GlobalBest1.Cost = inf;
46
47 % Initialize Population Members
48 for i=1:nPop1
49     for f=1:p
50         % Generate Random Solution
51         particle1(i,f).Position = unifrnd(VarMin1(f),VarMax1(f),
VarSize1);
52
53         % Initialize Velocity
54         particle1(i,f).Velocity = zeros(VarSize1);
55
56         % Evaluation
57         particle1(i,f).Cost = CostFunction1(particle1(i,f).Position);
58
59         % Update the Personal Best
60         particle1(i,f).Best.Position = particle1(i,f).Position;
61         particle1(i,f).Best.Cost = particle1(i,f).Cost;
62
63         % Update Global Best
64         if particle1(i,f).Best.Cost < GlobalBest1.Cost
65             GlobalBest1 = particle1(i,f).Best;
66         end
67     end
68 end
69
70 % Array to Hold Best Cost Value on Each Iteration
71 BestCosts1 = zeros(MaxIt1,1);
72
73
74 %% Main Loop of PSO
75 for it=1:MaxIt1
76     for i=1:nPop1
77         for f=1:p
78             % Update Velocity
79             particle1(i,f).Velocity = w1*particle1(i,f).Velocity ...
80             + c3*rand(VarSize1).*(particle1(i,f).Best.Position -

```

```
particle1(i,f).Position) ...
81         + c4*rand(VarSize1).*(GlobalBest1.Position - particle1(i,
      f).Position);
82
83         % Apply Velocity Limits
84         particle1(i,f).Velocity = max(particle1(i,f).Velocity,
      MinVelocity1(f));
85         particle1(i,f).Velocity = min(particle1(i,f).Velocity,
      MaxVelocity1(f));
86
87         % Update Position
88         particle1(i,f).Position = particle1(i,f).Position +
      particle1(i,f).Velocity;
89
90         % Apply Lower and Upper Bound Limits
91         particle1(i,f).Position = max(particle1(i,f).Position,
      VarMin1(f));
92         particle1(i,f).Position = min(particle1(i,f).Position,
      VarMax1(f));
93
94         % Evaluation
95         particle1(i,f).Cost = CostFunction1(particle1(i,f).
      Position);
96
97         % Update Personal Best
98         if particle1(i,f).Cost < particle1(i,f).Best.Cost
99             particle1(i,f).Best.Position = particle1(i,f).
      Position;
100             particle1(i,f).Best.Cost = particle1(i,f).Cost;
101
102         % Update Global Best
103         if particle1(i,f).Best.Cost < GlobalBest1.Cost
104             GlobalBest1 = particle1(i,f).Best;
105         end
106         end
107
108     end
109 end
110
```

```

111     % Store the Best Cost Value
112     BestCosts1(it) = GlobalBest1.Cost;
113
114     % Display Iteration Information
115     if ShowIterInfo
116         disp(['Iteration ' num2str(it) ': Best Cost = ' num2str(
BestCosts1(it))]);
117     end
118
119     % Damping Inertia Coefficient
120     w1 = w1*wdamp1;
121
122     pause(.09)
123
124     figure(7)
125     plot(it,particle1(i).Best.Cost,'*')
126     hold on %rms 17.8889 17.5368
127 end
128
129 %% Results
130 figure(8);
131 plot(BestCosts1,'LineWidth',2)
132 xlabel('Iterations');
133 ylabel('Best Cost');
134 grid on;

```

Listing 6: Algoritmo PSO para los polos optimos del sistema.