



UNIVERSIDAD AUTÓNOMA DEL ESTADO DE MÉXICO
UNIDAD ACADÉMICA PROFESIONAL TIANGUISTENCO

“Modelado híbrido basado en un sistema adaptativo de inferencia neuro difuso para un proceso de manufactura no convencional PECM”

T E S I S

Que para obtener el Grado Académico de:
Doctorado en Ciencias de la Computación

Presenta:

Irvin Uriel Nopalera Angeles

Director de Tesis:

Dr. Everardo Efrén Granda Gutiérrez

Tutores adjuntos:

Dr. René Arnulfo García Hernández

Dr. Ángel Hernández Castañeda

Abril de 2025

Resumen

El modelado de procesos es una representación formal y estructurada, considerada en el ámbito industrial como una práctica fundamental ya que facilita comprender de manera detallada el comportamiento, configuración y especificaciones de un procedimiento; permitiendo estandarizar, diseñar y planificar los recursos necesarios para su correcta reproducibilidad, investigación y optimización.

En este orden de ideas, existe un proceso de manufactura denominado maquinado electroquímico por pulsos, el cual es un método de manufactura moderna que permite fabricar herramientas en una escala micrométrica de manera indirecta empleando el proceso de electrólisis. Este método está conformado por múltiples variables, procesos eléctricos y fenómenos químicos, que lo convierten en un método de gran complejidad. Derivado de lo anterior, es un proceso constantemente estudiado para tratar de comprender el principio que gobierna su comportamiento en variables clave como el sobre corte y la tasa de remoción de material. Para ello, se parte del análisis del conjunto de variables que lo componen, debido a que estas representan la esencia misma de las respuestas del proceso de manufactura.

En este contexto, se desarrolló un sistema adaptativo de inferencia neuro difuso, optimizado con un algoritmo genético, para modelar las variables de respuesta del maquinado electroquímico por pulsos. Durante este proceso fue integrado un conjunto de datos del método de manufactura mediante un diseño experimental factorial 3^k , el cual fue dividido en subconjuntos para las etapas de entrenamiento, validación y prueba. La arquitectura del sistema adaptativo propuesto se seleccionó tras analizar el rendimiento con diferentes sistemas de inferencia y una serie de funciones difusas. Después de la evaluación, el sistema Takagi-Sugeno y funciones de membresía de tipo gaussiana fueron seleccionadas para la arquitectura de trabajo.

Como resultado de una aproximación experimental, el modelo neuro difuso optimizado alcanzó un rendimiento con un coeficiente de determinación R^2 de 0.94 para el sobre corte y uno de 0.92 para la tasa de remoción de material. Por otro lado, un valor del error cuadrático medio de 0.301 y 0.328 fue obtenido respectivamente. Estos resultados

evidenciaron una mejora significativa del modelo optimizado en comparación con los resultados previos obtenidos mediante un entrenamiento convencional basado en el descenso del gradiente. Por ello, se determinó que la complejidad del proceso de manufactura presenta desafíos tanto para los enfoques matemáticos como para los métodos de cómputo inteligente. Sin embargo, las técnicas de optimización evolutiva demostraron ser un complemento eficaz para capturar la variabilidad de los datos en el proceso de manufactura. Finalmente, esta variabilidad se analizó a través de la dispersión de las predicciones, el error de los residuos y la identificación de la homocedasticidad en la varianza.

Palabras clave: Modelo, maquinado electroquímico, ANFIS, algoritmo genético.

Abstract

Process modeling is a formal and structured representation, recognized as a fundamental practice in the industrial field, as it facilitates a detailed understanding of a process's behavior, configuration, and specifications. It enables the standardization, design, and planning of the necessary resources to ensure its accurate reproduction, analysis, and optimization.

In this context, pulsed electrochemical machining is identified as a modern manufacturing method that enables the indirect production of tools at a micrometric scale through the process of electrolysis. This method is characterized by its high complexity, as it involves multiple variables, electrical processes, and chemical phenomena. Consequently, it has been the subject of extensive study to elucidate the principles governing its behavior in key variables, such as overcut and material removal rate. Accordingly, the analysis focuses on the set of variables that constitute the process, as these represent the fundamental essence of the manufacturing process responses.

In this context, an adaptive neuro-fuzzy inference system, optimized with a genetic algorithm, was developed to model the response variables of pulsed electrochemical machining. During this process, a dataset derived from the manufacturing method was integrated through a 3^k factorial experimental design, which was divided into subsets for training, validation, and testing stages. Furthermore, the proposed adaptive system architecture was selected after analyzing the performance with different inference systems and a set of fuzzy functions. After evaluation, the Takagi-Sugeno system and Gaussian-type membership functions were selected for the working architecture..

As a result of an experimental approach, the optimized neuro fuzzy model achieved a performance with a coefficient of determination R^2 of 0.94 for overcut and 0.92 for the material removal rate. Furthermore, mean squared error (MSE) values of 0.301 and 0.328 were obtained, respectively. These findings highlight a significant improvement in the performance of the optimized model compared to the results derived from conventional training based on gradient descent. Accordingly, it was concluded that the inherent complexity of the manufacturing process presents substantial challenges for both

mathematical approaches and intelligent computing methodologies. However, evolutionary optimization techniques proved to be a robust and effective strategy for capturing the variability within the manufacturing process data. This variability was further examined through an analysis of prediction dispersion, residual errors, and the identification of homoscedasticity in variance.

Keywords: Model, electrochemical machining, ANFIS, genetic algorithm.

Productos académicos

Nopalera, I. U., Hernández, Á., Granda, E. E., García Hernández, R. A., & Ledeneva, Y. N. 2023. Pandemia y Tecnología: Un enfoque de la Inteligencia Artificial para la predicción de casos letales de COVID-19. *Komputer Sapiens*. Vol. 1. Pp. 45-49.

Nopalera, I. U., Granda, E. E., Hernández, Á., Hernández, R. A., 2023. Control inteligente en la industria 4.0: aplicación en el maquinado electroquímico por pulsos. *Avances en Ciencia de Frontera y Tecnología de Vanguardia en América Latina*. Amat. Primer Edición. Mexico. pp.161-164.

Nopalera, I. U., Granda, E. E., García, R. A., Hernández, Á., & García, J. F. 2022. Evolutionary Tuning of a Fuzzy Controller for Electrolyte Flow Regulation in a Pulsed Electrochemical Machining Process. *Research in Computing Science*. Vol. 151 (12). pp. 7-16.

Nopalera, I., Granda, E., Alejo, R., García, R., Hernández, Á. 2024. Non-conventional micromachining control based on multivariable parameter analysis using a fuzzy inference system. *DYNA*, vol. 99, no. 3, p. 289-295. DOI: <https://doi.org/10.6036/11044>.

Genetic algorithm for the optimization of an electrolyte flow controller in a non-conventional manufacturing method. *CIENCIA ergo-sum*. [Aceptado]

Índice

CAPÍTULO 1. INTRODUCCIÓN.....	12
1.1 Antecedentes	12
1.2 Planteamiento del problema.....	14
1.3 Objetivos de la investigación	14
1.4 Hipótesis.....	15
1.5 Pregunta(s) de investigación	15
1.6 Justificación.....	16
1.7 Impactos	16
CAPÍTULO 2. MARCO CONCEPTUAL	17
2.1 Maquinado electroquímico por pulsos.....	17
2.2 Lógica difusa.....	19
2.2.1 Conjuntos difusos.....	20
2.2.2 Normas Triangulares	22
2.2.3 Funciones de agregación	23
2.2.4 Sistema de inferencia Takagi-Sugeno	24
2.2.5 Sistema de Inferencia Mamdani	25
2.2.6 Métodos de defusificación	26
2.3 Redes neuronales Artificiales.....	27
2.4 Aprendizaje Supervisado	28
2.5 Sistema Adaptativo de Inferencia Neuro Difuso	29
CAPÍTULO 3. ESTADO DEL ARTE	32
3.1 Discusión del estado del arte.....	40
CAPÍTULO 4. METODOLOGÍA	42
4.1 Proceso de integración del conjunto de datos de PECM	42

4.1.1 Diseño experimental factorial 3k.....	44
4.2 Depuración del conjunto de datos	47
4.3 Análisis de correlación.....	47
4.4 Normalización de datos.....	48
4.5 Sistema adaptativo de inferencia neuro difuso basado en el método Takagi-Sugeno	49
4.5.1 Entrenamiento supervisado del modelo ANFIS.....	52
4.6 Sistema adaptativo de inferencia neuro difuso basado en el método Mamdani	55
4.7 Selección del método de inferencia y parámetros iniciales del modelo neuro difuso	56
4.8 Optimización genética del modelo ANFIS	57
CAPÍTULO 5. DISCUSIÓN Y RESULTADOS	61
5.1 Conjunto de datos del modelo PECM.....	61
5.2 Desempeño del modelo ANFIS: Evaluación de sistemas de inferencia y funciones de membresía	65
5.3 Modelo preliminar ANFIS-TS del proceso de maquinado electroquímico por pulsos (PECM)	67
5.4 Resultados de la optimización genética del modelo ANFIS	69
5.5 Análisis del rendimiento del modelo ANFIS-GA del proceso de manufactura PECM	72
CAPÍTULO 6. CONCLUSIONES Y TRABAJO A FUTURO	84
Referencias.....	88

ÍNDICE DE TABLAS

Tabla 4.1. Parámetros empleados en el diseño experimental factorial $3k$ de PECM.	45
Tabla 5.1 Resumen general del diseño experimental para la recopilación de datos.	61
Tabla 5.2. Coeficientes de cambio y valores de significancia estadística generados con una regresión múltiple de los datos del proceso PECM.	64
Tabla 5.3. Parámetros utilizados en la arquitectura inicial del modelo ANFIS.	68
Tabla 5.4. Parámetros de las funciones de membresía extraídos del modelo ANFIS, entrenado mediante métodos convencionales y que conforman el cromosoma número 100 de la población inicial del algoritmo de optimización.	70
Tabla 5.5. Parámetros de las funciones de membresía obtenidos en la optimización.	72
Tabla 5.6. Rendimiento general del coeficiente de determinación (R^2) y el error RMSE del modelo ANFIS y ANFIS-GA con el conjunto de datos de entrenamiento (validación cruzada) y prueba	75
Tabla 5.7. Resultados de mayor relevancia en el modelado de procesos no convencionales en el estado del arte y en la presente investigación.	82

Índice de figuras

Figura 2.1. Diagrama del principio básico de los elementos del proceso de maquinado electroquímico por pulsos (fuente de elaboración propia).....	19
Figura 2.2. Diagrama a bloques de un modelo basado en lógica difusa.	21
Figura 2.3. Diagrama a bloques de un modelo difuso utilizando un sistema de inferencia Mamdani (Madhumangal, et al., 2020).....	26
Figura 2.4. Diagrama a bloques del proceso de modelado empleado un motor de inferencia Takagi-Sugeno (Lendek, et al., 2011).....	26
Figura 2.5. Representación de un modelo basado en redes neuronales artificiales.	29
Figura 2.6. Estructura de ANFIS con dos entradas y una salida (Han, et al., 2010).....	30
Figura 4.1. Diagrama de los elementos que conforman el (A) Sistema mecánico y sistema de regulación de electrolito y (B) Sistema de monitoreo, control y procesamiento del prototipo de maquinado electroquímico por pulsos.	44
Figura 4.2. (A) Sistemas del prototipo de manufactura PECM empleados en el diseño experimental factorial $3k$ y (B) principio del desgaste de material realizado en cada experimento.....	46
Figura 4.3. Diagrama del modelo ANFIS Takagi-Sugeno empleado para el proceso PECM (Jang, et al., 1997).	50
Figura 4.4. Diagrama de flujo del proceso de entrenamiento del modelo ANFIS.....	55
Figura 4.5. Diagrama del entrenamiento de ANFIS utilizando un sistema Mamdani.	56
Figura 4.6. Diagrama de flujo del proceso de optimización realizado con el algoritmo genético y ANFIS.....	60
Figura 5.1. Gráficas de caja y bigotes para observar los datos atípicos identificados por el criterio de rango intercuartil en el (A) Sobre corte y (B) Tasa de remoción de material.....	62
Figura 5.2. Diagrama de calor con la correlación Spearman entre variables del conjunto de datos del proceso PECM.	63
Figura 5.3. Lote de datos normalizados de la variable de tasa de remoción de material.....	64
Figura 5. 4. Lote de datos normalizados de la variable de sobre corte.	65
Figura 5.5. Promedio del error cuadrático medio al evaluar diferentes funciones en el modelo ANFIS (A) Takagi-Sugeno y (B) Mamdani.	66

Figura 5.6. Errores RMSE del modelo inicial de ANFIS entrenado mediante métodos convencionales basados en el descenso del gradiente.....	68
Figura 5.7. Coeficientes de determinación (R^2) en la etapa de validación y prueba del modelo inicial de ANFIS entrenado con métodos convencionales basados en el descenso del gradiente.	69
Figura 5.8. Gráfica de convergencia del algoritmo genético utilizado para optimizar las funciones de membresía del modelo ANFIS.	71
Figura 5.9. Coeficientes de determinación (R^2) en la etapa de validación y prueba del modelo ANFIS optimizado con el algoritmo genético.	72
Figura 5.10. Funciones de membresía optimizadas para la evaluación de la variable de corriente en el modelo ANFIS-GA.	73
Figura 5.11. Funciones de membresía optimizadas para la evaluación del voltaje en el modelo ANFIS-GA.	73
Figura 5.12. Funciones de membresía optimizadas para la evaluación del gap en el modelo ANFIS-GA.	74
Figura 5.13. Funciones de membresía optimizadas para la evaluación del área de exposición en el modelo ANFIS-GA.	74
Figura 5.14. Errores RMSE del modelo ANFIS optimizado con el algoritmo genético.	75
Figura 5.15. Gráfico de ajustes de las predicciones y las observaciones normalizadas para la variable de sobre corte (OC).	76
Figura 5.16. Gráfico de ajustes de las predicciones y las observaciones normalizadas para la variable de tasa de remoción de material (MRR).....	76
Figura 5.17. Comportamiento de los datos de prueba y las predicciones del modelo ANFIS-GA para la variable de sobre corte.	77
Figura 5.18. Comportamiento de los datos de prueba y las predicciones del modelo ANFIS-GA para la variable de la tasa de remoción de material.	78
Figura 5.19. Gráfica de residuos del sobre corte.....	79
Figura 5.20. Gráfico de residuos de la tasa de remoción de material.	80
Figura 5.21. Coeficiente de determinación (R^2) obtenido con una red neuronal profunda (RNN), una máquina de soporte vectorial (SVM), un modelo de regresión no lineal (NLR) y el modelo ANFIS-GA.	81



CAPÍTULO 1.

INTRODUCCIÓN

1.1 Antecedentes

Como resultado de la continua evolución de la industria, múltiples estrategias han sido adoptadas en el campo de la manufactura moderna para mejorar los métodos de fabricación de piezas metálicas, permitiendo reducir los recursos necesarios para el diseño, transformación y producción de este tipo de materia prima. Partiendo de este contexto, se destaca el proceso de manufactura no convencional conocido como maquinado electroquímico por pulsos (PECM, por las siglas en inglés de *Pulsed Electrochemical Machining*). A diferencia de las técnicas convencionales, que desgastan el material mediante la energía transferida por la fricción entre una herramienta y la pieza de trabajo, PECM permite eliminar el metal de manera indirecta, sin contacto físico entre los materiales, a través de un proceso de disolución anódica. El fenómeno de disolución se desarrolla por medio del flujo de corriente eléctrica entre la herramienta y la pieza de trabajo, al estar expuestos a un electrolito y una fuente de polarización en forma de pulsos eléctricos, estableciendo de esta manera el principio del proceso de manufactura PECM (Groover, 2010; Kats & Tibbles, 2005).

Este método involucra un conjunto de variables que permiten el desgaste de metal de manera controlada. Parámetros como voltaje, corriente, distancia inter-electrodos (*gap*, por su nombre en inglés), frecuencia y área de exposición, forman parte de las variables que contribuyen en gran medida a delimitar las características resultantes de la disolución de material. Por otro lado, la tasa de remoción de material (MRR, por las siglas en inglés de *Material Removal Rate*) y el sobre corte (OC, por las siglas en inglés de *Over Cutting*),

son establecidas como las características finales que son analizadas como criterio de calidad en esta estrategia no convencional (Abdel & El-Hofy, 2005; Feng, et al., 2016).

Asimismo, PECM se caracteriza por conformarse por múltiples variables, fenómenos químicos y cambios continuos originados por el gradual desgaste de material (Zaytzev, et al., 2004). Por esta razón, presenta características de un comportamiento no lineal, siendo incapaz de ser expresado mediante la descripción de los efectos independientes originados por sus entradas, delimitado bajo el principio de superposición (Adam, 2020). Este principio no es aplicable, de acuerdo con Adam (2020), en sistemas caóticos, fisicoquímicos o naturales, debido a que limitan o imposibilitan la descripción de su comportamiento mediante la suma de sus conductas descriptivas. Por otro lado, Liu (2008) atribuye este comportamiento a los procesos de manufactura, puesto que presentan características como mala estructuración, cambios en las condiciones de trabajo, fallas operacionales aleatorias o ambigüedad en la información cuantificada.

A partir de lo expuesto, se han desarrollado diversas iniciativas orientadas a la modelación de este tipo de procesos de manufactura, destacándose aquellas fundamentadas en el uso de inteligencia artificial. En este sentido, investigaciones como las de Alvarado et al. (2018), Munasypov et al. (2017), Wen et al. (2012), Chuang et al. (2023) y Ji & Mi (2022) han realizado aportaciones significativas al proponer la representación de procesos no convencionales mediante redes neuronales. Dicho enfoque permite establecer la correlación entre las características de un conjunto de variables iniciales y un conjunto de variables de salida, contribuyendo así a una mejor comprensión y optimización de estos procesos. Sin embargo, también se han propuesto modelos algebraicos, que a partir de ecuaciones matemáticas describen las propiedades eléctricas para generar un modelo representativo (Kozak, 1998) (Klocke, et al., 2018).

Adicionalmente, en el contexto de la implementación de técnicas derivadas del cómputo suave (*soft-computing*, por su origen del inglés), estudios como los de Rama et al. (2009), Labid et al. (2011) y Chakraborty y Das (2019) han adoptado enfoques basados en la teoría de conjuntos, aplicando la lógica difusa como método para modelar procesos de manufactura. Este enfoque permite mapear dichos procesos mediante la emulación del

razonamiento aproximado, el uso de reglas y un sistema de inferencia, lo que resulta particularmente útil para la representación de problemas no lineales.

Actualmente, la combinación de más de una técnica derivada de la inteligencia artificial ha permitido crear métodos híbridos que adoptan parte de diferentes estrategias para mejorar el modelado de problemas con comportamientos aleatorios y no lineales. Esta clase de contribuciones son observadas en (Chai, et al., 2009; Han, et al., 2010; Kennedy, et al., 2021; Gupta, et al., 2016; Pourasl, 2022), donde la combinación del aprendizaje proveniente de las redes neuronales artificiales y el sistema de inferencia difuso son adoptados para el modelado de problemas en el campo de la ingeniería. Dentro de estos problemas son destacadas aplicaciones de clasificación y predicción en problemas multivariantes, presentando un desempeño superior en contraste con aproximadores universales aplicados de manera independiente. En este sentido, con base en el principio de ambos métodos descritos anteriormente, se propone un Sistema Adaptativo de Inferencia Neuro Difuso (ANFIS, por las siglas en inglés de *Adaptive Neuro-Fuzzy Inference System*) como una alternativa para el modelado del proceso de manufactura PECM.

1.2 Planteamiento del problema

El maquinado electroquímico por pulsos es un método multivariable en el cual se observan fenómenos químico-eléctricos derivados del proceso de electrólisis, empleado para llevar a cabo la disolución de material. Estas características, y la complejidad del comportamiento no lineal identificado, dificultan la descripción algebraica del proceso de manufactura, generando un área de oportunidad para la implementación de estrategias computacionales con aplicaciones en problemas no lineales, aleatorios y ambiguos, como es el caso de dicho proceso de manufactura no convencional (Kozak, 1998; Kennedy, et al., 2021; McGeough 1974; Zaytzev et al. 2004; Klope et al. 2015).

1.3 Objetivos de la investigación

General

Desarrollar un modelo ANFIS optimizado con un algoritmo genético para predecir la tasa de remoción de material (MRR) y el sobre corte (OC), en función de las variables de configuración del proceso de maquinado electroquímico por pulsos (PECM)

Específicos

1. Integrar un conjunto de datos significativo del proceso de manufactura para el entrenamiento y prueba del modelo neuro difuso.
2. Analizar la correlación de las variables independientes y dependientes del proceso de maquinado electroquímico por pulsos.
3. Establecer el sistema de inferencia y funciones de membresía que mejor se adapten al problema de manufactura no convencional, empleando como indicador medidas de rendimiento de error y varianza.
4. Optimizar el desempeño de ANFIS mediante el uso de un algoritmo genético.
5. Evaluar el desempeño del modelo ANFIS mediante el análisis del error cuadrático medio y el coeficiente de determinación en la predicción de la tasa de remoción de material y el sobre corte.

1.4 Hipótesis

La implementación de un sistema adaptativo de inferencia neuro-difuso optimizado, permitirá describir con exactitud la relación entre la corriente de maquinado, el voltaje de polarización, el gap y el área de exposición respecto a la tasa de remoción de material y el sobre corte en el proceso de maquinado electroquímico por pulsos (PECM).

1.5 Pregunta(s) de investigación

- ¿Qué variables del proceso PECM presentan una relación significativa con el sobre corte y la tasa de remoción de material?
- ¿Qué estrategia utilizar para integrar el conjunto de datos del proceso de manufactura para el entrenamiento y validación del modelo?
- ¿Qué sistema de inferencia y tipo de funciones de membresía serán las más eficientes en el modelado de PECM?

- ¿Qué tipo de operadores debe tener el algoritmo genético para optimizar el modelado de PECM utilizando un sistema adaptativo de inferencia neuro difuso?
- ¿Cómo demostrar la eficacia del modelado de PECM mediante la implementación de un método neuro difuso?

1.6 Justificación

El modelado en la industria es una tarea fundamental, ya que permite describir el comportamiento de procedimientos, metodologías o procesos. Esto contribuye significativamente a anticipar y definir los requisitos necesarios para la producción de un producto final, destacando ventajas como la mejora en la productividad, reducción de pérdidas asociadas al desconocimiento o comprensión inexacta del proceso de manufactura (Klocke et al., 2018; MacGillivray, 2017). Asimismo, el PECM está compuesto por una gran cantidad de factores que dificultan el modelado convencional a través de representaciones algebraicas. Esto abre la posibilidad de abordar el problema de modelado utilizando algoritmos computacionales, los cuales ofrecen una solución viable para gestionar la complejidad inherente de estos procesos. En este sentido, partiendo de los alcances, ventajas y aplicaciones de las técnicas derivadas de la inteligencia artificial, se propone un sistema adaptativo de inferencia neuro difuso para el mapeo del comportamiento de PECM. La selección de este algoritmo se fundamenta en su naturaleza híbrida, que combina los principios del aprendizaje de las redes neuronales artificiales y los sistemas expertos basados en lógica difusa. Este enfoque es ideal para modelar sistemas complejos, típicamente no lineales, al permitir el mapeo desde un espacio de entrada a un espacio de salida (Han et al., 2010), utilizando un aprendizaje supervisado y una aproximación a través de reglas difusas.

1.7 Impactos

- Científico: Desarrollo de un modelo híbrido basado en redes neuronales artificiales, lógica difusa y algoritmos evolutivos para modelar el sobre corte y la tasa de remoción de material en un proceso de maquinado electroquímico por pulsos.

- Tecnológico: Contribución en la metodología para la manufactura de herramientas en escala micrométrica sobre metales de alta resistencia a través del maquinado electroquímico por pulsos.



CAPÍTULO 2.

MARCO

CONCEPTUAL

En el presente capítulo son descritos los fundamentos necesarios para la correcta interpretación y discusión de las estrategias empleadas en el modelado de procesos de manufactura moderna identificados en el estado del arte.

2.1 Maquinado electroquímico por pulsos

En el campo de la manufactura moderna existen métodos de eliminación de material empleados para el desgaste de piezas metálicas. Estas estrategias, a diferencia de las técnicas convencionales, mantienen una separación entre las herramientas empleadas (Younas, et al., 2017). Este es el caso del maquinado electroquímico por pulsos, el cual, mediante una polarización en forma de pulsos eléctricos, una solución conductora y un sistema de movilización, realiza el desgaste de material sobre piezas metálicas con propiedades conductoras al ser polarizadas en forma de ánodo-cátodo a una separación constante (*gap*) durante toda la ejecución del proceso (Groover, 2010). Estos fundamentos son descritos en la Figura 2. 1, donde se visualiza el diagrama con los elementos esenciales empleados en PECM.




Figura 2. 1. Diagrama del principio básico de los elementos del proceso de maquinado electroquímico por pulsos (fuente: Elaboración propia).

En este proceso de manufactura, se utilizan medidas cuantitativas para evaluar la productividad en función del material eliminado, destacando la tasa de remoción de material (MRR). Esta valoración se calcula considerando la ley de Faraday y los principios de la reacción electroquímica, lo que permite determinar la magnitud del parámetro del MRR a través de la ecuación (2. 1) (McGeough, 1974) (Feng et al., 2016).

$$MRR = \frac{V}{t} = C \frac{EA}{g\delta} \quad (2.1)$$

Donde:

V : Volumen desgastado [mm^3]	A : Área del electrodo [mm^2]
t : Tiempo [min]	g : Distancia inter-electrodos [mm]
E : Voltaje [V]	δ : Resistividad del electrolito [Ω]
C : Tasa de remoción específica de la pieza de trabajo [$\frac{\text{mm}^3}{\text{As}}$]	

Por otra parte, el sobre corte (OC) se define como un parámetro de calidad analizado en PECM, el cual describe la relación que existe entre las dimensiones del maquinado generado y las dimensiones del electrodo que hace la herramienta de trabajo. Esta medida

se utiliza para visualizar la magnitud del exceso de material eliminado en el producto generado, normalmente estimado mediante la ecuación (2. 2) (Elhami & Razfar, 2017).

$$OC = D_m - D_t \quad (2. 2)$$

Donde:

D_t : Son las dimensiones del maquinado final.

D_m : Son las dimensiones de la herramienta de trabajo.

Tal como se aprecia anteriormente, las variables que impactan en el MRR y el OC actúan de manera interdependiente, lo que implica un enorme esfuerzo para determinar la relación adecuada entre cada factor, y de esta manera establecer un equilibrio entre eficiencia, precisión y calidad de las piezas manufacturadas mediante este método (Bhattacharyya & Doloi, 2019) (Groover, 2010).

2.2 Lógica difusa

La lógica difusa, en relación con la inteligencia artificial, es una técnica derivada del *soft-computing* que se basa en la teoría de conjuntos para realizar la evaluación de datos reales mediante la asignación de grados de pertenencia a variables lingüísticas (Trillas & Eciolaza, 2015). Esta secuencia de procesamiento de datos evalúa información numérica y la convierte en un grado de pertenencia según una serie de conjuntos difusos, comúnmente denominada etapa de fuzzificación. Posteriormente, se genera una conclusión derivada de una base de conocimiento y la metodología establecida por un sistema de inferencia, generando un resultado de manera particular según el sistema empleado. No obstante, el principio que rige el mapeo de este método sin especificar el tipo de sistema de inferencia se visualiza mediante el diagrama a bloques de la Figura 2. 2 (Reyes & Torres, 2022).




Figura 2. 2. Diagrama a bloques de un modelo basado en lógica difusa (adaptado de Reyes & Torres (2022)).

2.2.1 Conjuntos difusos

Un conjunto de membresía en lógica difusa es una función matemática utilizada para representar la incertidumbre, imprecisión y vaguedad del mundo real. Estos conjuntos permiten asignar grados de pertenencia a sus elementos dentro de un dominio continuo entre 0 y 1. Sin embargo, con base en la nomenclatura descrita en Pekala (2019), es posible describir a un conjunto difuso según la definición 2.1.1.

Definición 2.1.1. Un conjunto difuso M para $X \neq \emptyset$ es descrito como un mapeo de $M: X \rightarrow [0 - 1]$. Donde $M(x)$ hace referencia a un grado de membresía del parámetro x dentro del conjunto M . En consecuencia, se denota como $FS(X)$ a la familia de todos los conjuntos sobre el universo X .

El grado de membresía descrito en la definición anterior se asocia a un parámetro *crisp* (valor real) según la terminología en inglés, que mapea la entrada según el conjunto empleado. En este sentido, la pertenencia resultante es influenciada según el tipo de función establecida en X . Algunos tipos de funciones de membresía empleados en lógica difusa son descritos a continuación (Pekala, 2019).

a) Triangular

$$Mf(x; a, b, c) = \begin{cases} 0, & \text{si } x \leq a, \\ \frac{x-a}{b-a}, & \text{si } a < x \leq b, \\ \frac{c-x}{c-b}, & \text{si } b < x \leq c, \\ 0 & \text{si } x > c \end{cases} \quad (2.3)$$

Donde:

$Mf(x)$ es el grado de pertenencia del valor x al conjunto difuso, a el valor que indica el comienzo de la pendiente de la función y valores no nulos, b el punto donde se alcanza el valor máximo del conjunto y c el valor donde la pendiente de la función tiende a 0.

b) Trapezoidal

$$Mf(x; a, b, c, d) = \begin{cases} 0, & \text{si } x \leq a, \\ \frac{x-a}{b-a}, & \text{si } a < x \leq b, \\ 1 & \text{si } b < x \leq c, \\ \frac{d-x}{d-c}, & \text{si } c < x \leq d, \\ 0 & \text{si } x > d \end{cases} \quad (2.4)$$

Donde:

$Mf(x)$ es el grado de pertenencia del valor x al conjunto difuso, a indica el inicio de la pendiente de la función ascendente, b el valor donde el conjunto alcanza la unidad, c el parámetro donde termina el punto máximo de la función e inicia la pendiente descendiente hacia 0 y d donde los valores de la función se hacen nulos.

c) Gaussiana

$$Mf(x; u, \sigma) = \exp^{-\frac{(x-u)^2}{2\sigma^2}} \quad (2.5)$$

Donde:

$Mf(x)$ es el grado de pertenencia del valor x al conjunto difuso, u indica el centro de la función y σ el valor de la desviación estándar de la función la cual delimita el ancho del conjunto.

d) Tipo Z

$$Mf(x; \alpha, b) = \left\{ \frac{1}{1 + e^{\alpha(x-b)}} \right\} \quad (2.6)$$

Donde:

$Mf(x)$ es el grado de pertenencia del valor x al conjunto difuso, e es la base del logaritmo natural, α es un parámetro que controla la pendiente de la curva y c es el punto que indica el comienzo de la inflexión en la curva.

e) Tipo S

$$Mf(x; \alpha, b) = \left\{ \frac{1}{1 + e^{-\alpha(x-b)}} \right\} \quad (2.7)$$

Donde:

$Mf(x)$ es el grado de pertenencia del valor x al conjunto difuso, e es la base del logaritmo natural, $-\alpha$ es un parámetro que controla la pendiente de la curva y c es el punto que indica el comienzo de la inflexión en la curva.

2.2.2 Normas Triangulares

Las normas triangulares denominadas *T-Norm* (T) y *T-Conorm* (S) son operadores fundamentales en la lógica difusa empleados para realizar operaciones entre conjuntos. Este tipo de normas satisfacen los requerimientos de conjunción y disyunción respectivamente, además de ser considerados como parte de la familia de funciones que permiten modelar el cuadrado unitario, en un intervalo unitario, como se describe en la definición 2.1.2 (Pekala, 2019).

Definición 2.1.2. Una norma triangular sobre un intervalo entre $[0-1]$ es una operación conmutativa, creciente y asociativa $T: [0,1]^2 \rightarrow [0, 1]$ con un elemento neutral 1. Una conorma triangular entre $[0-1]$ es una operación conmutativa, creciente y asociativa $S: [0,1]^2 \rightarrow [0, 1]$ con un elemento neutral 0. Por lo tanto, una representación general bajo una notación de Lukasiewicz cumple la forma de las ecuaciones 2.8 y 2.9 para las *T-Norm* y *T-Conorm* respectivamente.

$$T_l(x, y) = \max(0, x + y - 1) \quad (2.8)$$

$$S_l(x, y) = \min(1, x + y) \quad (2.9)$$

2.2.3 Funciones de agregación

En lógica difusa, una función de agregación permite combinar múltiples valores difusos en un solo parámetro representativo. Normalmente, son empleadas para establecer un resultado derivado del conjunto de reglas de inferencia que operan en la base de conocimiento, cumpliendo las condiciones descritas a continuación (Pekala, 2019).

Definición 2.1.3. Sea $n \in \mathbb{N}$, $n \geq 2$. Una función $A: [0 - 1]^n \rightarrow [0 - 1]$ es creciente y mantiene:

$$x_i \leq y_i \Rightarrow A(x_1, \dots, x_n) \leq A(y_1, \dots, y_n) \quad (2.10)$$

para cuando $x_i, y_i \in [0-1]$, $i = 1, \dots, n$, es denominada como una función de agregación si,

$$A(0, \dots, 0) = 0, A(1, \dots, 1) = 1 \quad (2.11)$$

Además, el tipo de agregación puede ser conjuntiva, disyuntiva o promedio según los siguientes criterios:

Conjuntiva:

$$A(x_1, \dots, x_n) \leq T_M(x_1, \dots, x_n) \quad (2.12)$$

Disyuntiva:

$$A(x_1, \dots, x_n) \geq S_M(x_1, \dots, x_n) \quad (2.13)$$

Promedio:

$$T_M(x_1, \dots, x_n) \leq A(x_1, \dots, x_n) \leq S_M(x_1, \dots, x_n) \quad (2.14)$$

Las normas anteriores son representadas por las operaciones *min*, *max* y *mean* respectivamente, durante la ponderación del resultado difuso proveniente de la base de conocimiento en forma de reglas.

2.2.4 Sistema de inferencia Takagi-Sugeno

El sistema de inferencia Takagi-Sugeno (TS) es un método diseñado para modelar sistemas complejos usualmente con rasgos no lineales, empleando un conjunto de reglas difusas. En otras palabras, mediante un conjunto de reglas, se particiona el sistema no lineal en múltiples subsistemas lineales, con cierto grado de correlación. Posteriormente, todos los subsistemas lineales son integrados en un solo producto para asemejar la conducta de un método de defuzzificación y representar el sistema no lineal tan preciso como sea posible. En este sentido, se describe a un sistema TS por un conjunto de reglas “*IF-THEN*” donde la sección de antecedentes que sigue al bloque “*IF*” se construye con base en la obtención de pertenencias a conjuntos difusos denominada etapa de fuzzificación, y la parte que sigue al bloque “*THEN*” donde se establecen los subsistemas lineales manteniendo la estructura descrita en la ecuación (2.19) (Sun et al., 2021).

$$\text{Model } M: \text{if } \mathbf{x} \text{ is } A_i(\mathbf{x}, \mathbf{v}_i), \text{ then } y \text{ is } L_i(\mathbf{x}, \mathbf{a}_i) \quad (2.15)$$

Donde cada modelo se conforma por un antecedente o condición A_i y una conclusión L_i para $i=1, 2, \dots, n$. Sin embargo, cada condición se formula por un prototipo $\mathbf{v}_i$ y cada conclusión por un coeficiente $\mathbf{a}_i$. En este sentido, dado un valor de entrada $\mathbf{x}$, la salida y se determina de forma acumulativa aplicando un operador de conjunción como se describe en la ecuación (2.20).

$$y = \sum_{i=1}^n A_i(\mathbf{x}, \mathbf{v}_i) L_i(\mathbf{x}, \mathbf{a}_i) \quad (2.16)$$

Finalmente, el resultado del sistema TS se conforma con base en el número de reglas y la optimización de los coeficientes, manteniendo un proceso de mapeo como se describe en el diagrama a bloques de la Figura 2. 3.




Figura 2. 3. Diagrama a bloques del proceso de modelado empleado un motor de inferencia Takagi-Sugeno (Lendek, et al., 2011).

2.2.5 Sistema de Inferencia Mamdani

Mamdani es un mecanismo de inferencia empleado en la lógica difusa para modelar información utilizando conjuntos difusos de salida, y así obtener un resultado. Seguido a esto, se emplea una función de defuzzificación para transformar la conclusión difusa en términos de conjuntos a un valor de dominio continuo. Por lo tanto, basado en esta serie de argumentos, en la gráfica de la Figura 2. 4 se describe el diagrama a bloques del proceso de mapeo difuso empleando un mecanismo de inferencia Mamdani.




Figura 2. 4. Diagrama a bloques de un modelo difuso utilizando un sistema de inferencia Mamdani (Madhumangal, et al., 2020).

La determinación de los grados de pertenencia en la etapa de fuzzificación sigue el criterio propuesto por Zadeh (1988), considerando A_i conjuntos de entrada, S_i conjuntos de salida y un valor de evaluación x con respecto a la familia de conjuntos FS establecidos dentro de un universo U , para todo $A_i, S_i \in FS(U)$. Posteriormente, se obtiene una inferencia

mediante un conjunto de reglas “*IF-THEN*” manteniendo la forma descrita en la ecuación (2.18).

$$\text{Model } M: \text{if } x \text{ is } A_i, \text{ then } y \text{ is } S_i \quad (2.17)$$

Cada regla genera un valor numérico dependiendo de la norma triangular empleada. No obstante, la inferencia total de salida se estima mediante la agregación de cada regla. Finalmente, después de aplicar un método de defuzzificación, se obtiene un valor de salida perteneciente al dominio continuo como resultado.

2.2.6 Métodos de defuzzificación

Un método de defuzzificación en lógica difusa es una función utilizada para transformar la conclusión o inferencia del sistema difuso, a un parámetro en el dominio de los números reales cuando se emplea un motor de inferencia tipo Mamdani. Por lo tanto, según es descrito en Ruspini (1998) y Kumar (2017), dada la agregación de los grados de pertenencia del consecuente C'_i sobre un conjunto de salida Z , es posible obtener una conversión Z_0 mediante las siguientes estrategias de defuzzificación más utilizadas en la literatura.

- 1) Centro de gravedad (COG)

$$Z_0 = \frac{\int z C'(z) dz}{\int C'(z) dz} \quad (2.18)$$

- 2) Centro de sumas (CSM)

$$Z_0 = \frac{\int z [C'_1(z) + C'_2(z) + \dots + C'_n(z)] dz}{\int [C'_1(z) + C'_2(z) + \dots + C'_n(z)] dz} \quad (2.19)$$

- 3) Media del máximo (MOM)

$$Z_0 = \frac{\int M z dz}{\int M dz} \quad (2.20)$$

Donde $M = \{z | C'(z)\}$ con un grado máximo.

2.3 Redes neuronales Artificiales

Las redes neuronales artificiales (ANN, por sus siglas en inglés de *Artificial Neural Network*) son modelos computacionales dentro del campo de la inteligencia artificial que tienen como objetivo principal asemejar el proceso cognitivo humano. En otras palabras, mimetizar el comportamiento para la resolución de problemas. Este proceso cognitivo se atribuye en la naturaleza humana a un conjunto de células denominadas neuronas, ubicadas en la corteza cerebral mediante una sinapsis que les permite comunicarse entre ellas. Por su parte, estos elementos en las ANN son construidos por medio de unidades de procesamiento denominados neuronas, las cuales permiten generar cálculos complejos para la resolución de problemas de distinta naturaleza (Vanneschi & Silva, 2023).

En computación, esta estrategia se estructura mediante capas, como se muestra en la Figura 2. 5, donde el procesamiento se lleva a cabo en varias etapas, evaluando los datos de entrada y generando valores significativos en la salida. Sin embargo, la facultad para obtener una solución con este tipo de estrategias se basa en la capacidad para definir los pesos sinápticos de cada una de las conexiones entre cada neurona, para de esta manera, entrenar el modelo para la resolución de problemas específicos. No obstante, esto se alcanza haciendo uso de algoritmos de aprendizaje supervisado o no supervisado mediante el reconocimiento de patrones sobre datos relacionados directamente con el fenómeno estudiado, implicando gran relevancia para el establecimiento de los pesos en la arquitectura computacional (Rosa, et al., 2020).




Figura 2. 5. Representación de un modelo basado en redes neuronales artificiales (Rosa, et al., 2020).

2.4 Aprendizaje Supervisado

El aprendizaje supervisado es una estrategia del aprendizaje automático utilizada en el entrenamiento de modelos, permitiéndoles predecir o clasificar a partir de ejemplos previamente etiquetados. El concepto fundamental en las ANN se basa en mapear las entradas a una serie de salidas de manera precisa, utilizando los patrones de entrada como base para emular el conocimiento y lograr hacer predicciones sobre datos desconocidos (Liu, et al., 2023). Este proceso de aprendizaje se realiza mediante una serie de estrategias, dentro de las cuales son destacadas las siguientes (Tyagi, et al., 2022) (Liu, et al., 2023):

- 1) **Conjunto de datos de entrenamiento:** En este se reúnen los datos de ejemplo para la entrada del modelo con sus respectivos datos de salida deseados.
- 2) **Selección del modelo:** Se establece el tipo de algoritmo o modelo para el problema que se desea abordar.
- 3) **Alimentación de datos:** Se le proporcionan los datos de entrenamiento al modelo para ajustar los parámetros internos y establecer la relación entre los datos de entrada y salida.

- 4) **Ajuste y optimización:** Durante el entrenamiento, son ajustados los parámetros del modelo de manera iterativa para minimizar la diferencia entre las predicciones y las salidas reales.
- 5) **Validación y evaluación:** Una vez el modelo es entrenado, se evalúa el rendimiento mediante datos ajenos a la etapa de entrenamiento, comparando las predicciones y los valores deseados para establecer la precisión del modelo.
- 6) **Ajuste final:** Si el modelo no cumple con los requerimientos deseados, se aplican ajustes adicionales para cumplir con los criterios necesarios para satisfacer la precisión del algoritmo.

2.5 Sistema Adaptativo de Inferencia Neuro Difuso

El sistema adaptativo de inferencia neuro difuso es una técnica híbrida que emplea un método de aprendizaje por descenso del gradiente utilizado en las redes neuronales artificiales, pero que a diferencia de éstas utiliza un sistema de inferencia difuso para mapear la relación entre el espacio de las variables de entrada y los valores de salida (Han, et al., 2010). Este sistema está compuesto por 5 capas y múltiples nodos que se encargan de llevar a cabo diferentes tareas. En el diagrama de la Figura 2. 6 se presenta la estructura de un sistema de inferencia de dos entradas y una salida (Han, et al., 2010).




Figura 2. 6. Estructura de ANFIS con dos entradas y una salida (Han, et al., 2010).

Según se aprecia en la figura anterior, la capa número 1 se encarga de realizar la fuzzificación de los datos *crisp* a un grado de pertenencia según las funciones de

membresía delimitadas inicialmente. Este proceso es representado mediante las ecuaciones (2.21 - 2.22) tomando en cuenta el ejemplo del diagrama de la Figura 2. 6 para todo i = número conjuntos de evaluación (Sada, & Ikpeseni, 2021).

$$O_{1i} = \mu_f(DO), \quad i = 1, 2 \quad (2.21)$$

$$O_{2i} = \mu_f(COD), \quad i = 1, 2 \quad (2.22)$$

Posteriormente, la capa número 2 es alimentada con los datos fuzzificados para obtener los pesos de las funciones de membresía, tomando en cuenta un conjunto de reglas de inferencia que asocian cada pertenencia con un consecuente, tal como se describe en la ecuación (2.23), donde COD y DO representan las entradas del modelo, A_1 y B_1 los conjuntos difusos propuestos, f_1 un polinomio de primer orden y p_1, q_1, r_1 los parámetros consecuentes (Sada, & Ikpeseni, 2021).

$$IF \text{ DO is } A_1 \text{ AND COD is } B_1, THEN f_1 = p_1 DO + q_1 COD + r_1 \quad (2.23)$$

Cada asociación establecida por las reglas del modelo neuro difuso son obtenidas algebraicamente mediante *T-norms* como se observa en la ecuación (2.24), para cada i -ésima regla difusa. Estos resultados son denominados pesos o fuerza de disparo.

$$O_{2i} = \mu_A(DO) \mu_B(COD) \quad (2.24)$$

En la siguiente sección, son normalizados los pesos obtenidos por cada regla utilizando la ecuación (2.25), donde $\bar{w}_j$ representa la magnitud de cada peso j .

$$O_{3,i} = \bar{w}_j = \frac{w_j}{w_1 + w_2 + \dots + w_j} \quad (2.25)$$

Posteriormente, en la capa número 4 se lleva a cabo la división del sistema a modelar en un subconjunto de ecuaciones lineales. Este proceso se realiza mediante el establecimiento de los coeficientes p_i, q_i, r_i . Aquí, cada consecuente de la capa cuatro $O_{4,i} = \bar{w}_j f_i$ se define según la ecuación (2.26).

$$O_{4i} = \overline{w}_j f_i = \overline{w}_j (p_i DO + q_i COD + r_i) \quad (2.26)$$

Finalmente, en la capa número 5 se obtiene un resultado mediante la sumatoria de las salidas generadas en la capa anterior tal como se describe en la ecuación (2.27).

$$O_{5,i} = \sum_j \overline{w}_j f_i \quad (2.27)$$

El proceso de entrenamiento que emplea esta técnica se basa en un aprendizaje híbrido que aplica el descenso del gradiente y mínimos cuadrados para actualizar los parámetros del modelo. Dicho esto, en cada época se realiza una evaluación hacia adelante hasta la capa 4 donde se identifica el resultado generado por los mínimos cuadrados, y durante el paso hacia atrás la actualización de los datos con base en la señal del error mediante el descenso del gradiente (Han, et al., 2010) (Kennedy, et al., 2021).



CAPÍTULO 3.

ESTADO DEL ARTE

Klocke et al. (2015) considera la ley de Faraday como un factor relacionado con la disolución de material para modelar el proceso de manufactura. El utiliza la notación descrita en la ecuación (3.1), donde la masa de la pieza anódica m presenta una relación directamente proporcional con su masa molar M y la carga eléctrica $I \cdot t$ con una valencia constante z .

$$m = \frac{M}{z \cdot F} I \cdot t \quad (3.1)$$

Sin embargo, describe que al considerar la densidad del material p como un factor relevante, la ecuación (3.1) se rescribe según se observa en la ecuación (3.2). En esta representación, se formula un factor proporcional entre el material disuelto definido como V_{sp} y la carga eléctrica $I \cdot t$, manteniéndose constante durante todo el proceso.

$$V = \frac{M}{p \cdot z \cdot F} I \cdot t = V_{sp} \cdot I \cdot t \quad (3.2)$$

Klocke et al. (2013) menciona que, a pesar de mantener un comportamiento proporcional en la disolución de material, fenómenos fisicoquímicos derivados de las propiedades eléctricas interfieren directamente en la estabilidad estructural de la herramienta. Por esta razón, las características eléctricas son consideradas en el diseño modelos matemáticos del proceso de manufactura utilizando ecuaciones de Maxwell, con el objetivo de describir las propiedades conductivas y la presencia de gas a consecuencia de la electrólisis como se observa en la ecuación (3.3) (Klocke, et al., 2013). En ella, se establece que la densidad de la carga eléctrica local p se ve alterada por la divergencia en la densidad de la corriente

el ctrica, estableciendo as  el comportamiento del rotacional del campo magn tico $\vec{\nabla}$ y el vector de densidad de corriente $\vec{I}$ por medio de su tasa de cambio.

$$\vec{\nabla} \cdot \vec{I} = - \frac{dp}{dt} \quad (3.3)$$

Este conjunto de caracter sticas descritas por Klocke (2015) repercuten con mayor relevancia en el modelado del maquinado no convencional. Sin embargo, gracias a los avances acerca del proceso de manufactura establecidos en (Xu, et al., 2018) e (Idrosov, et al., 2004) se demuestra que la distancia inter-electrodos est  relacionada en gran medida con las caracter sticas finales del proceso. No obstante, como consecuencia de la proximidad entre las herramientas y los fen menos qu mico-el ctricos, este par metro se obtiene por medio de la relaci n que ejercen las variables como voltaje,  rea de exposici n y conductividad del electrolito, sobre la corriente de maquinado. Por esta raz n, seg n el criterio de Xu (2018), la representaci n del gap se puede dividir parcialmente mediante la estimaci n de la corriente del gap lateral y frontal. La corriente lateral puede ser estimada mediante la ecuaci n (3.4), tomando en cuenta los principios de la ley de Faraday y el  rea de exposici n lateral de la herramienta. Este c lculo se estima partiendo de la conductividad del electrolito k , el voltaje U_R , la longitud de la herramienta L , el  rea lateral expuesta H y la distancia lateral Δ_b .

$$I_s = kU_R L \left(\sqrt{\frac{2H}{\Delta_b} + 1} - 1 \right) \quad (3.4)$$

Por otra parte, la representaci n frontal del gap se calcula mediante la estimaci n de la corriente inferior del electrodo, descrita por la ecuaci n (3.5), donde la corriente frontal I_n es expresada por el cociente del producto entre la conductividad del electrolito k , el voltaje U_R , el di metro frontal del electrodo D y la longitud L , dividido entre la separaci n inicial entre las herramientas Δ_n .

$$I_n = \frac{kU_R DL}{\Delta_n} \quad (3.5)$$

De esta manera, Groover (2020) explica que es posible generar una aproximación global de la distancia entre las herramientas expresada en términos de corriente, obtenida por la sumatoria de I_s e I_n . No obstante, esta representación describe una disolución de material deseable, descartando los fenómenos químicos y la liberación de gases en forma de burbujas catódicas durante el proceso de manufactura, lo cual repercute en la estabilidad, calidad y control de las características finales del maquinado (Groover, 2020). Por esta razón, el modelado basado en características eléctricas representa parcialmente el fenómeno de disolución de material, aumentando el grado de complejidad para el desarrollo de un modelo matemático completo.

Aunado a lo anterior, en (Wu, et al., 2022) se sustenta que los métodos numéricos basados en elementos finitos resultan imprácticos para el diseño de un modelo, debido a características como la alta frecuencia de los pulsos de corriente eléctrica y la presencia de burbujas catódicas. Como resultado, han surgido estrategias que modelan el comportamiento no lineal de estos métodos considerando un menor número de variables y parámetros específicos de trabajo (Lyubimov, et al., 2019). Según Lyubimov (2019), las variables de distancia entre electrodos, voltaje y frecuencia presentan mayor influencia y permiten modelar con mayor precisión el desgaste de material para casos específicos de trabajo, pero estableciendo una brecha desconocida para aquellos resultados fuera de los parámetros contemplados.

Tomando en cuenta esta serie de problemáticas, han sido adoptadas otras estrategias que permiten abarcar un número mayor de variables sin incrementar excesivamente la complejidad del modelado. Casos de este tipo son reportados en (Leyva, 2018), (Rama, et al., 2009), (Morteza, 2017), (Muhammad, 2021) donde se observa la implementación de una técnica de *soft-computing* derivada de la inteligencia artificial denominada lógica difusa, para modelar los procesos de maquinado por descarga eléctrica y torneado asistido por vibración ultrasónica (UVAT, por las siglas en inglés de *Ultrasonic Vibration Assisted Turning*) a través datos experimentales. En este sentido, los trabajos mencionados mapean

el comportamiento del proceso de manufactura estableciendo relaciones entre los parámetros de configuración de ambos métodos y el comportamiento identificado en variables como la tasa de remoción de material, el diámetro de sobre corte, rugosidad, fuerzas de corte y temperatura, permitiendo establecer congruencias para datos desconocidos con base en el entrenamiento de los modelos. No obstante, para este tipo de estrategia situada dentro de los sistemas expertos, influye en gran medida la correcta designación del conocimiento a través de las reglas de inferencia y la asignación de los diferentes parámetros del modelo difuso (Dumitrescu, et al., 2021).

Por otra parte, de acuerdo con Schaarschmidt (2019) la distancia inter-electrodos también conocida como *gap*, se considera como un parámetro de gran influencia, ya que según la estimación de Xu et al. (2017) influye notoriamente en características de salida como la tasa de remoción de material. Por esta razón, en la investigación reportada por estos autores desarrollan un modelo para mapear este parámetro mediante el análisis del voltaje y la corriente de salida. Además, Xu et al. (2017) menciona que la representación matemática de PECM se modifica por la presencia de gases, cambios en la presión del electrolito y otro tipo de variaciones que ocurren dentro del establecimiento de la distancia inter-electrodos, puesto que, al presentarse este tipo de fenómenos, resulta complejo discriminar la relación entre el *gap* y la corriente cuantificada en términos matemáticos precisos. Finalmente, se argumenta que, al asegurar un *gap* uniforme, es posible establecer una relación con mayor fiabilidad mediante un sistema de entradas y salidas como se observa en investigaciones anteriores.

Otro caso particular encargado de estudiar el modelado de procesos de manufactura es reportado por Wen et al. (2012), el cual desarrolla la descripción del proceso de eliminación de material a través de una técnica de búsqueda de patrones libres (FPS, por las siglas en inglés de *Free Pattern Search*). Este método derivado de la programación de expresiones genéticas (GEP, por las siglas en inglés de *Gene Expression Programming*) se considera como parte de la familia de los métodos genéticos, que, para el caso específico de modelado, utiliza a la tasa de alimentación, voltaje y el flujo del electrolito para modelar la tasa de remoción de material, la rugosidad de la superficie y el sobre corte. Los resultados generados por el método FPS son contrastados con las predicciones de una

red neuronal artificial (ANN, por las siglas en inglés de *Artificial Neural Networks*), un análisis de regresión (RA, por las siglas en inglés de *Regression Analysis*) y un sistema co-adaptativo de inferencia neuro difuso (CANFIS, por las siglas en inglés de *Co-Active Neuro Fuzzy Inference System*) obteniendo un valor del indicador MAPE de 5.01 en la tasa de remoción de material, siendo menor al obtenido por los métodos RA y CANFIS con un valor de 11.75 y 12.93 respectivamente, pero por debajo de la red neuronal quien presento un MAPE de 4.38. Por otro lado, FPS presentó una predicción más exacta en el sobre corte, presentando un valor de 5.97 con el mismo indicador. Mientras tanto, las técnicas de RA, ANN y CANFIS obtuvieron un 9, 17.85 y 8.82. Finalmente, la predicción de la rugosidad con mayor exactitud fue la técnica híbrida CANFIS con un error de 11.99. Esto sugiere que FPS es capaz de modelar el proceso de ECM con una exactitud muy similar a la obtenida con redes neuronales artificiales y métodos híbridos, aunque no genera la mejor predicción para todas las variables modeladas.

A diferencia de la investigación anterior, en el trabajo reportado por Alvarado et al. (2018), se implementa una red neuronal artificial para modelar un proceso de maquinado no convencional EDM, utilizando una función de base radial. Según se describe en esta investigación, este método permite modelar sistemas no lineales por su simplicidad estructural y aproximación funcional. Este tipo de métodos propagan la señal de entrada hacia un conjunto de capas ocultas que son evaluadas por una función de activación gaussiana. Además, con el objetivo de optimizar el proceso de modelado, se aplica un algoritmo genético para inicializar los pesos de las neuronas. Con base en estas características, recogen datos a partir de experimentos y se realiza el entrenamiento para predecir el MRR, obteniendo una valoración del indicador R^2 de 0.94. Sin embargo, según el criterio descrito en (Naseem et al., 2023) gran parte de la precisión de un modelo neuronal se fundamenta por la gran cantidad de datos, ya que el ajuste de los hiperparámetros se realiza con base en la estadística generada por medio de los patrones durante el entrenamiento, criterio a considerarse para problemas que requieren recursos y equipamiento específico como es el caso del maquinado electroquímico por pulsos.

En (Chuang et al., 2023) utilizan una red neuronal artificial profunda para modelar la eliminación de material con EDM y ECM utilizando la corriente y el voltaje como

variables de mayor significancia. Este proceso se desarrolló mediante el entrenamiento y validación del modelo utilizando datos provenientes de experimentos, obteniendo un error medio absoluto de 1.32 mm^2 en el desgaste de material predicho. Por otra parte, en (Ji & Min, 2022) adicionan el recosido simulado a la red neuronal artificial para predecir características como profundidad y ancho de microcanales en NaNO_3 . Para llevar esto a cabo utilizan los atributos de frecuencia, corriente, voltaje y ciclo de trabajo para entrenar el algoritmo, obteniendo finalmente un error relativo del 5.3 % con base en las predicciones.

Por otro lado, en (Wu, et al., 2022) sucede un comportamiento similar al reportado anteriormente, obteniendo un error cuadrático medio de 7.60 en la predicción del diámetro y profundidad de maquinados en PECM, utilizando una red neuronal convolucional. Según Ji y Min (2022) atribuyen estos índices altos del error a la poca cantidad de datos empleados, argumentando que es un factor que influye negativamente a este método computacional para generar una correcta generalización. Davis et al. (2018) también menciona que esto se debe a que las redes neuronales artificiales son procesos estadísticos que basan su capacidad de aprendizaje en los patrones de entrada, por lo que necesitan grandes cantidades de datos para mejorar su rendimiento.

Las redes neuronales son utilizadas en los procesos de manufactura no convencional como ECM, no solo para predecir factores de rendimiento, sino también para optimizar los parámetros del proceso. En (Munasypop & Masalimov, 2017) aplican este principio, determinando que, variables como la distancia entre electrodos y el voltaje, permiten predecir las condiciones ideales de la corriente, el cual es un parámetro fuertemente relacionado con la tasa de remoción de material (Groover, 2010).

A diferencia de los casos anteriores, en (Rai & Kumar, 2020) utilizan una metodología de superficie de respuesta (RMS, por las siglas en inglés de *Response Surface Methodology*) para modelar la tasa de remoción de material (MRR), sobre corte (OC) y rugosidad (SR) en maquinados con ECM en acero AISI-304. Según el enfoque adoptado en esta investigación utilizan como atributos a el voltaje, concentración del electrolito y tasa de avance. Utilizan el coeficiente de determinación R^2 para cuantificar el rendimiento, generando un valor de 72.28 % para el MRR, 70.12 % para el OC y 96 % para el SR. Este

método es aplicado en más de una investigación reportada en la literatura, en (Singh, et al., 2022) la utilizan para modelar el MRR y SR en maquinados con EN-31. Según los resultados obtenidos, generan un rendimiento del R^2 de 84.5 % y 74.8 % respectivamente. Según se observa, esta metodología es aplicable para modelar ECM, aunque según Sekar et al. (2023) también se utiliza para predecir los parámetros óptimos de trabajo como fue descrito anteriormente con las redes neuronales artificiales.

Por otra parte, la técnica de ordenamiento de preferencias por similitud con la solución ideal (TOPSIS, por las siglas en ingles de *Technique for Order of Preference by Similarity to Ideal Solution*) es otro tipo de estrategia menos común, pero con un rendimiento destacado en el modelado de ECM (Nagarajan, et al., 2022). Porcentajes de R^2 del 90.34 % y 92.2 % son reportados como medidas de rendimiento para modelar el MRR y la presencia de Nickel (NP por las siglas en inglés de *Nickel Presence*).

En gran parte de la literatura examinada anteriormente es posible destacar una similitud con respecto al modelado. En cada uno de los trabajos que se abordaron, son identificados parámetros o variables que intervienen en las características finales del proceso, aunque también se demuestra en la literatura especializada en manufactura descrita por (Groover, 2020) y (Abdel & El-Hofy, 2005). Por esta razón, los algoritmos derivados de la inteligencia artificial e inclusive los métodos de optimización como algoritmos genéticos han demostrado gran viabilidad para perfeccionar el modelado de procesos en el área de ingeniería y manufactura.

A este tipo de modelos, que emplean diferentes estrategias de inteligencia artificial son denominadas técnicas híbridas, y presentan características distintivas de más de un método para mejorar la eficiencia en problemas complejos. Esto se observa en (Kennedy, et al., 2021), donde integran las redes neuronales y la lógica difusa para generar el método denominado ANFIS (*Adaptative Neuro Fuzzy Inference System*, por su traducción al inglés). Aunque este algoritmo utiliza el principio de dos técnicas, existen investigaciones que adicionan estrategias de optimización para complementar el ajuste de parámetros. Optimizadores como el de enjambre de partículas, colonia de hormigas o algoritmos genéticos son usualmente utilizados (Kennedy, et al., 2021). Justamente, Kennedy et al. (2022) emplea ANFIS en conjunto con algoritmos genéticos y el optimizador de colonia

de hormigas para mejorar la precisión de este método en la predicción de propiedades en el campo de la geotecnia. No obstante, también ha sido aplicado en el modelado de EDM como se observa en (Pourasl, et al., 2022), donde se demuestra gran eficiencia de ANFIS para modelar la tasa de remoción de material y el desgaste de la herramienta, obteniendo un error cuadrático medio (RMSE) para el *MRR*, *OC* y *RA* de 0.81, 0.288 y 0.17 respectivamente. Mientras tanto, una red neuronal artificial obtuvo 1.03, 1.17 y 0.33, demostrando una mejor aproximación con el método híbrido.

Resultados particularmente similares son descritos en (Singh et al., 2019) donde son comparados los métodos ANFIS, ANN y RSM (*Response Surface Methodology*, por su traducción al inglés) en la predicción de la tasa de remoción de material y la rugosidad en un proceso de EDM sobre acero troquelado D3. Durante el desarrollo de cada modelo fueron empleadas 5 características de entrada (corriente de descarga, tiempo de pulso, ciclo de trabajo, rotación del electrodo, presión de descarga de gas) consideradas como variables de mayor influencia. Finalmente, mediante un estudio riguroso de los parámetros esperados y las predicciones de cada modelo, considerando el error cuadrático medio (MSE) y la raíz del error cuadrático medio, fue demostrado un mejor rendimiento por parte de la técnica híbrida ANFIS al obtener una menor varianza con respecto los resultados generados.

Por otra parte, en (Sagathiya, et al., 2021) son reportados resultados prometedores durante el modelado de EDM utilizando el método ANFIS, empleando un conjunto de características de entrada y materiales de trabajo totalmente diferentes a los anteriormente expuestos. Para esta investigación, fue utilizada la aleación denominada Ti6Al4V, comprobando la adaptabilidad de esta estrategia para el modelado bajo numerosas condiciones, demostrando gran rendimiento ante problemas complejos, multivariantes y no lineales.

Gran parte de la eficiencia obtenida por ANFIS se basa en que permite modelar fenómenos complejos mediante conjuntos y métodos de inferencia, adaptando sus parámetros por medio de estrategias de aprendizaje supervisado como se realiza en las redes neuronales artificiales. Esto se observa en (Sada, & Ikpeseni, 2021) (Chai, et al., 2009), donde se describe la metodología de trabajo de los sistemas de inferencia Mamdani y Takagi-

Sugeno para modelar los patrones. Además, parte de las ventajas de ANFIS según Zhi y He-qing (2006) es que el entrenamiento por medio de esta técnica requiere de menos datos, además de ser rápida y precisa en las predicciones generadas. Estos argumentos son apoyados por Karaboga et al. (2019) y Qin (1998) quienes incluso favorecen el uso ANFIS con métodos de optimización para modelar sistemas no lineales con alto grado de complejidad y aleatoriedad.

Los argumentos anteriormente expuestos son comprobados en (Singh, et al., 2020) al realizar una investigación para optimizar la precisión de los parámetros predichos en una técnica no convencional EDM. Aquí, se observa el incremento del rendimiento de ANFIS al aplicar una optimización basada en un algoritmo genético (GA-ANFIS), teniendo como referencia la predicción generada por una red neuronal artificial y un modelo ANFIS convencional. Estos resultados fueron obtenidos mediante una serie de evaluaciones mediante error cuadrático medio, la raíz del error cuadrático medio y el coeficiente de determinación R^2 , el cual permitió determinar la proporción de variabilidad de la variable dependiente para cada modelo y estimar bajo este criterio el de mayor rendimiento. Bajo todos estos supuestos, se visualiza a ANFIS como una estrategia dinámica y aplicable en diferentes contextos como se observa en (Kaplan, et al., 2023), (Kushwaha, et al., 2023) y (Ben, et al., 2023) permitiendo ser una opción viable para ser aplicado en la vertiente del maquinado electroquímico por pulsos.

3.1 Discusión del estado del arte

Como se observa en la literatura, el maquinado electroquímico es un proceso compuesto por múltiples variables como corriente, voltaje, gap, flujo de electrolito, entre otras, que permiten modificar los resultados que son obtenidos al término del desgaste de material. Por otra parte, parámetros como la tasa de remoción de material (MRR), rugosidad o sobre corte engloban parte de las características de mayor interés que determinan la calidad del maquinado. En este sentido, fueron analizados diferentes puntos de vista identificados en la literatura, para llevar a cabo el análisis y comprensión de los requerimientos necesarios en el modelado de procesos de manufactura no convencional, y de esta manera, lograr manipular y experimentar con el proceso PECM. Dentro de las técnicas analizadas se identifican modelos matemáticos, redes neuronales, lógica difusa, metodología de

superficie de respuesta, optimizadores basados en algoritmos genéticos, enjambres de partículas y en su caso métodos híbridos que proporcionan beneficios agregados de más de un enfoque. Además, son identificados métodos que permiten modelar efectivamente el MRR en procesos de manufactura no convencional como EDM o por otro lado la magnitud de sobre corte de manera independiente, destacando que aquellos que consideran ambos criterios benefician la exactitud del valor de MRR. Derivado de lo anterior, se presentan los sistemas de inferencia neuro difusos, los cuales integran las propiedades de aprendizaje de las redes neuronales y los principios de inferencia acotados por la teoría de conjuntos, permitiendo diseñar un modelo dinámico, ajustable y eficiente que puede modelar problemas que presentan no linealidad, carecen de información o presentan cambios en las condiciones iniciales debido a las características aleatorias del proceso. Estas premisas son generadas mediante el análisis de diferentes problemáticas donde contrastan los resultados obtenidos por ANFIS y ANN, demostrando menor error en la predicción que otros aproximadores universales. Este comportamiento se atribuye a que los sistemas de inferencia híbridos ANFIS permiten entrenar el modelo con menor cantidad de datos y llevar a cabo el ajuste de los parámetros con mayor eficacia durante la etapa de entrenamiento. Por ende, se considera como una alternativa viable para el modelado del proceso de manufactura no convencional PECM, el cual es delimitado como multivariable, aleatorio y no lineal.



CAPÍTULO 4.

METODOLOGÍA

En el presente capítulo se describe la metodología empleada en esta investigación para modelar el proceso de maquinado electroquímico por pulsos mediante un sistema adaptativo de inferencia neuro difuso. Inicialmente se describe el proceso de integración, depuración, análisis y normalización del conjunto de datos empleado para entrenar y validar el modelo. Posteriormente se presenta la arquitectura y características del algoritmo en conjunto con el método para seleccionar el sistema y funciones de membresía iniciales. Finalmente, se describen las características del algoritmo genético empleado para llevar a cabo la optimización del modelo neuro difuso.

4.1 Proceso de integración del conjunto de datos de PECM

El proceso de manufactura PECM es uno de los métodos industriales en el área de la manufactura metalmecánica con escasa información experimental abierta al público para su investigación. Debido a estas circunstancias, se optó por utilizar un prototipo de maquinado electroquímico por pulsos el cual se describe en (Nopalera, 2021). Este sistema fue diseñado con base en investigaciones y literatura especializada del proceso PECM para aplicar el principio de disolución de material. En términos generales, el prototipo se compone por un sistema de ejes coordenados X, Y, Z, el cual se utiliza para desplazar la herramienta a lo largo del espacio de trabajo. Además, cuenta con un sistema de regulación y filtrado de electrolito para mantener las condiciones de trabajo adecuadas. En el esquema de la Figura 4. 1 son detallados los elementos que conforman el sistema mecánico, mientras que en el diagrama de la Figura 4.2 se describen los módulos utilizados por el sistema de manufactura para monitorear las variables de interés, el control de la fuente pulsos eléctricos y la gestión del control y procesamiento del prototipo.




Figura 4. 1. Diagrama de los elementos que conforman el sistema mecánico y el sistema de filtrado de electrolito (fuente: Elaboración propia).




Figura 4. 2. Diagrama de los módulos de monitoreo y control empleados para el desgaste de material en el prototipo de manufactura PECM (fuente: Elaboración propia).

Este recurso fue empleado como una alternativa para obtener datos del proceso de manufactura y posteriormente ser utilizados en el entrenamiento, validación y prueba del modelo neuro difuso propuesto en esta investigación.

4.1.1 Diseño experimental factorial 3^k

El diseño experimental factorial 3^k es un método de investigación que permite estudiar la interacción de variables independientes (factores) y variables dependientes (respuesta) dentro de un intervalo de tres diferentes magnitudes para cada factor denominado nivel (Melo, et al., 2020). Esto permite generar un panorama completo sobre la influencia de cada factor en la variable de respuesta y obtener información sustancial con un menor número de experimentos, a diferencia de otros diseños tradicionales (Melo, et al., 2020). Tomando en cuenta estos supuestos, se seleccionaron las variables directamente manipulables desde el prototipo para desarrollar experimentos bajo esta metodología. Por otro lado, las variables no manipulables, pero estrechamente relacionadas con las variables de estudio según lo señalado en la literatura, fueron monitoreadas y consideradas posteriormente en el modelo. En este contexto, la Tabla 4.1 presenta los parámetros utilizados en el diseño experimental para integrar el conjunto de datos del modelo neuro difuso.

Tabla 4. 1. Parámetros empleados en el diseño experimental factorial 3^k de PECM.

Factores	Niveles	Repeticiones	Bloques
Voltaje	3 V	5	2
	5 V		
	7 V		
Gap	200 μm	5	2
	240 μm		
	280 μm		
Frecuencia	40 kHz	5	2
	60 kHz		
	80 kHz		

Según se aprecia en la tabla anterior, son propuestas 5 repeticiones para cada experimento divididos en dos bloques, los cuales hacen referencia al parámetro de profundidad de desgaste de material de cada experimento. Estos bloques fueron establecidos a una profundidad de maquinado de 180 y 340 μm , donde se observan dos estados con diferente influencia debido al área de exposición activa. Como resultado, se realizaron un total de 270 experimentos como se describe en la ecuación (4.1), donde $k=3$ es el número de niveles, $R=5$ es el número de repeticiones y $B=2$ es el número de bloques propuestos.

$$Experimentos = 3^k \cdot R \cdot B \quad (4.1)$$

Agregado a lo anterior, se mantiene como constante la concentración del electrolito basada en agua (H_2O) y cloruro de sodio ($NaCl$), al 16 % en masa por cada litro de agua. Mediante estas concentraciones se genera una conductividad de la solución de 207 mS/cm, la cual fue medida mediante un conductímetro HANNA modelo HI5521. Finalmente, una pieza de acero estructural AISI-1018 fue propuesta como material de pruebas.

El proceso experimental propuesto consistió en configurar todas las posibles combinaciones de los factores y niveles de la Tabla 4. 1 en el prototipo de manufactura PECM. Esto implica manipular sistemas del equipo de mecanizado como la unidad de polarización y el sistema mecánico, mismos donde se lleva a cabo el monitoreo de la corriente como se describe en el esquema de la Figura 4. 3 (A). Este proceso se realiza en cada experimento hasta obtener un desgaste de material sobre la pieza de pruebas siguiendo el principio del esquema de la Figura 4. 3 (B), hasta alcanzar la profundidad establecida en cada bloque.




Figura 4. 3. (A) Sistemas del prototipo de manufactura PECM empleados en el diseño experimental factorial 3^k y (B) principio del desgaste de material realizado en cada experimento (fuente: Elaboración propia).

Posteriormente, al término de cada prueba se realizan mediciones de profundidad y diámetro de maquinado con un microscopio digital ODAR63 para realizar la estimación de las variables de estudio descritas por la tasa de remoción de material y sobre corte. El primer calculo se aproxima mediante el cociente del volumen de material desgastado (obtenido por medio de la ecuación (4.2)) y el tiempo empleado durante desgaste de material, tal como se expresa en la ecuación (4.3). Por otro lado, la segunda variable de estudio se aproxima mediante la ecuación (4.4), la cual delimita la diferencia entre el diámetro del maquinado y el diámetro de la herramienta de trabajo.

$$Vol = \left(\pi * \left(\frac{Dm}{2} \right)^2 \right) * Pm \quad (4.2)$$

$$MRR = \frac{Vol}{t} = C \frac{EA}{g\delta} \quad (4.3)$$

$$OC = Dm - Dh \quad (4.4)$$

Donde:

Vol : Volumen removido [mm^3]	A : Área del electrodo [mm^2]
Dm : Diámetro de maquinado [mm^3]	g : Distancia inter-electrodos [mm]
Dh : Diámetro herramienta [mm^3]	δ : Resistividad del electrolito [Ω]
Pm : Profundidad maquinado [mm^3]	C : Tasa de remoción específica de la pieza
t : Tiempo [min]	de trabajo utilizada [$\frac{mm^3}{As}$]
E : Voltaje aplicado [V]	

El conjunto de datos experimental fue integrado estableciendo el MRR y OC como variables de salida, mientras que los atributos como variables de entrada (voltaje, corriente, frecuencia, gap y área de exposición) formando un sistema de cinco entradas y dos salidas como primera aproximación para el modelo del proceso PECM.

4.2 Depuración del conjunto de datos

Durante el análisis y desarrollo de un modelo es común aplicar estrategias estadísticas para asegurar la calidad de la información recopilada. Esta práctica se lleva a cabo para eliminar datos deficientes ocasionados por errores humanos, mecánicos o de cualquier otra naturaleza que puedan perjudicar el propósito de la información (Kulczycki, & Kruszewski, 2017). Con este propósito se llevó a cabo una depuración de datos atípicos del conjunto de datos PECM, asegurando que la precisión del modelo no resulte afectada y los resultados no presenten sesgo por muestras deficientes. Por lo tanto, se aplicó un método estadístico de rango intercuartil para identificar muestras atípicas basándose en los cuartiles de los datos (Cho & Eo, 2016). Esta medida se delimita mediante la diferencia entre el tercer cuartil (Q3) y el primer cuartil (Q1) como se describe en la ecuación 4.5. Sin embargo, los criterios que establecen a un dato como atípico son presentados en las ecuaciones 4.6 - 4.7. Por lo tanto, cualquier caso donde el valor sea menor que la diferencia entre Q1 y 1.5 veces el rango intercuartil o, por el contrario, donde el valor sea mayor que la sumatoria de Q3 y 1.5 veces el rango intercuartil será considerado como un valor atípico (Va).

$$IQR = Q3 - Q1 \quad (4.5)$$

$$VaSix < Q1 - (1.5 \cdot IQR) \quad (4.6)$$

$$VaSix > Q3 + (1.5 \cdot IQR) \quad (4.7)$$

4.3 Análisis de correlación

En la literatura existen diferentes argumentos acerca de las variables que mantienen mayor influencia sobre la tasa de remoción de material y el sobre corte en PECM. No obstante, en gran mayoría de la literatura analizada en el estado del arte (Capítulo 3) son destacadas variables como voltaje, corriente, distancia entre electrodos (gap), frecuencia y área de exposición, mismos que conforman el conjunto de datos inicial para el proceso de manufactura (Sección 4.1). Con el objetivo de verificar la correlación entre estos atributos

y las variables de estudio, fue propuesto un análisis de correlación Spearman, el cual permite identificar la fuerza y dirección de las relaciones entre variables sin asumir una correspondencia lineal (Yu, et al., 2022). En la ecuación (4.8) se describe el principio de la correlación antes mencionada, donde p define el grado de correlación, a_i y b_i los rangos de la primera y segunda variable en la i -ésima observación del conjunto total n (Yu, et al., 2022).

$$p = 1 - \frac{6 \cdot \sum_{i=1}^n (a_i - b_i)^2}{n \cdot (n^2 - 1)} \quad (4.8)$$

Según el valor p de correlación obtenido, se establece la dirección y la fuerza entre variables donde un valor cercano a 1 indica una correlación positiva fuerte y un valor cercano a -1 indica una correlación negativa sólida. Por otra parte, si el valor de p es cercano a 0, es un indicativo de una correlación débil. De esta forma es posible analizar la influencia que mantienen cada uno de los atributos del proceso de manufactura con las variables de interés, para posteriormente descartar o mantener en el modelo neuro difuso.

4.4 Normalización de datos

La normalización de datos es una práctica regular en el desarrollo de modelos mediante estrategias de inteligencia artificial, debido a que algunos de estos métodos suelen ser sensibles a cambios abruptos en las escalas de las variables. Además, se tienen beneficios agregados como mejora en la convergencia, disminución del sesgo, facilidad de interpretación y mayor rendimiento del algoritmo (Patil, et al., 2022). La normalización z-score o estandarización es una técnica ampliamente empleada para transformar los datos (x) de tal manera que mantengan una media (μ) en cero y una desviación estándar (σ) en uno. La ecuación (4.9) describe el tipo de normalización anteriormente descrito y utilizado para los datos del proceso de manufactura PECM.

$$Z = \frac{x - \mu}{\sigma} \quad (4.9)$$

4.5 Sistema adaptativo de inferencia neuro difuso basado en el método Takagi-Sugeno

El modelo de predicción propuesto en la presente investigación se constituye por la combinación de las técnicas basadas en lógica difusa y redes neuronales artificiales. No obstante, dentro del mapeo realizado por la lógica difusa existen mecanismos de inferencia que permiten generar un resultado mediante diferentes procedimientos. Uno de ellos se denomina sistema Takagi-Sugeno, el cual permite modelar fenómenos no lineales a través de reglas *si-entonces* y subsistemas lineales denominadas ecuaciones de primer orden Takagi-Sugeno (Sun, et al., 2021). Además, al igual que las redes neuronales, el método ANFIS mantiene una arquitectura basada en capas y conexiones entre cada etapa, lo que le permite ajustar sus parámetros mediante algoritmos de aprendizaje supervisado. En el esquema de la Figura 4. 4 se visualiza la arquitectura del modelo propuesto considerando las variables de voltaje, corriente, distancia entre electrodos (gap) y área de exposición para la predicción de la tasa de remoción de material y sobre corte.




Figura 4. 4. Diagrama del modelo ANFIS Takagi-Sugeno empleado para el proceso PECM (Jang, et al., 1997).

Se aprecia, según el esquema de la figura anterior, como el modelo ANFIS se compone por 5 etapas o capas de evaluación en donde se generan resultados de salida específicos para cada sección. Estos resultados son definidos como $O_{n,i}$ donde n hace referencia a la capa actual de salida, mientras i define a la i -th salida de cada conjunto difuso denominado “nodo” en la capa n . Agregado a lo anterior, para fines de simplificación en la terminología del modelo, se estableció cada variable de entrada como u, v, x, z , refiriéndose a las variables de entrada establecidas con detalle en la Figura 4.3. Por otro lado, las salidas del modelo referentes a la tasa de remoción de material y sobre corte son simplificadas como Y_1 y Y_2 respectivamente. De esta manera, el resultado de cada variable en la primera capa de entrada en el nodo i , con $n=1$ estará definido como un grado de pertenencia derivado de las funciones de membresía μf_i , tal como se expresa en las ecuaciones (4.10 – 4.13)

$$O_{nu,i} = \mu f_i(u) \quad (4.10)$$

$$O_{nv,i} = \mu f_i(v) \quad (4.11)$$

$$O_{nx,i} = \mu f_i(x) \quad (4.12)$$

$$O_{nz,i} = \mu f_i(z) \quad (4.13)$$

Cabe destacar que para todo μf_i puede asignarse un tipo de función de membresía en particular como fue detallado en la sección 2.3, donde cada función es generada mediante un conjunto de parámetros que determinan su forma y ubicación dentro de un conjunto de soluciones denominado universo del discurso. De modo que los parámetros de estas funciones cambian constantemente hasta obtener un valor adecuado, se considera a esta capa como adaptativa dentro del modelo ANFIS.

Continuando con la descripción del modelo, en la capa número dos se aplica el operador *AND* situado dentro de las *T-norm* (sección 2.4). Este producto entre conjuntos se obtiene en la capa número dos mediante la ecuación (4.14), donde $O_{n,j}$ ó w_j representa la magnitud

de la fuerza de cada regla de inferencia con $n=2$, j =número de reglas de inferencia e i = a el número de funciones de membresía.

$$O_{2,j} = w_j = \mu_{f_i}(u) \mu_{f_i}(v) \mu_{f_i}(x) \mu_{f_i}(z) \quad (4.14)$$

Posteriormente, en la capa número tres se aplica una normalización de las fuerzas generadas por cada regla tomando como referencia la sumatoria total de la capa número dos, tal como se describe en la ecuación (4.15).

$$O_{3,j} = \bar{w}_j = \frac{w_j}{w_1 + w_2 + \dots + w_m} \quad (4.15)$$

En la siguiente etapa del modelo neuro difuso se lleva a cabo un segundo proceso adaptativo acotado por el mecanismo Takagi-Sugeno para subdividir el sistema no lineal del proceso de manufactura a un subconjunto de ecuaciones lineales. Esto se lleva a cabo mediante los coeficientes p_i, q_i, r_i, s_i, t_i denominados como parámetros consecuentes. De esta manera, cada consecuente de la capa cuatro $O_{4,j} = \bar{w}_j f_i$ estará definido según la estructura de la ecuación (4.16).

$$O_{4,j} = \bar{w}_j f_i = \bar{w}_j (p_i u + q_i v + r_i x + s_i y + t_i) \quad (4.16)$$

Finalmente, en la última capa del modelo neuro difuso se realiza la sumatoria de los resultados generados por cada ecuación Takagi-Sugeno producida en la capa cuatro. Este resultado genera una aproximación para cada variable de interés definida anteriormente como $\{Y_k\}$, con $k=1,2$, tal como se describe en la ecuación (4.17).

$$Y_k = O_{5,k} = \sum_j \bar{w}_j f_i = \frac{\sum_j w_j f_i}{\sum_j w_j} \quad (4.17)$$

4.5.1 Entrenamiento supervisado del modelo ANFIS

El proceso de entrenamiento del método ANFIS se lleva a cabo de manera similar como en una red neuronal artificial a través de dos pasos. El primero de ellos consiste en evaluar de manera secuencial de la capa uno, hasta la capa número cuatro, donde los parámetros consecuentes son identificados mediante el método de mínimos cuadrados descrito por la ecuación (4.18), donde $u = [u_1, \dots, u_p]^T$ es el vector de datos entrada del modelo, $f = [f_1, \dots, f_n]$ son funciones conocidas de u y $[\theta_1 \dots \theta_n]$ son denominados coeficientes de regresión. Para este proceso son empleados los datos de entrenamiento del proceso de manufactura tomando en cuenta el paradigma de entrenamiento supervisado, el cual contempla que para cada conjunto de atributos de entrada se conoce su respectivo conjunto de datos de salida.

$$y = \theta_1 f_1(u) + \theta_2 f_2(u) + \dots + \theta_n f_n(u) \quad (4.18)$$

En el segundo paso, se lleva a cabo una retroalimentación ajustando los valores de la sección de premisas (funciones de membresía) mediante el método de descenso del gradiente, basándose en las señales del error de cada nodo y del tipo de función difusa utilizada. Para el caso de funciones de tipo gaussianas, el centro y la desviación estándar son los parámetros que delimitan a la función en el universo del discurso. Por esta razón, los gradientes del centro para cada función μf_{ij} , son calculados mediante la ecuación (4.19) (Jang, et al., 1997) (Karaboga & Kaya, 2019).

$$\frac{\partial E}{\partial c_{ij}} = \frac{\partial E}{\partial \bar{w}_j f_i} \cdot \frac{\partial \bar{w}_j f_i}{\partial w_j} \cdot \frac{\partial w_j}{\partial \mu f_{ij}} \cdot \frac{\partial \mu f_{ij}}{\partial c_{ij}} \quad (4.19)$$

Donde:

$$\frac{\partial \mu f_{ij}}{\partial c_{ij}} = \mu f_{ij}(x_i) \cdot \frac{(x_i - c_{ij})^2}{\sigma_{ij}^2} \quad (4.20)$$

Por otra parte, el ancho de la función gaussiana delimitado por una desviación estándar se ajusta mediante el gradiente de la función de costo con respecto a cada conjunto difuso como se describe en la ecuación (4.21) (Jang, et al., 1997).

$$\frac{\partial E}{\partial \sigma_{ij}} = \frac{\partial E}{\partial \bar{w}_j f_i} \cdot \frac{\partial \bar{w}_j f_i}{\partial w_j} \cdot \frac{\partial w_j}{\partial \mu f_{ij}} \cdot \frac{\partial \mu f_{ij}}{\partial \sigma_{ij}} \quad (4.21)$$

Donde:

$$\frac{\partial \mu f_{ij}}{\partial \sigma_{ij}} = \mu f_{ij}(x_i) \cdot \frac{(x_i - c_{ij})^2}{\sigma_{ij}^3} \quad (4.22)$$

Una vez que los gradientes son estimados, el centro y desviación de cada función se ajusta mediante las ecuaciones (4.23 - 4.24) (Jang, et al., 1997).

$$c_{ij} = c_{ij} - \eta \cdot \frac{\partial E}{\partial c_{ij}} \quad (4.23)$$

$$\sigma_{ij} = \sigma_{ij} - \eta \cdot \frac{\partial \mu f_{ij}}{\partial \sigma_{ij}} \quad (4.24)$$

El diagrama de la Figura 4. 5 ilustra el proceso empleado para ajustar los parámetros adaptativos del modelo neuro difuso. Durante el entrenamiento, se evalúan los datos del método de manufactura utilizando el error cuadrático medio como métrica de referencia. Este ajuste se realiza de manera iterativa hasta que no se detecten mejoras significativas en la función de error a lo largo de 50 iteraciones consecutivas, criterio establecido como convergencia.




Figura 4. 5. Diagrama de flujo del proceso de entrenamiento del modelo ANFIS (fuente: Adaptado de (Karaboga & Kaya, 2019)).

4.6 Sistema adaptativo de inferencia neuro difuso basado en el método Mamdani

A diferencia del modelo ANFIS que emplea un sistema de inferencia basado en el método Takagi-Sugeno visto anteriormente, el modelo basado en el sistema Mamdani permite modelar la salida del sistema neuro difuso mediante un grado de pertenencia. Bajo estas condiciones, para lograr interpretar la predicción utilizando el sistema Mamdani, es necesario utilizar un método de defuzzificación para transformar la salida difusa en un valor numérico, tal como se describe en la sección 2.6. Además, al emplear funciones en gran parte del proceso de mapeo, el tipo de conjunto contribuye en la calidad de la generalización del modelo, requiriendo un esfuerzo agregado para definir estos parámetros. Sin embargo, a diferencia del enfoque basado en Takagi-Sugeno, el ajuste de los parámetros de las funciones se realiza únicamente por medio del descenso del gradiente. El diagrama de la Figura 4. 6 describe el proceso empleado para el entrenamiento del modelo neuro difuso con el sistema Mamdani utilizando el mismo criterio de convergencia en el error que el sistema Takagi.




Figura 4. 6. Diagrama del entrenamiento de ANFIS utilizando un sistema Mamdani (fuente: Adaptado de (Jang, et al., 1997)).

4.7 Selección del método de inferencia y parámetros iniciales del modelo neuro difuso

El propósito de esta sección tiene como objetivo encontrar el tipo de arquitectura y parámetros iniciales del modelo ANFIS para realizar la predicción de las variables de estudio del proceso PECM. Para ello se plantea realizar una exploración mediante una serie de experimentos con los sistemas de inferencia Takagi-Sugeno y Mamdani. Además, visualizar el rendimiento de cada uno de ellos al utilizar funciones de tipo sigmoidal, gaussiana, triangular y trapezoidal. Para comenzar esta exploración, se dividieron los datos del proceso de manufactura en dos conjuntos: entrenamiento-validación y prueba, para posteriormente realizar el análisis de las predicciones y determinar la arquitectura y tipos de funciones a implementar. Sin embargo, para lograr definir con certeza estos rubros se plantearon como apoyo las siguientes hipótesis:

1. Hipótesis nula (H_0): No hay diferencias significativas en el rendimiento predictivo entre el sistema Takagi-Sugeno y el sistema Mamdani.
2. Hipótesis alternativa (H_1): Existe una diferencia significativa en el rendimiento predictivo entre el sistema Takagi-Sugeno y el sistema Mamdani.
3. Hipótesis nula (H_2): No hay diferencia significativa en el rendimiento del modelo ANFIS al utilizar diferentes tipos de funciones de pertenencia (sigmoidales, gaussianas, triangulares, trapezoidales).
4. Hipótesis alternativa (H_3): Existe una diferencia significativa en el rendimiento del modelo ANFIS al utilizar diferentes tipos de funciones de pertenencia (sigmoidales, gaussianas, triangulares, trapezoidales).

Las hipótesis anteriores son empleadas para argumentar de manera fiable la selección los parámetros del modelo ANFIS. Para lograr aceptar o refutar cada hipótesis, se evalúa la predicción de los experimentos con cada uno de los rubros planteados (sistemas y funciones) mediante un análisis estadístico basado en la prueba T-Student. De esta manera, se utiliza esta prueba para la dictaminación del sistema de inferencia. Además, se propone la prueba ANOVA para argumentar las diferencias entre funciones difusas. Posteriormente, de ser refutada la hipótesis nula para cada caso, un proceso de evaluación mediante el error cuadrático medio y el coeficiente de determinación será aplicado para

visualizar el rendimiento de cada criterio. No obstante, este paso se omitirá en caso de que la hipótesis nula sea aceptada, demostrando una indiferencia al sistema o tipo de función empleada según sea el caso.

4.8 Optimización genética del modelo ANFIS

La sección de premisas del modelo ANFIS (etapa 1) se ajusta convencionalmente mediante técnicas basadas en el descenso del gradiente (Karaboga & Kaya, 2019). Este método utiliza la derivada de la función para establecer la magnitud y dirección en que se ajustan los parámetros del modelo, y de esta manera minimizar la pérdida a partir de mejores predicciones (Welper, 2022). No obstante, el descenso del gradiente suele presentar deficiencias en problemas complejos o funciones no convexas. Esto sucede cuando la dirección del ajuste encuentra un espacio que minimiza localmente la función de pérdida y no es capaz de salir para establecer un mínimo global (Goodfellow, et al., 2016). Con base en estos argumentos, se propone la optimización de la etapa de premisas del modelo ANFIS mediante los principios de selección y herencia delimitados por el algoritmo genético, y de esta manera incrementar la capacidad de exploración para evitar caer en mínimos locales derivados de la complejidad del proceso de manufactura PECM (Tsai & Chiang, 2023).

La optimización implica ajustar los parámetros de las funciones de membresía utilizadas en la etapa 1 del modelo neuro difuso. Para este propósito se utiliza una representación en forma de vector denominado cromosoma como se describe en la ecuación (4.25), el cual hace referencia a cada uno de los parámetros o genes empleados para formar cada conjunto.

$$Chromosome = [G_1, G_2, G_3, \dots, G_n] \quad (4.25)$$

Inicialmente son generados 99 cromosomas cuyos genes son inicializados de manera aleatoria. Posteriormente se integra un individuo más para completar una población total de 100 cromosomas. Este último elemento no mantiene una inicialización aleatoria, sino que contiene el vector de parámetros ajustados mediante un entrenamiento convencional del modelo ANFIS basado en el descenso del gradiente. Esta metodología se propone para

verificar si el algoritmo genético es capaz de mejorar el rendimiento del modelo neuro difuso a través de cada iteración. Si esto sucede, demostraría un óptimo local obtenido con las técnicas tradicionales de ANFIS basadas en el descenso del gradiente. De no ser así, el algoritmo genético mantendrá el cromosoma con los parámetros pre entrenados a lo largo de cada generación, comprobando que el ajuste de los conjuntos difusos se realizó eficientemente y de manera global con los métodos convencionales.

Una de las medidas de rendimiento empleadas para evaluar el modelo ANFIS es el coeficiente de determinación R^2 , el cual indica la proporción de la variabilidad en que la variable dependiente puede ser explicada mediante las variables independientes. Para este problema en particular, se tienen dos variables dependientes (tasa de remoción de material y sobre corte). Por esta razón, la función objetivo que se emplea en el algoritmo genético se basa en maximizar el promedio de ambos coeficientes, tal como se describe en la ecuación (4.26). En este sentido, para el caso de la variable del MRR, i es el número de la muestra, Y_{MRR_i} son los valores reales de la variable dependiente, $\hat{y}_{MRR_i}$ son los valores predichos por el modelo, $\bar{y}_{MRR}$ es el valor medio de la variable dependiente y n el número total de muestras. Esta misma estructura se utiliza para la variable de sobre corte, utilizando el subíndice OC .

$$Fo = \max \left(1 - \frac{1}{2} \left(\frac{\sum_{i=1}^n (y_{MRR_i} - \hat{y}_{MRR_i})^2}{\sum_{i=1}^n (y_{MRR_i} - \bar{y}_{MRR})^2} + \frac{\sum_{i=1}^n (y_{OD_i} - \hat{y}_{OC_i})^2}{\sum_{i=1}^n (y_{OD_i} - \bar{y}_{OC})^2} \right) \right) \quad (4.26)$$

Utilizar esta función objetivo requiere de generar predicciones con el modelo ANFIS y así estimar el rendimiento mediante los coeficientes de determinación. Por lo tanto, para llevar esto a cabo en el proceso de optimización, se realiza la evaluación de cada cromosoma de la población en el modelo ANFIS, el cual establece los parámetros de cada gen como punto de referencia para formar las funciones difusas. Seguido a esto, el modelo neuro difuso utiliza dichas funciones para realizar predicciones y calcular el resultado de la función objetivo, derivada de los parámetros del cromosoma. El proceso de optimización completo se describe mediante el diagrama de la Figura 4.7, donde se visualiza la metodología descrita anteriormente. Además, según este esquema, la siguiente etapa consiste en aplicar un operador de selección. En esta propuesta se utiliza una

selección elitista durante cada iteración para asegurar la permanencia del cromosoma con mejor aptitud. De esta manera se asegura la prevalencia de los parámetros obtenidos en el entrenamiento convencional de ANFIS, suponiendo que representen un óptimo global de la función de pérdida.




Figura 4. 7. Diagrama de flujo del proceso de optimización realizado con el algoritmo genético y ANFIS (fuente: Elaboración propia).

Después de realizar la selección de la población para generar descendencia, se aplica un operador de mezcla cruzada Alpha (BLX- α , por las siglas en inglés de Blend Cross Over). Este tipo de cruce se describe mediante la ecuación (4.27) la cual permite generar descendencia aleatoria basada en la combinación de dos genes padres $[G_1, G_2]$ y un valor aleatorio de α con una distribución uniforme, donde Gn_{max} es el valor máximo de los genes padres, Gn_{min} es el valor mínimo de los genes padres, y D es la diferencia entre $Gn_{max} - Gn_{min}$ (Takahashi & Kita, 2001).

$$Descendencia = rand[(Gn_{min} - D * \alpha), (Gn_{max} + D * \alpha)] \quad (4.27)$$

Finalmente, para asegurar la diversidad genética, se aplica una mutación uniforme en uno de los genes de la población con una probabilidad del 1 %.



CAPÍTULO 5.

DISCUSIÓN Y RESULTADOS

En el presente capítulo se lleva a cabo la discusión sobre los hallazgos y resultados obtenidos en la investigación para el modelado del proceso de maquinado electroquímico por pulsos utilizando un sistema adaptativo de inferencia neuro difuso.

5.1 Conjunto de datos del modelo PECM

El conjunto de datos inicial para el desarrollo de la investigación fue generado mediante el diseño experimental planteado en la sección 4.1.1. En la Tabla 5. 1 se presenta un resumen general de las variables dependientes e independientes que conforman cada patrón de datos, así como las características del diseño experimental realizado.

Tabla 5. 1 Resumen general del diseño experimental para la recopilación de datos.

Variables	Experimentos	Repeticiones	Bloques	Número de patrones obtenidos
Dependientes				
Tasa de remoción de material				
Sobre corte				
Independientes				
Frecuencia	27	5	2	270
Voltaje				
Distancia entre electrodos (gap)				
Área de exposición				
Corriente				

Este conjunto fue sometido a una etapa de preprocesamiento basada en un criterio de rango intercuartil. Bajo este criterio fueron identificados los datos con características atípicas

para ser excluidos de la etapa de entrenamiento y validación del modelo neuro difuso. En la gráfica de la Figura 5. 1 (A) se visualiza el diagrama de caja y bigotes con el análisis descrito para el sobre corte y en la Figura 5. 1 (B) para la tasa de remoción de material.




Figura 5. 1. Gráficas de caja y bigotes para observar los datos atípicos identificados por el criterio de rango intercuartil en el (A) Sobre corte y (B) Tasa de remoción de material (fuente: Elaboración propia).

Durante el análisis del sobre corte fueron identificados catorce datos fuera de 1.5 veces el criterio de rango intercuartil. Estos datos fueron excluidos del agrupamiento total al igual que el resto de los datos relacionados al dato atípico (atributos y segunda variable independiente de ese experimento), conservando un total de 256 patrones. Al termino de este proceso fueron analizadas las variables de este conjunto de datos resultante mediante el método de correlación Spearman, para observar la fuerza y dirección de la correlación entre variables. En la gráfica de la Figura 5.2 se presenta el mapa de calor obtenido como resultado de la prueba antes mencionada.




Figura 5. 2. Diagrama de calor con la correlación Spearman entre variables del conjunto de datos del proceso PECM (fuente: Elaboración propia).

En el mapa de calor se observa una correlación superior a 0.5 por parte de las variables de corriente, voltaje, gap y área de exposición. Por otro lado, el parámetro de frecuencia genera una correlación débil con un valor de -0.14 para el MRR y uno de -0.13 para el OC. Estos resultados sugieren que la frecuencia presenta una influencia poco significativa en las variables de estudio. Para verificar este argumento, se aplicó una regresión múltiple con los datos del proceso de manufactura, generando los coeficientes de cambio y valores de significancia estadística descritos en la Tabla 5.2.

Tabla 5. 2. Coeficientes de cambio y valores de significancia estadística generados con una regresión múltiple de los datos del proceso PECM.

Variable	Sobre corte		Tasa de remoción de material	
	(OC)		(MRR)	
	Coeficiente	Valor p	Coeficiente	Valor p
Corriente	2548.44	0.0026	22.8	0.0084
Voltaje	27.51	0.00015	11.87	0.0003
Gap	-10.01	0.0085	-12.2	0.0017
Área	205.05	0.013	9.73	0.00057
Frecuencia	-0.37	0.192	-0.00058	0.113

El análisis descrito por la regresión múltiple permite observar un valor estadístico p de la frecuencia de 0.192 para el sobre corte y uno de 0.113 para la tasa de remoción de material, estableciéndose como la única variable con una significancia superior a 0.05. Estos resultados estadísticos rectifican que la frecuencia mantiene una relación poco significativa con las variables de estudio y por lo tanto se excluyó del conjunto de datos, conservando únicamente los atributos de corriente, voltaje, gap y área de exposición para modela el OC y MRR.

Posteriormente, se aplicó una normalización de los datos con el método z -score para escalar y mantener una mejor estabilidad y rendimiento en el entrenamiento del modelo. En la gráfica en la Figura 5. 3 se presenta un lote de 50 datos normalizados donde se observa el comportamiento de la tasa de remoción de material en el proceso experimental.




Figura 5. 3. Lote de datos normalizados de la variable de tasa de remoción de material (fuente: Elaboración propia).

Por otro lado, en la gráfica de la Figura 5. 4 se presenta una muestra para los datos normalizados de la variable de sobre corte.




Figura 5. 4. Lote de datos normalizados de la variable de sobre corte (fuente: Elaboración propia).

Es posible observar en las gráficas anteriores parte del comportamiento que presentan ambas variables en el proceso de manufactura, comúnmente aunadas a rasgos característicos de no linealidad, aleatoriedad o sistemas caóticos, tal como se describe en la literatura especializada (McGeough, 1974) (Zaytzev, et al., 2004) (Kloke, et al., 2015). Finalmente, el conjunto de datos total fue dividido en dos subconjuntos con una proporción en porcentaje del 80 y 20 %. El primer subconjunto fue destinado para realizar el entrenamiento y validación del modelo mediante validación cruzada “*k-fold*” con un factor *k* de tamaño 4. En este tipo de validación se subdivide este conjunto en cuatro bloques y se entrena y valida con cada segmento de datos. Por otro lado, el 20 % de los datos restantes se utilizó para realizar las pruebas del modelo neuro difuso.

5.2 Desempeño del modelo ANFIS: Evaluación de sistemas de inferencia y funciones de membresía

Tal como se presentó en la sección de metodología, el modelado mediante ANFIS puede ser realizado mediante dos tipos de arquitectura: Takagi-Sugeno y Mamdani. Además, es posible implementar múltiples tipos de funciones de pertenencia. Por esta razón, para comenzar con este proceso de selección fueron desarrollados ambas arquitecturas

mediante el lenguaje de programación Python, cada una con diferentes tipos de funciones disponibles (triangulares, trapezoidales, gaussianas y sigmoidales).

El primer paso de esta exploración consistió en entrenar y validar cada uno de los modelos generados mediante el conjunto de datos empleado para la validación cruzada y los diferentes tipos de funciones de membresía. Al término de este proceso fue analizado el rendimiento de cada configuración del modelo neuro difuso mediante la medida de rendimiento del error cuadrático medio y la prueba ANOVA, con el objetivo de vislumbrar la presencia o no, de diferencias significativas entre los diferentes tipos de conjuntos difusos (Liu & Wang, 2021).

Como resultado, fue obtenido un valor estadístico p de la prueba ANOVA de 0.0019, valor que permite rechazar la hipótesis nula (H_2) establecida en la sección 4.7, la cual describe la inexistencia de diferencias significativas entre funciones de pertenencia. De este modo, se establece que el tipo de función empleada permite modificar sustancialmente la predicción de las variables de estudio del proceso de manufactura. Sin embargo, para observar un panorama con mayor claridad fue evaluada la predicción mediante el error cuadrático medio (RMSE). En la gráfica de la Figura 5. 5 (A) se describe el promedio del error RMSE generado por cada tipo de función utilizando el sistema de inferencia Takagi-Sugeno, mientras que en la Figura 5. 5 (B) se observa la magnitud del error utilizando el sistema Mamdani.




Figura 5. 5. Promedio del error cuadrático medio al evaluar diferentes funciones en el modelo ANFIS (A) Takagi-Sugeno y (B) Mamdani (fuente: Elaboración propia).

En la figura anterior se aprecia un mejor rendimiento del modelo ANFIS al emplear un sistema de inferencia Takagi-Sugeno y funciones de tipo gaussianas, el cual genera un error RMSE de 0.333. Este resultado se atribuye a las características de la función gaussiana, la cual permite modelar dentro del universo del discurso de forma no lineal debido a la composición matemática del conjunto. Por el contrario, las funciones triangulares o trapezoidales, donde se lleva a cabo el cambio entre un valor nulo y la máxima pertenencia, se obtienen mediante una pendiente, generando una ponderación de las variables bajo un principio lineal (Godoy, 2021).

Otro punto destacado en este análisis hace referencia a que, en ambos métodos de inferencia, la función gaussiana presenta un mejor rendimiento, pero no es posible comprobar a simple vista si existe una diferencia significativa entre cada arquitectura con el mismo tipo de función. Para determinar esta indagatoria fue aplicada la prueba *T-Student* a las diferencias entre las predicciones de cada método utilizado únicamente funciones de tipo gaussianas. Como resultado, fue obtenido un valor estadístico p de 0.00012, permitiendo aceptar la hipótesis alternativa (H1) establecida en la sección 4.7, la cual describe que existe una diferencia significativa en el rendimiento predictivo entre el sistema Takagi-Sugeno y el sistema Mamdani. Con base en estas observaciones fue seleccionado el sistema Takagi-Sugeno para trabajar con modelo ANFIS, además de implementar funciones de tipo gaussiana.

5.3 Resultados del modelo preliminar de ANFIS entrenado mediante métodos tradicionales

La arquitectura general del modelo ANFIS después del análisis anterior se describe en la Tabla 5.3, donde se presentan los parámetros utilizados para modelar el proceso de manufactura, utilizando inicialmente un método clásico basado en el descenso del gradiente en la etapa de premisas.

Tabla 5. 3. Parámetros utilizados en la arquitectura inicial del modelo ANFIS.

Modelo	Sistema de inferencia	Tipo de función de membresía	No. de variables de entrada	No. de funciones difusas por variable	Algoritmo de ajuste
ANFIS	Takagi-Sugeno	Gaussiana	4	3	Descenso del gradiente

La configuración de los parámetros descritos en la Tabla 5.3 generaron un promedio del error cuadrático medio de 0.428 con los datos de prueba. No obstante, cada variable de salida genera un error de manera independiente. En la gráfica de la Figura 5.6 se detalla el error obtenido en la etapa de validación cruzada (entrenamiento y validación con k-folds) y prueba con el modelo inicial de ANFIS. Según los resultados individuales del error se visualiza mayor exactitud para el sobre corte con un valor en la etapa de prueba de 0.394, mientras que para la tasa de remoción de material un error de 0.463.




Figura 5. 6. Errores RMSE del modelo inicial de ANFIS entrenado mediante métodos convencionales basados en el descenso del gradiente (fuente: Elaboración propia).

Además del RMSE, se evaluó el coeficiente de determinación R^2 para observar la magnitud en que pueden ser explicadas las variables de respuesta por medio de las variables independientes en el modelo. En la Figura 5.7 se presenta coeficiente de determinación de cada variable de salida del modelo inicial de ANFIS.




Figura 5. 7. Coeficientes de determinación (R^2) en la etapa de validación y prueba del modelo inicial de ANFIS entrenado con métodos convencionales basados en el descenso del gradiente (fuente: Elaboración propia).

Los coeficientes obtenidos con el modelo entrenado mediante el descenso gradiente generan un rendimiento en la etapa de prueba de 0.88 para el sobre corte y un valor de 0.84 para la tasa de remoción de material. Ambas medidas de rendimiento (RMSE y R^2) establecen la referencia acerca del rendimiento que es posible alcanzar utilizando un entrenamiento convencional del modelo ANFIS inicial.

5.4 Resultados de la optimización genética del modelo ANFIS

La siguiente etapa según los objetivos propuestos consistió en explorar el espacio de búsqueda de los parámetros de las funciones de membresía mediante el remplazo de la metodología basada en el descenso del gradiente a una acotada por los principios de herencia establecidos en el algoritmo genético. En este sentido, la optimización genética del modelo ANFIS ahora denominada como ANFIS-GA para diferenciarlo de la etapa anterior, fue propuesta para ampliar el espacio de búsqueda de los parámetros de los conjuntos difusos, y de esta forma determinar si la complejidad de comportamiento de las variables de estudio interfiere en el ajuste de estas funciones al utilizar métodos tradicionales como el descenso del gradiente, tal como lo describe Goodfellow et al. (2016) y Karaboga & Kaya (2019).

El algoritmo genético comenzó el proceso de optimización partiendo de los parámetros óptimos de las funciones de membresía obtenidos en el entrenamiento convencional de

ANFIS detallado en la sección 4.5.1. Por esta razón, el rendimiento óptimo al comienzo del algoritmo genético permite obtener un coeficiente R^2 de 0.88 para el OC y uno de 0.84 para el MRR descrito en términos de cada variable dependiente. No obstante, la función objetivo del algoritmo genético evalúa el promedio de ambas medidas de rendimiento, por lo que en términos de la función objetivo genera un resultado de 0.86. Adicionalmente, en la Tabla 5.4 se presentan los parámetros de las funciones que fueron extraídos del modelo inicial de ANFIS, y que conformaron uno de los 100 cromosomas de la población inicial del algoritmo de optimización.

Tabla 5. 4. Parámetros de las funciones de membresía extraídos del modelo ANFIS, entrenado mediante métodos convencionales y que conforman el cromosoma número 100 de la población inicial del algoritmo de optimización.

Variable de entrada	Identificador de la función difusa	Centro	Desviación estándar
Corriente	$\mu f(1)$	-0.230	0.810
	$\mu f(2)$	0.215	0.643
	$\mu f(3)$	0.475	0.832
Voltaje	$\mu f(4)$	-0.569	0.613
	$\mu f(5)$	-0.918	0.842
	$\mu f(6)$	-0.059	0.835
Gap	$\mu f(7)$	0.041	0.685
	$\mu f(8)$	-0.614	0.897
	$\mu f(9)$	0.389	0.741
Área de exposición	$\mu f(10)$	-0.985	0.693
	$\mu f(11)$	0.497	0.855
	$\mu f(12)$	-0.199	0.580

La condición de paro del algoritmo de optimización consistió en finalizar el algoritmo cuando la función de aptitud no presentara cambios por más de 50 iteraciones. En la gráfica de la Figura 5.8 se describe el diagrama de convergencia donde se observa el comportamiento de la función objetivo a lo largo de la optimización. En este gráfico se puede observar que el cromosoma derivado del entrenamiento inicial se estableció como

mejor resultado de la función de aptitud al comienzo de la optimización. Si bien, este comportamiento era previsible debido a que el resto de la población fue generada de manera aleatoria. Sin embargo, se puede destacar que a lo largo del proceso fue generada descendencia con mejor aptitud en un número bajo de iteraciones. Es decir, le tomo al algoritmo alrededor de 4 generaciones para incrementar la función de aptitud. A pesar de que el cambio inicial de la función de aptitud no fue drástico en la primera descendencia, se puede visualizar un incremento notorio en las siguientes iteraciones, donde la convergencia final se estableció en un coeficiente R^2 promedio de 0.93.




Figura 5. 8. Gráfica de convergencia del algoritmo genético utilizado para optimizar las funciones de membresía del modelo ANFIS (fuente: Elaboración propia).

Una de las primeras conclusiones derivadas del comportamiento observado en la convergencia consiste en que el ajuste de los parámetros realizado por el método tradicional de ANFIS generó un mínimo de la función de pérdida de manera local, algo usualmente frecuente cuando el comportamiento a modelar es complejo como lo menciona Karaboga y Kaya (2019). A diferencia con el algoritmo genético, fue capaz de ampliar la búsqueda de los parámetros óptimos de las funciones de membresía, ya que permitió incrementar la exactitud de las predicciones reflejada por el aumento de la función de aptitud. Esta capacidad se atribuye a que el operador de selección BLX- α permite generar descendencia no solo dentro del rango de los genes padres, sino que es capaz de explorar los límites adyacentes a ellos, y de esta manera extender el espacio de búsqueda (Sato & Oyama, 2021).

5.5 Análisis del rendimiento del modelo ANFIS-GA del proceso de manufactura PECM

La gráfica de convergencia muestra el promedio de los coeficientes R^2 debido a la constitución de la función objetivo. No obstante, en la gráfica de la Figura 5.9 se presenta el coeficiente de determinación obtenido para cada variable de estudio durante las etapas de validación y prueba con el cromosoma con mejor aptitud al término de la optimización genética. Además, en la Tabla 5.5 se presentan los parámetros de las funciones de membresía optimizados.




Figura 5. 9. Coeficientes de determinación (R^2) en la etapa de validación y prueba del modelo ANFIS optimizado con el algoritmo genético (fuente: Elaboración propia).

Tabla 5. 5. Parámetros de las funciones de membresía obtenidos en la optimización.

Variable de entrada	Identificador de la función difusa	Centro	Desviación estándar
Corriente	$\mu f(1)$	-0.211	1.018
	$\mu f(2)$	0.214	0.545
	$\mu f(3)$	0.492	0.952
Voltaje	$\mu f(4)$	-0.584	0.626
	$\mu f(5)$	-0.911	0.855
	$\mu f(6)$	-0.053	1.038
Gap	$\mu f(7)$	0.036	0.799

	$\mu f(8)$	-0.595	0.634
	$\mu f(9)$	0.352	0.834
	$\mu f(10)$	-1.015	0.636
Área de exposición	$\mu f(11)$	0.425	0.888
	$\mu f(12)$	-0.172	0.882

Los parámetros descritos en la tabla anterior describen los genes del cromosoma con mejor aptitud de la optimización. Además, es posible representarlas visualmente con apoyo de Python para identificar la cobertura de cada una en el universo del discurso. En este sentido, en la Figura 5.10 se describen gráficamente las funciones para la variable de voltaje, en la Figura 5.11 para la variable de corriente, en la Figura 5.12 para la variable del área de exposición y en la Figura 5.13 para la variable del gap.




Figura 5. 10. Funciones de membresía optimizadas para la evaluación de la variable de corriente en el modelo ANFIS-GA (fuente: Elaboración propia).




Figura 5. 11. Funciones de membresía optimizadas para la evaluación del voltaje en el modelo ANFIS-GA.




Figura 5. 12. Funciones de membresía optimizadas para la evaluación del gap en el modelo ANFIS-GA (fuente: Elaboración propia).




Figura 5. 13. Funciones de membresía optimizadas para la evaluación del área de exposición en el modelo ANFIS-GA (fuente: Elaboración propia).

La constitución de cada conjunto difuso hace posible determinar el grado de pertenencia que se le asigna a cada variable de entrada (corriente, voltaje, gap, área de exposición) en la etapa de premisas, para posteriormente establecer la magnitud en que influye cada entrada con el sistema de reglas tal como se describe en la sección 4.5. Por lo tanto, según el análisis de rendimiento de ANFIS con cada una de las medidas descritas anteriormente, es posible establecer que el tipo de método empleado para la selección de los parámetros de la etapa de fuzzificación puede modificar la exactitud con que la técnica neuro difusa realiza las predicciones. Incluso, la complejidad del problema interfiere en la capacidad del modelo para ajustar correctamente los parámetros de su arquitectura. A pesar de ello, la integración del algoritmo genético demuestra al menos para el problema de manufactura excelentes resultados para mejorar la generalización de las predicciones con respecto a las observaciones del MRR y el OC.

Al igual que en el entrenamiento convencional del modelo neuro difuso, ANFIS-GA permite generar un valor específico del error RMSE para cada variable dependiente. En la Figura 5.14 se presenta un gráfico de barras para visualizar el error RMSE durante las

etapas de validación y prueba del modelo ANFIS-GA con las funciones optimizadas con el algoritmo genético.




Figura 5. 14. Errores RMSE del modelo ANFIS optimizado con el algoritmo genético (fuente: Elaboración propia).

El rendimiento del modelo ANFIS-GA también demostró una mejoría en las predicciones según el error RMSE presentado en la gráfica anterior. En general, se visualizó una disminución de esta medida en una magnitud de 0.093 para el sobre corte y 0.135 para la tasa de remoción de material con los datos de prueba. Adicionalmente, en tabla 5.6 se describe el rendimiento general con el coeficiente R^2 obtenido por cada criterio analizado durante la predicción de ambas variables de estudio.

Tabla 5. 6. Rendimiento general del coeficiente de determinación (R^2) y el error RMSE del modelo ANFIS y ANFIS-GA con el conjunto de datos de entrenamiento (validación cruzada) y prueba

	Validación		Prueba		Validación		Prueba	
	cruzada (R^2)		(R^2)		cruzada (RMSE)		(RMSE)	
	OC	MRR	OC	MRR	OC	MRR	OC	MRR
ANFIS	0.94	0.91	0.88	0.84	0.299	0.335	0.394	0.463
ANFIS-GA	0.97	0.95	0.94	0.92	0.256	0.289	0.301	0.328

A grandes rasgos, el modelo ANFIS-GA permitió plasmar el comportamiento no lineal del proceso de manufactura con mayor fidelidad. Esto es observable mediante el gráfico de ajustes de la Figura 5.15, donde se aprecian las predicciones y las observaciones de la variable de sobre corte utilizando el conjunto de prueba.




Figura 5. 15. Gráfico de ajustes de las predicciones y las observaciones normalizadas para la variable de sobre corte (OC) (fuente: Elaboración propia).

Tomando en cuenta el gráfico de la figura anterior se puede establecer que no existe un sobre ajuste en las predicciones del sobre corte, y que se tiene un rendimiento eficaz considerando la no linealidad y complejidad que involucran las variables de estudio. Por otro lado, en la gráfica de la Figura 5.16 se presenta el ajuste de las predicciones y observaciones para la tasa de remoción de material. Al igual que el caso anterior, se observa una predicción exacta con relación a las observaciones generadas a partir de los experimentos, pero mantienen un comportamiento alejado al que podría observarse en un caso de sobre ajuste con un error casi nulo.




Figura 5. 16. Gráfico de ajustes de las predicciones y las observaciones normalizadas para la variable de tasa de remoción de material (MRR) (fuente: Elaboración propia).

El apoyo visual del gráfico de ajuste permite visualizar el rendimiento del modelo tomando en cuenta la pendiente de referencia con origen intercepto en cero y una pendiente en uno, cuyos límites describen el valor mínimo y máximo de las predicciones. No obstante, es posible complementar este análisis con la representación de la Figura 5.17, la cual muestra el comportamiento que siguen los datos del conjunto de prueba y la tendencia obtenida por parte de las predicciones del modelo ANFIS-GA con la variable del sobre corte. Con este diagrama se aprecia con mayor claridad la exactitud resultante del modelo optimizado, destacando que a pesar de la complejidad en el comportamiento del sobre corte, el modelo neuro difuso es capaz de generalizar adecuadamente.




Figura 5. 17. Comportamiento de los datos de prueba y las predicciones del modelo ANFIS-GA para la variable de sobre corte (fuente: Elaboración propia).

Por otro lado, sucede una tendencia similar con la tasa de remoción de material. El comportamiento de las predicciones para esta variable se describe en la Figura 5.18, y se aprecia al igual que el caso anterior cómo es posible generalizar con exactitud con los datos del conjunto de prueba. Además, analizando con mayor detalle la estructura del comportamiento de ambas variables, se puede identificar que presentan una tendencia similar en ambos casos, pero no idéntica. Esto puede atribuirse a que la tasa de remoción de material y el sobre corte presentan una correlación alta de 0.9, pero no precisamente lineal, según el análisis de correlación detallado en la sección 5.1. Incluso, se puede identificar que la magnitud de los cambios no es directamente proporcional, debido a que tanto el error como el coeficiente de determinación mantienen un valor particular para cada variable de estudio. Debido a todas estas peculiaridades, son aplicados grandes

esfuerzos para incrementar la comprensión del maquinado electroquímico por pulsos y los diferentes métodos de manufactura no convencional, y para el caso de la presente investigación, integrando un proceso de optimización al modelo neuro difuso.




Figura 5. 18. Comportamiento de los datos de prueba y las predicciones del modelo ANFIS-GA para la variable de la tasa de remoción de material (fuente: Elaboración propia).

Hasta este punto de la investigación, se presentan resultados sobre el rendimiento del modelo neuro difuso utilizando la normalización z-score, que mantiene una distribución de la media en cero y una desviación en uno para un mejor manejo de los datos, disminución del sesgo y facilidad de interpretación (Patil, et al., 2022). Sin embargo, en el esquema de la Figura 5.19 se presenta la gráfica de residuos del sobre corte en términos de la unidad de medida original para apreciar el error de los valores predichos por el modelo y las observaciones cuantificadas durante los experimentos, y de esta manera, observar en que magnitud difieren de las predicciones.




Figura 5. 19. Gráfica de residuos del sobre corte (fuente: Elaboración propia).

Los residuos mostrados en de la Figura 5.19 permiten establecer que las predicciones del sobre corte presentan una exactitud por debajo de los 20 μm en su gran mayoría, y solo algunos datos se acercan a un residuo mayor alrededor de los 30 μm . Otro aspecto relevante de esta figura se basa en que no se identifican patrones específicos en las predicciones, lo que indica que el modelo es capaz de capturar adecuadamente las relaciones en los datos. Por otro lado, el comportamiento de los datos sugiere homocedasticidad, permitiendo establecer que presentan una varianza constante y no tienden a sesgarse a medida que cambian las predicciones. Para verificar este argumento fue aplicada la prueba estadística de Breusch-Pagan (Pesaran, 2021), obteniendo un valor estadístico p de 0.160, lo que demuestra la ausencia de heterocedasticidad.

En cuanto a la tasa de remoción de material, en la gráfica de la Figura 5.20 se presentan los residuos obtenidos con los datos de prueba y las predicciones generadas con el modelo neuro difuso. Los resultados de la prueba Breusch-Pagan en esta variable generaron un valor estadístico p de 0.058, el cual se establece por arriba del nivel de significancia. A diferencia de la variable de sobre corte, la tasa de remoción de material mantiene una escala totalmente distinta, lo que generalmente ocasiona dificultades para capturar correctamente el comportamiento de las variables en modelos no estandarizados.




Figura 5. 20. Gráfico de residuos de la tasa de remoción de material (fuente: Elaboración propia).

La complejidad del proceso PECM derivado de la diversidad de principios químicos y eléctricos (Groover, 2020), genera grandes retos no solo para las descripciones algebraicas, sino también para los modelos computacionales como se observó en la literatura y el desarrollo de esta investigación. Para contrastar este argumento se aplicaron una serie de algoritmos adicionales para analizar la exactitud de otro tipo de estrategias y la obtenida en la presente investigación. Se utilizó el mismo conjunto de datos para predecir el comportamiento del proceso de manufactura con una red neuronal profunda (DNN, por las siglas en inglés de Deep Neural Network), una máquina de soporte vectorial (SVM, por las siglas en inglés de Support Vector Machine) y un modelo de regresión no lineal (NLR, por las siglas en inglés de Non-Linear Regression). El coeficiente de determinación (R^2) promedio de ambas variables de estudio fue utilizado como medida de rendimiento en cada método. En el esquema de la Figura 5.21 se presentan los resultados obtenidos en cada estrategia.




Figura 5. 21. Coeficiente de determinación (R^2) obtenido con una red neuronal profunda (RNN), una máquina de soporte vectorial (SVM), un modelo de regresión no lineal (NLR) y el modelo ANFIS-GA (fuente: Elaboración propia).

Los resultados de cada método descritos en la Figura 5.21 demuestran el argumento sobre la dificultad para modelar el proceso de manufactura no solo para métodos algebraicos sino también para estrategias computacionales, lo que implica que el área de investigación en PECM, e incluso en otros métodos no convencionales aun es extenso. En la Tabla 5.7 se presenta un resumen general sobre los resultados alcanzados en las investigaciones con mayor relevancia en el estado del arte y los resultados obtenidos en esta investigación. En esta tabla se aprecian distintos puntos de vista para atender el problema de modelado no convencional, recordando que tanto ECM como PECM son parte de un método de manufactura que comparten grandes rasgos (Groover, 2010) (McGeough, 1974). Si bien, algunos enfoques pretenden predecir el comportamiento del proceso de manufactura bajo una configuración específica, otros son empleados bajo otro enfoque. Es decir, buscan indagar sobre el comportamiento de las variables de respuesta para criterios distintos a los empleados durante el entrenamiento del algoritmo, como es el caso de esta investigación. Por esta razón, dividir al conjunto de datos para entrenar, validar y probar generó gran importancia en esta investigación, y así lograr sustentar el rendimiento del modelo.

Tabla 5. 7. Resultados de mayor relevancia en el modelado de procesos no convencionales en el estado del arte y en la presente investigación.

Autor	Método de manufactura	Tipo de modelo	Variables modeladas	División del conjunto de datos (%)	Medidas de rendimiento evaluadas	Resultados de las medidas de rendimiento
Investigación desarrollada	PECM	ANFIS-GA	MRR / OC	80 / 20	R^2 RMSE	0.94 / 0.92 0.301 / 0.328
(Chuang, et al., 2023)	EDM / ECM	ANN	Área	90 / 10	MAE	1.32
(Sada & Ikpeseni, 2021)	NR*	ANN / ANFIS	MRR	70 / 15 / 15	R^2	0.921 / 0.732
(Ji & Min, 2022)	ECM	ANN	DP / LG	NR*	Error relativo	0.053
(Wu, et al., 2022)	PECM	CNN	DC*	NR*	MSE	7.60
(Chakraborty & Das, 2019)	EDM / ECM	FL*	MRR / OC / SR	NA*	NA*	NA*
(Rai & Kumar, 2020)	ECM	MSR*	MRR / OC / SR	NA*	R^2	0.722 / 0.71 / 0.96
(Singh, et al., 2022)	ECM	MSR*	MRR / SR	NR*	R^2	0.845 / 0.748
(Nagarajan, et al., 2022)	ECM	<i>TOPSIS</i> *	MRR / Nickel	NR*	R^2	0.903 / 0.922

* NR: No reportado, FL: Lógica difusa, MSR: Metodología de superficie de respuesta, TOPSIS: Técnica para el Orden de Preferencia por Similitud con la Solución Ideal, NA: No aplicado, DC: Dimensión de Cavidades, DP: Profundidad, LG: Longitud.

Por otra parte, según los resultados identificados en la literatura y que son detallados en el capítulo del estado del arte, se puede observar que se obtuvo un rendimiento viable para predecir la tasa de remoción de material y el sobre corte, logrando incrementar la capacidad para capturar la variabilidad de los datos con ayuda del algoritmo genético. En este caso en particular, fueron de vital relevancia las características del método evolutivo, ya que se consideraron tanto características del problema de manufactura como la composición de las funciones difusas. Además, el análisis del rendimiento del modelo ANFIS entrenado de manera convencional mediante métodos basados en el descenso del gradiente, y la adición de una optimización genética, permitió establecer que aunque el método neuro difuso mantiene mayor exactitud que otros métodos computacionales, presenta ciertas deficiencias cuando el problema abordado es complejo, con tendencias de no linealidad, pocos datos y multivariable, ya que por medio de la adición del algoritmo genético se logró incrementar la exactitud de las predicciones del modelo neuro difuso.



CAPÍTULO 6.

CONCLUSIONES Y TRABAJO A FUTURO

En la presente investigación se desarrolló un modelo computacional basado en un sistema adaptativo de inferencia neuro difuso (ANFIS), para modelar el comportamiento de dos variables de vital relevancia en un proceso de maquinado electroquímico por pulsos: la tasa de remoción de material y el sobre corte. Para llevar esto a cabo, se realizó un estudio profundo de la literatura especializada en el proceso de manufactura, además del estado del arte relacionado al problema planteado en la investigación. Durante este proceso fueron propuestos un conjunto de atributos relacionados con las variables de estudio. Posteriormente, fueron utilizados como punto de referencia para generar un diseño experimental factorial 3^k utilizando un prototipo del proceso de manufactura. Como resultado de este proceso experimental, se integró un conjunto de datos inicial con los atributos seleccionados y las observaciones de su respuesta.

Una vez integrado el conjunto de datos inicial fue aplicado la prueba de correlación Spearman y una regresión múltiple para analizar la significancia de los atributos con las variables dependientes. Como resultado, los parámetros de voltaje, corriente, distancia entre electrodos y área de exposición fueron establecidas como atributos de mayor significancia, mientras que la frecuencia fue eliminada debido a la baja correlación. Finalmente, como parte de una etapa de preprocesamiento, se realizó una depuración de los datos atípicos y una normalización para un mejor rendimiento en el modelo.

Por otra parte, durante el establecimiento de la arquitectura del modelo se efectuó un estudio para determinar los parámetros iniciales en el método neuro difuso, estableciendo al sistema de inferencia Takagi-Sugeno como método para generar el mapeo de salida en la etapa consecuente del algoritmo. Además, fueron seleccionadas las funciones de tipo gaussianas como conjuntos difusos con mejor rendimiento según el análisis del error en la salida y un análisis en la significancia mediante ANOVA, estableciendo de esta manera los parámetros de la arquitectura inicial.

El proceso de entrenamiento utilizado para modelar las variables de la tasa de remoción de material y sobre corte fue desarrollado en dos etapas, utilizando en ambos casos una división de los datos de 80 % para entrenar y validar utilizando validación cruzada *k-fold*, y 20 % para realizar la prueba. La primera etapa consistió en entrenar el algoritmo utilizando los métodos convencionales basados en el principio del descenso del gradiente. Posteriormente, se implementó un algoritmo genético para optimizar los conjuntos difusos del modelo generado previamente.

El rendimiento de ambos criterios fue evaluado utilizando el coeficiente de determinación R^2 y la raíz del error cuadrático medio. Como resultado, se obtuvo una eficacia del modelo ANFIS entrenado mediante el descenso del gradiente de 0.88 y 0.84 en la medida R^2 y uno de 0.394 y 0.463 para la raíz del error cuadrático medio, en la predicción de la tasa de remoción de material y sobre corte, respectivamente. Por otro lado, se observó un rendimiento de la medida R^2 del algoritmo ANFIS optimizado con el algoritmo genético de 0.94 para el sobre corte y uno de 0.92 para la tasa de remoción de material, mientras que uno de 0.301 y 0.328 en el error.

Según el análisis de los resultados, se concluyó que el modelo entrenado mediante métodos basados en el descenso del gradiente presenta deficiencias debido a la complejidad del comportamiento de la tasa de remoción de material y el sobre corte. Esto debido a que en la literatura se describe que el proceso de manufactura sigue un comportamiento no lineal a consecuencia de los principios químicos y eléctricos identificados en el proceso, además de la multi variedad de parámetros. Estos resultados permitieron establecer que el rendimiento menor de ANFIS, se produjo por un ajuste del modelo en un óptimo local con el descenso del gradiente. Mientras que, por otro lado, el

algoritmo genético fue capaz de establecer los valores óptimos de las funciones difusas en un óptimo global, justificando así el incremento de las medidas de rendimiento. Esta capacidad del algoritmo genético para alcanzar un óptimo global se atribuyó al operador de cruce BLX- α , el cual permitió extender el espacio de búsqueda no solo dentro de los límites de los genes padres sino también en su adyacencia.

Finalmente, el rendimiento del modelo optimizado fue visualizado mediante gráficos de ajuste y el error de residuos, donde además se logró identificar homocedasticidad en la varianza, al obtener un valor estadístico de la prueba Breusch-Pagan de 0.160 para el sobre corte y uno de 0.058 para la tasa de remoción de material, indicando que las predicciones no tienden a sesgarse a medida que cambian las predicciones.

Como conclusión adicional se establece que parte de las limitaciones de la investigación se centran en la carencia de datos abiertos del proceso de maquinado electroquímico por pulsos para la investigación. Por esta razón, el conjunto de datos utilizado para el modelo neuro difuso fue obtenido mediante una caracterización desarrollada con un prototipo de manufactura de este tipo. A pesar de que este prototipo cumple con las necesidades fundamentales del maquinado electroquímico por pulsos descritas en esta investigación, se tienen algunas limitaciones para estudiar en su totalidad el proceso, en las cuales se destacan la falta de elementos para implementar herramientas rotatorias, incluir distintos tipos de señales de polarización o modificar el flujo de electrolito, lo que en esencia, podría integrarse al modelo para aprovechar al máximo las capacidades de predicción del sistema adaptativo de inferencia neuro difuso. Por esta misma razón, se propone como trabajo a futuro integrar otro tipo de variables que son empleadas en la literatura para observar las capacidades del modelo ANFIS en la predicción de las características de salida utilizadas, e incluso de variables de respuesta adicionales, según las necesidades que se establezcan para mejorar la eficiencia de este proceso.

Referencias

Abdel, H. & El-Hofy, G., 2005. *Advance Machining Processes*. 1 ed. Alexandria: McGraw-Hill.

Adam, E., 2020. *Instrumentacion y control de procesos*. 3 ed. s.l.:UNL.

Alvarado, R., Leyva, J., Hernandez, A. & Granda, E., 2018. Radial basis function neural network for modeling an electrical discharge machining drilling process. *2018 IEEE International Autumn Meeting on Power, Electronics and Computing (ROPEC 2018)*, pp. 1-6.

Ben, M., Plevris, V. & Malekjafarian, A., 2023. Development of Hybrid Adaptive Neural Fuzzy Inference System-Based Evolutionary Algorithms for Flexural Capacity Prediction in Corroded Steel Reinforced Concrete Beam. *Arabian Journal for Science and Engineering*, Volumen 48, pp. 13147-13163.

Bhattacharyya, B. & Doloi, B., 2019. *Modern machining technology: Advanced, hybrid, micro machining and super finishing technology*. s.l.:Academic Press.

Chai, Y., Jia, L. & Zhang, Z., 2009. Mamdani model based adaptative neural fuzzy inference system and its application in traffic level of service evaluation. *Computer Society*, pp. 555-559.

Chakraborty, S. & Das, P., 2019. Fuzzy modeling and parametric analysis of non-traditional machining processes. *Management and Production Engineering Review*, 10(3), pp. 111-123.

Cho, H. & Eo, S., 2016. Outlier detection for mass spectrometric data. *Methods in Molecular Biology*, Volumen 1362, pp. 91-102.

Chuang, M., Jan, C., Wang, Y. & Hsu, Y., 2023. Intelligent Monitoring and Compensation between EDM and ECM. *Applied Sciences*, 13(2), pp. 1-16.

Davis, S., Cremaschi, S. & Eden, M., 2018. Efficient Surrogate Model Development: Impact of Sample Size and Underlying Model Dimensions. *Computer Aided Chemical Engineering*, Volumen 44, pp. 979-984.

Dumitrescu, C., Ciotirnae, P. & Vizitiu, C., 2021. Fuzzy Logic for Intelligent Control System Using Soft Computing Applications. *Sensors*, 21(8), pp. 1-33.

Elhami, S. & Razfar, M., 2017. Analytical and experimental study on the integration of ultrasonically vibrated tool into the micro electrochemical discharge drilling. *Precision Engineering*, Volumen 47, pp. 423-433.

Feng, Z., Granda, E. & Wayne, H., 2016. Experimental Investigation of Vibration-Assisted Pulsed Electrochemical Machining. *Procedia Manufacturing*, Volumen 5, pp. 798-814.

Godoy, M., 2021. *Artificial Intelligence for Smarter Power Systems: Fuzzy Logic and Neural Networks*. s.l.:Institution of Engineering & Technology.

Goodfellow, I., Bengio, Y. & Courville, A., 2016. *Deep Learning*. s.l.:MIT Press.

Groover, M., 2020. *Fundamentals of modern manufacturing: materials, processes, and systems (Seventh Edition)*. s.l.:John Wiley & Sons.

Groover, P., 2010. *Fundamentos de manufactura moderna*. 4 ed. México: McGrawHill.

Gupta, K., Jain, N. & Laubscher, R., 2016. *Hybrid machining processes: perspectives on machining and finishing*. 1 ed. s.l.:Springer.

Han, Y., Zhihong, Z. & Huiwen, W., 2010. Adaptative neuro fuzzy inference system for clasification of water quality status. *Journal of environmental sciences* , Volumen 22, pp. 1891-1896.

Idrosov, T., Zaitzev, A. & Zhitnikov, V., 2004. Estimation of the process localization at the electrochemical machining by microseconds pulses of bipolar current. *Journal of Materials Processing Technology*, Volumen 149, pp. 479-485.

Jang, J., Mizutani, E. & Sun, C., 1997. *Neuro-Fuzzy and Soft Computing. A computational approach to learning and machine intelligence*. London: Prentice Hall.

Ji, F. & Min, B., 2022. Simulated annealing ANN approach for parameter optimization of micro-scaled flow channels formation by electrochemical machining. *International Journal of Electrochemical Science*, 17(5), pp. 1-15.

Kaplan, G., Öz, A., Bayrak, B. & Aydın, A., 2023. The effect of geopolymer slurries with clinker aggregates and marble waste powder on embodied energy and high-temperature resistance in prepacked concrete: ANFIS-based prediction model. *Journal of Building Engineering*, Volumen 67, pp. 1-22.

Karaboga, D. & Kaya, E., 2019. *Adaptive network based fuzzy inference system (ANFIS) training approaches: a comprehensive survey*. Netherlands, Springer .

Kats, Z. & Tibbles, C., 2005. Analysis of micro-scale EDM process. *Springer-Verlag London*, Volumen 25, pp. 923-928.

Kennedy, C., Shakeri, J., Amimi, H. & Bunyamin, A., 2021. Application on ANFIS hibrids to predict coefficient of curvantage and uniformity of treated unsaturated lateritic soil for sustainable earthwords. *Cleaner materials* , Volumen 1.

Klocke, F., Heidemanns, L., Zeis, M. & Klink, A., 2018. A Novel Modeling Approach for the Simulation of Precise ElectrochemicalMachining (PECM) with Pulsed Current and Oscillating Cathode. 19th CIRP Conference on Electro Physical and Chemical Machining, 23-27 April 2018, Bilbao, Spain. pp. 499-504.

Klocke, F. y otros, 2013. Modeling and simulation of the electrochemical machining (ECM) material removal process for the manufacture of aero engine components. *Procedia CIRP*, Volumen 8, pp. 265-270.

Klocke, F., Zeis, M. & Klink, A., 2012. Technological and economical capabilities of manufacturing titaniumand nickel-based alloys via Electrochemical Machining (ECM). *Key Engineering Materials* , Volumen 504, pp. 1237-1242.

Kloke, F., Zeis, M. & Klink, A., 2015. Interdisciplinary modelling of electrochemical machining for engine blades. *CIRP Annal - Manufacturing Technology*, 64(1), pp. 217-220.

- Kozak, J., 1998. Mathematical Models for computer simulations of electrochemical machining processes. *Journal of materials processing technology*, Volumen 76, pp. 178-175.
- Kulczycki, P. & Kruszewski, D., 2017. Identification of atypical elements by transforming task to supervised form with fuzzy and intuitionistic fuzzy evaluations. *Applied Soft Computing*, Volumen 60, pp. 623-633.
- Kumar, H., 2017. Some recent defuzzification methods. En: *Theoretical and Practical Advancements for Fuzzy System Integration*. s.l.:IGI Global, pp. 31-48.
- Kushwaha, O., Uthayakumar, H. & Kumaresan, K., 2023. Modeling of carbon dioxide fixation by microalgae using hybrid artificial intelligence (AI) and fuzzy logic (FL) methods and optimization by genetic algorithm (GA). *Environmental Science and Pollution Research*, 30(10), pp. 24927-24948.
- Labid, A., Keasberry, V., Atkinson, J. & Frost, H., 2011. Towards next generation electrochemical machining controls. A fuzzy control approach to ECM. *Expert systems with applications*, 38(6), pp. 7486-7493.
- Lendek, Z., Guerra, T., Babuska, R. & Schutter, B., 2011. *Stability analysis and nonlinear observer design using Takagi-Sugeno fuzzy models*. Berlin : Springer.
- Leyva, J., 2018. Modelado del proceso de maquinado ECDM mediante logica difusa. *Tesis de maestria. Corporacion Mexica de Investigación en materiales*.
- Liu, L., 2008. *An Intelligent Control Design for Non-Linear MIMO Processes. Conference on Human System Interactions*. Krakow, Poland, pp. 400-404.
- Liu, Q. & Wang, L., 2021. t-Test and ANOVA for data with ceiling and/or floor effects. *Behavior Research Methods*, 53(1), pp. 264-267.
- Liu, X. y otros, 2023. Self-Supervised Learning: Generative or Contrastive. *IEEE Transactions on Knowledge and Data Engineering*, 35(1), pp. 857-876.

Lyubimov, V., Volgin , V. & Krasilnikov, V., 2019. *Theoretical Investigation of Current Pulses Parameters in Electrochemical Machining with Micro - and Nanoparameters*. Sochi, Russia, 2019 International Russian Automation Conference (RusAutoCon).

MacGillivray, B., 2017. Characterising bias in regulatory risk and decision analysis: An analysis of heuristic applied in health technology appraisal, chemical regulation, and climate change governance.. *Environement international*, Volumen 105, pp. 20-33.

Madhumangal, P., Sovan, S. & Ganesh, G., 2020. *Modern Trends in Fuzzy Graph Theory*. Singapore: Springer.

McGeough, J., 1974. Principles of electrochemical machining, CRC Press, 1974. ISBN 9780470584132.

Melo, O., López, L. & Melo, S., 2020. *Diseño de experimentos: Métodos y aplicaciones*. 2° ed. Colombia: Universidad Nacional de Colombia Facultad de Ciencias.

Morteza, A., 2017. Controlling Electrochemical Machining By Using a Fuzzy Logic Approach. *Journal of Modern Processes in Manufacturing and Production*, 6(2), pp. 61-71.

Muhammad, R., 2021. A fuzzy logic model for the analysis of ultrasonic vibration assisted turning and conventional turning of Ti-based alloy. *Materials*, 14(21), pp. 1-23.

Munasypop, R. & Masalimov, K., 2017. Neural Networks models for diagnostics of complex technical objects state by example of electrochemical treatment process. *2nd International Ural Conference on Measurements (UralCon)* , pp. 156-160.

Nagarajan, V. y otros, 2022. Meta-heuristic technique-based parametric optimization for electrochemical machining of monel 400 alloys to investigate the material removal rate and the sludge. *Applied Science*, 12(6), pp. 1-23.

Naseem , S., Andrew , S. & Yawney,, J., 2023. Intelligent estimation: A review of theory, applications, and recent advances. *Digital Signal Processing*, Volumen 135, pp. 1-13.

Nopalera, I., 2021. Algoritmo de control difuso para el ajuste de polarización de un proceso de maquinado electroquímico por pulsos. Tesis de Maestría. *Universidad Autónoma del Estado de México*.

Patil, D., Wadhvani, R., Shukla, S. & Gupta, M., 2022. Adaptive wind data normalization to improve the performance of forecasting models. *Wind Engineering*, 46(5), pp. 1606-1617.

Pekala, B., 2019. *Uncertainty Data in Interval Valued Fuzzy Set Theory. Properties, Algorithms and Applications*. Poland: Springer.

Pesaran, M., 2021. General diagnostic tests for cross-sectional dependence in panels. *Empirical Economics*, 60(1), pp. 13-50.

Pourasl, H., Javidani, M., Khojastehnezhad, V. & Vatankhah, R., 2022. The Performance Prediction of Electrical Discharge Machining of AISI D6 Tool Steel Using ANN and ANFIS Techniques: A Comparative Study. *Crystals*, 12(3), pp. 1-18.

Rai, V. & Kumar, J., 2020. Study of Influence of Process Parameters in Electrochemical Machining of AISI-304 Stainless Steel. *IOSR Journal of Mechanical and Civil Engineering (IOSR-JMCE)*, 17(4), pp. 1-9.

Rama, S., Sravan, C., Pandu, V. & Padmanabhan, G., 2009. Fuzzy Logic based forward modeling of electrochemical machining process. *World Congress on Nature & Biologically Inspired Computing*, pp. 1431-1435.

Reyes, C. & Torres, A., 2022. Fuzzy logic and fuzzy systems. En: A. Torres, ed. *Biosignal Processing and Classification Using Computational Learning and Intelligence*. s.l.:Academic Press, pp. 153-176.

Rosa, J. y otros, 2020. *Using Artificial Neural Networks for Analog Integrated Circuit Design Automation*. Switzerland: SpringerBriefs in Applied Sciences.

Ruspini, E., Bonissone, P. & Pedrvicz, W., 1998. *Handbook of Fuzzy Computation*. Bristol : IOP Publishing Ltd.

Sada, S. & Ikpeseni, S., 2021. Evaluation of ANN and ANFIS modeling ability in the prediction of AISI 1050 steel machining performance. *Heliyon*, 7(2), pp. 1-9.

Sagathiya, N., Prajapati, A., Desai, K. & Dave, H., 2021. ANFIS-Based Prediction Model for Tool Wear Criteria During Orbital Electrical Discharge Machining of Ti6Al4V. In *Lecture Notes in Mechanical Engineering*, pp. 277-291.

Sato, M. & Oyama, A., 2021. *Comparative Study of Crossovers for Decision Space Diversity of Non-Dominated Solutions*. Orlando, IEEE, pp. 1-8.

Schaarschmidt, I. y otros, 2019. Implementation of the Machine Tool-Specific Current and Voltage Control Characteristics in Multiphysics Simulation of Electrochemical Precision Machining. *Procedia CIRP*, Volumen 82, pp. 237-242.

Sekar, T. y otros, 2023. *Modeling of Rotary Tool Adapted Electrochemical Machining of AISI 202*. s.l., IEEE Computer Society, pp. 1-7.

Singh, K., Singh, Y. & Kumar, S., 2020. Integration of GA and neuro-fuzzy approaches for the predictive analysis of gas-assisted EDM responses. *SN Applied Sciences*, 2(137), pp. 1-14.

Singh, N., Singh, Y., Kumar, S. & Sharma, A., 2019. Comparative study of statistical and soft computing-based predictive models for material removal rate and surface roughness during helium-assisted EDM of D3 die steel. *SN Applied Sciences*, 1(6), pp. 1-12.

Singh, P., Sangle, S., Singh, A. & Guleria, V., 2022. Parametric modeling and optimization of electrochemical machining of EN-31 alloy steel. *Sādhanā*, 47(4).

Sun, J., Dai, Y., Zhao, K. & Jia, Z., 2021. Second order Takagi-Sugeno fuzzy model with domain adaptation for nonlinear regression. *Information Sciences*, Volumen 570, pp. 34-51.

Takahashi, M. & Kita, H., 2001. *A crossover operator using independent component analysis for real-coded genetic algorithms*. Seoul, IEEE, pp. 643-649.

Trillas, E. & Eciolaza, L., 2015. *Fuzzy Logic. An Introductory Course for Engineering*. Londres: Springer.

Tsai, C. & Chiang, M., 2023. *Handbook of Metaheuristic Algorithms: From Fundamental Theories to Advanced Applications*. s.l.:Elsevier.

Tyagi, K., Rane, C. & Manry, M., 2022. Supervised learning. En: *Artificial Intelligence and Machine Learning for EDGE Computing*. s.l.:Elsevier, pp. 3-22.

Vanneschi, L. & Silva, S., 2023. Artificial Neural Networks. *Natural Computing Series* , pp. 161-204.

Welper, G., 2022. Universality of gradient descent neural network training. *Neural Networks*, Volumen 150, pp. 259-273.

Wen, L., Gao, L. & Zhang, L., 2012. *Modeling the performance of electrochemical machining process using free pattern search*. China, IEEE, pp. 465-471.

Wu, M. y otros, 2022. Profile prediction in ECM using machine learning. *Procedia CIRP*, Volumen 113, pp. 410-416.

Xu, K., Ren, K. & Zhang, Z., 2018. *Process charcterisic modelling and front gap control algorithm in pulsed electrochemical slot machining. The 9th International Conference on Modelling, Identification and Control*. China, s.n.

Younas, T., Manzoor, M. & Kumari, J., 2017. Non Conventional Machining Processes as Expedient Alternatives for Conventional Machining Processes. 3rd International Conference on Engineering Technologies and Social Sciences (ICETSS). *IEEE*, p. 5.

Yu, H., Hutson, A. & A., D., 2022. A robust Spearman correlation coefficient permutation test. *Communications in Statistics - Theory and Methods*., pp. 1-13.

Zadeh, L., 1988. Fuzzy Logic. *Computer*, 21(4), pp. 83-93.

Zaytzev, A. y otros, 2004. Precise pulse electrochemical machining by bipolar current: Aspects of effective technological aplication. *Journal of Materials Processing Technology*, 149(3), pp. 419-425.

Zhi, H. & He-qing, L., 2006. Nonlinear system identification based on Adaptative Neural Fuzzy Inference System. *2006 International Conference on Communications, Circuits and Systems*, pp. 2067-2069.