



UNIVERSIDAD AUTÓNOMA DEL ESTADO DE MÉXICO



CENTRO UNIVERSITARIO UAEM ATLACOMULCO

**Modelado de un proceso de manufactura no convencional
basado en lógica difusa y un micro algoritmo genético**

T E S I S

MAESTRÍA EN CIENCIAS DE LA COMPUTACIÓN

PRESENTA:

Ing. Silvia Salas Hernández

Tutor principal

Dr. Juan Fernando García Mejía

Tutores adjuntos

Dr. Everardo Efrén Granda Gutiérrez

Dr. Carlos Eduardo Torres Reyes

Noviembre 2021

RESUMEN

La manufactura, es un proceso para la construcción de piezas pequeñas como tornillos, tuercas, broqueles, aretes entre otros productos, cuyo término fue definido por primera vez en el año de 1567; se deriva de las palabras en latín manus que significa manos y factus que significa hacer, derivado de los términos anteriores manufactura significa hecho a mano, la construcción de los productos antes mencionados se realizan bajo dos enfoques: maquinado convencional y no convencionales como el Proceso de Maquinado Electroquímico por Descarga Eléctrica (ECDM) (Groover, 2007), (Kalpakjian & Schmid, 2002).

El proceso de Maquinado Electroquímico por Descarga Eléctrica ECDM ha sido objeto de modelado empleando utilizando técnicas de Soft Computing , una de ellas es lógica difusa, en dos propuestas diferentes presentadas por (Lin, et al., 2000) y (Antil, et al., 2014) donde toman como parámetros de entrada voltaje, corriente, ciclo de trabajo, polaridad de la pieza de trabajo, fluido dieléctrico, tiempo de encendido y como parámetros de salida, la tasa de remoción, desgaste de la pieza, y rugosidad de la superficie en ambos casos el proceso a modelar es validado a través de conjuntos experimentales del proceso.

Los modelos difusos de los procesos de manufactura no convencional son susceptibles a convertirse en problemas optimización. Esta es una una de las áreas de la ingeniería, que se constituye como un conjunto de postulados cuya finalidad es encontrar en un espacio de búsqueda el mejor resultado posible o la óptima solución a problemas de alguna rama del conocimiento científico en entornos económicos, sociales y naturales si y solo si estos son modelables a través de funciones matemáticas (Gen & Cheng, 2000) .

En la presente investigación se construye un modelo computacional para un proceso de manufactura no convencional a partir de técnicas de Soft Computing específicamente lógica difusa para la construcción del modelo y un micro algoritmo genético como optimizador de funciones de membresía para los parámetros de Tasa de Remoción de Material y Diámetro de Sobrecorte.

ABSTRACT

Manufacturing is a process for the construction of small parts such as screws, nuts, buckles, earrings among other products, whose term was defined for the first time in the year 1567; It is derived from the Latin words manus which means hands and factus which means to make, derived from the previous terms manufactura means handmade, the construction of the aforementioned products are carried out under two approaches: conventional machining and unconventional machining such as the Process of Electrochemical Electric Discharge Machining (ECDM) (Groover, 2007), (Kalpakjian & Schmid, 2002).

The process of Electrochemical Machining by Electric Discharge ECDM has been modeled using Soft Computing techniques, one of them is fuzzy logic, in two different proposals presented by (Lin, et al., 2000) and (Antil, et al. , 2014) where they take as input parameters voltage, current, duty cycle, polarity of the workpiece, dielectric fluid, ignition time and as output parameters, the removal rate, part wear, and roughness of the surface in both cases the process to be modeled is validated through experimental sets of the process.

Fuzzy models of unconventional manufacturing processes are susceptible to becoming optimization problems. This is one of the areas of engineering, which is constituted as a set of postulates whose purpose is to find in a search space the best possible result or the optimal solution to problems of some branch of scientific knowledge in economic, social and economic environments. natural if and only if they are modelable through mathematical functions (Gen & Cheng, 2000).

In the present investigation, a computational model is built for an unconventional manufacturing process from Soft Computing techniques specifically fuzzy logic for the construction of the model and a genetic micro algorithm as an optimizer of membership functions for the Material Removal Rate parameters. Overcut Material and Diameter.

INDICE

RESUMEN	2
ABSTRACT	3
INDICE DE TABLAS	6
INDICE DE FIGURAS	7
PRESENTACIÓN	9
Capítulo 1 RACIONALIDAD DEL OBJETO DE INVESTIGACIÓN.....	11
1.1 Fundamentación inicial	11
1.2 Definición del problema.....	14
1.2.1 Objetivos de la investigación	15
1.2.2 Objetivo General	16
1.2.3 Objetivos específicos.....	16
1.2.4 Preguntas de investigación	16
1.3 Justificación	17
1.4 Requerimientos del proyecto	17
1.5 Impactos.....	18
1.6 Hipótesis.....	18
Capítulo 2 ESTADO DE ARTE	19
2.1 Identificación de sistemas.....	19
2.2 Topologías de sistemas difusos para la identificación de sistemas	21
2.3. Modelado de procesos de manufactura no convencional con lógica difusa	31
2.4 Sistema Híbrido de Inferencia Neuro-difuso.	38
2.5 Algoritmos Evolutivos.	42
2.6 Algoritmo genético canónico	45
2.7 Micro algoritmo genético.....	57
Capítulo 3 METODOLOGÍA.....	60
3.1.- Tipo de Investigación	60
3.2.- Datos a utilizar	63
3.3.- Topología del micro-algoritmo a usar.....	65
3.4.- Propuesta del modelo difuso.....	66
3.5.- Experimentos	69
Capítulo 4 RESULTADOS Y DISCUSIONES	71
4.1 Modelado del MRR con lógica difusa y un algoritmo genético canónico.....	71

4.2. Modelado del MRR con lógica difusa y un micro algoritmo genético canónico	75
4.3. Modelado del DOC con lógica difusa y un algoritmo genético canónico	80
4.4. Modelado del DOC con lógica difusa y un micro genético.	84
CONCLUSIONES	91
REFERENCIAS.....	93

INDICE DE TABLAS

Tabla 2.1 Modelos de los procesos no convencionales de manufactura basados en lógica difusa	35
Tabla 3.1. Datos de validación	64
Tabla 3.2. Datos de entrenamiento.	64
Tabla 3.3 Conjuntos del Sistema difuso propuesto	68
Tabla 3.4 Diseño de experimentos propuestos para la sintonización del MAPE con un GA	70
Tabla 3.5 Experimentos propuestos para la sintonización del MAPE con un uGA	70
Tabla 4.1 Mejor experimento para ajuste de MRR.....	71
Tabla 4.2 Cromosoma resultante para ajuste de MRR	72
Tabla 4.3 Tests de Normalidad	75
Tabla 4.4 Tests de Normalidad	76
Tabla 4.5 Estadísticos MRRR micro genético	76
Tabla 4.6 Cromosoma resultante para ajuste de MRR con micro GA	77
Tabla 4.7 Test de Normalidad	80
Tabla 4.8 Estadísticos del Test 10	81
Tabla 4.9 Estadísticos del Test 5	81
Tabla 4.10 Cromosoma resultante para ajuste de DOC.....	82
Tabla 4. 11 Tests de normalidad.....	85
Tabla 4.12 Test de Wilcox.....	86
Tabla 4.13 Estadísticos tests	86
Tabla 4.14 Resultados del test de Tuckey	87
Tabla 4.15 Estadísticos del test.....	87
Tabla 4.16 Cromosoma resultante para ajuste de DOC con micro algoritmo genético	88
Tabla 4.17 Resultados MAPE para la Tasa de Remoción de Material (MRR)	92
Tabla 4.18 Resultados MAPE para el Diámetro de Sobrecorte (DOC)	92

INDICE DE FIGURAS

Figura 2.1 Topología de identificación de sistemas basado en minimización del error (Chafaa, et al., 2015)	22
Figura 2.2 Topología de sistema difuso basado minimización del error del proceso y el modelo (Chafaa, et al., 2015).	23
Figura 2.3 Topología de sistema difuso basado minimización del error del proceso modelo primario y mecanismos de ajuste (Chafaa, et al., 2015).....	24
Figura 2.4 Estructura básica de un sistema de identificación no lineal (Jianhua, et al., 2015)	25
Figura 2.5 Arquitectura de un sistema Difuso Tipo-2 (Karnik & Mendel, 1998).....	26
Figura 2.6 Conjuntos difusos Tipo 2 (Karnik & Mendel, 1998)	31
Figura 2.7 Arquitectura del método HyFIS (Kim & Kasabov, 1999)	39
Figura 2.8 Derivación de reglas difusas a través del método (Wang & Mendel, 1992).....	40
Figura 2.9.- Esquema de un algoritmo evolutivo (Gestal, 2013)	44
Figura 2.10 Componentes de un algoritmo genético (Peña, et al., 2011).....	46
Figura 2.11 Cromosoma con codificación binaria (Gestal, 2013).....	47
Figura 2.12 Cromosoma con codificación real (Chang & Chen, 1998).....	48
Figura 2.13 Operador ruleta (Gestal, 2013).....	49
Figura 2.14 Esquema de selección de torneo (Elaboración propia).	50
Figura 2.15 Cruzamiento binario de un punto (Gestal, 2013)	51
Figura 2.16 Cruzamiento binario de dos puntos (Gestal, 2013).....	52
Figura 2.17 Cruzamiento uniforme (Gestal, 2013).....	53
Figura 2. 18 Mutación binaria (Jamshidi, et al., 2003).....	55
Figura 2. 19 Mutación sobre varios puntos (Eiben & Smith, 2015).....	55
Figura 2.20 Diagrama de flujo de un algoritmo genético canónico (Goldeberg & Holland, 1988).....	57

Figura 2.21	Diagrama de flujo de un micro algoritmo genético (Coello, 1995).....	59
Figura 3.1	Esquema metodológico propuesto (Elaboración propia).....	61
Figura 3.2	Esquema estadístico propuesto (Elaboración propia).....	62
Figura 3.2	Respuesta de un cruce BLX-alpha (Herrera, et al., 2002).....	65
Figura 3.3	Función difusa triangular.....	66
Figura 3.4	Función difusa Gaussiana.....	67
Figura 3.5	Sistema difuso MISO.....	68
Figura 4.1	Convergencia del Algoritmo genético canónico para MRR.....	72
Figura 4.2	Conjuntos difusos para la variable voltaje.....	73
Figura 4.3	Conjuntos difusos de variable frecuencia.....	73
Figura 4.4	Conjuntos difusos de variable corriente.....	74
Figura 4.5	Conjuntos difusos de variable MRR.....	74
Figura 4.6	Gráfica de convergencia para MRR.....	78
Figura 4.7	Conjuntos difusos de voltaje MRR.....	78
Figura 4.8	Conjuntos difusos de frecuencia MRR.....	79
Figura 4.9	Conjuntos difusos de corriente MRR.....	79
Figura 4.10	Conjuntos difusos de voltaje MRR.....	80
Figura 4.11	Conjuntos difusos de Tasa de Remoción de Material MRR.....	80
Figura 4.12	Convergencia del micro-algoritmo para DOC.....	82
Figura 4.13	Conjuntos difusos de variable voltaje.....	83
Figura 4.14	Conjuntos difusos de variable frecuencia.....	83
Figura 4.15	Conjuntos difusos de variable corriente.....	84
Figura 4.16	Conjuntos difusos de variable Diámetro de Sobrecorte (DOC).....	84
Figura 4.17	Conjuntos difusos de variable voltaje.....	89
Figura 4.18	Conjuntos difusos de variable frecuencia.....	89
Figura 4.19	Conjuntos difusos de variable corriente.....	89
Figura 4.20	Conjuntos difusos de variable Diámetro de Sobrecorte (DOC).....	90

PRESENTACIÓN

Este trabajo documenta el proceso investigativo realizado en el marco de un área de la tecnología de la información que tiene como objeto de estudio la aproximación de funciones no lineales por medio de técnicas de Soft Computing combinadas entre sí en un paradigma denominado inteligencia computacional. Esto con la finalidad de escribir un modelo computacional representativo de los parámetros tasa de remoción de material y el diámetro de sobre corte de un proceso de manufactura no convencional denominado Maquinado por descarga dieléctrica (ECDM).

El documento se organiza de la siguiente forma: En el Capítulo 1 titulado Racionalización del objeto de estudio se describen antecedentes del Maquinado Electroquímico por Descarga Eléctrica(ECDM). Se listan la pregunta de investigación, los objetivos específicos y el general, además de la hipótesis a verificar, los impactos y la justificación propia del presente tema. Cabe destacar que también se muestra información de carácter introductorio sobre algunos tópicos de inteligencia artificial

En el Capítulo 2 se muestran una panorámica de trabajos relacionados con el tema de esta propuesta, los tópicos que abarca esta revisión a la literatura especializada, son: identificación de sistemas por medio de topologías difusas, sus aplicaciones en la construcción de modelos la construcción de modelos de procesos de manufactura por medio de SoftComputing

En el Capítulo 3 se describe la metodología utilizada para el desarrollo de la propuesta de investigación, así como el tipo de investigación, además de la definición de la topología del algoritmo a utilizar, la descripción del conjunto de entrenamiento y validación para el modelo y el diseño de experimentos planteado.

En el Capítulo 4 se muestran los resultados obtenidos por un algoritmo genético en su versión canónica y un micro algoritmo genético para la Tasa de Remoción de Material (MRR) y el

Diámetro de Sobrecorte (DOC) del proceso de Maquinado Electroquímico por Descarga Eléctrica (ECDM) , así como el Error Porcentual Medio (MAPE) del modelo, finalmente se evalúa la estabilidad de los algoritmos a través de estadística inferencial, aplicado los Test de Kruskall-Wallis, Tuckey, Wilcox a una muestra de los algoritmos según el teorema del límite central. .

Capítulo 1 RACIONALIDAD DEL OBJETO DE INVESTIGACIÓN

En el presente capítulo encontrara la fundamentación para el desarrollo del proyecto de investigación, en donde se define el objetivo general y específicos, se plasma el planteamiento del problema, así como las preguntas de investigación que emanan de este. Finalmente encontrara los requerimientos hardware y software para el desarrollo de la investigación.

1.1 Fundamentación inicial

La manufactura, es un proceso para la construcción de piezas pequeñas como tornillos, tuercas, broques, aretes entre otros productos, cuyo término fue definido por primera vez en el año de 1567; se deriva de las palabras en latín manus que significa manos y factus que significa hacer, derivado de los términos anteriores manufactura significa hecho a mano, la construcción de los productos antes mencionados se realizan bajo dos enfoques: maquinado convencional y no convencionales (Groover, 2007), (Kalpakjian & Schmid, 2002).

En los procesos de maquinado convencional, la fabricación de piezas se realiza cuando la pieza de trabajo y la herramienta de trabajo entran en contacto; dentro de este tipo de procesos se encuentran: fresado, torneado, rectificado, etcétera. En el caso de los procesos de maquinado no convencional la fabricación de las piezas se realiza sin que la herramienta de trabajo y la pieza estén en contacto; este tipo de procesos surgen en el año de 1991, algunos de estos son: Maquinado con rayo láser, chorro de agua, chorro abrasivo, Maquinado electroquímico, Maquinado por descarga eléctrica, y maquinado electroquímico por descarga eléctrica (Kalpakjian & Schmid, 2002), (Barbosa, et al., 2019)

El maquinado electroquímico (Electrochemical Machining, ECM por sus siglas en inglés) es un proceso utilizado por primera vez en el año de 1929, consiste en el retiro de material en la pieza de trabajo (ánodo) a través de la herramienta de trabajo (cátodo), el uso de un solución para el viaje de la corriente permite retirar los iones de la pieza de trabajo y que estos no se adhieran a la herramienta de trabajo, la ventaja de este tipo de maquinado es que

no existe un desgaste en la herramienta y la construcción de piezas de forma compleja y con cavidades profundas (Asokan, et al., 2008),(Kalpakjian & Schmid, 2002), (Rama, et al., 2009),

Por otra parte, el maquinado por descarga eléctrica (Electrical Discharge Machining, EDM por sus siglas en inglés) es un proceso térmico que al igual que el proceso de maquinado electroquímico se construyen piezas de tamaño muy pequeño a través de pulsos eléctricos que generan energía entre pieza de trabajo y la herramienta de trabajo, que se encuentran sumergidas en el electrolito sin contacto físico, los pulsos eléctricos entre la pieza y el electrodo generan una burbuja de gas que alcanza una temperatura de 8000 a 12 grados centígrados esto hace fundir el material de las pieza, cuando la corriente disminuye la burbuja de gas colapsa da como resultado la eliminación de material Como resultado con mayor precisión con respecto al maquinado convencional,(Rangajanardhaa, et al., 2009), (Kholi, et al., 2012). De la unión de los procesos de manufactura anteriores surge un nuevo tipo de maquinado no convencional, denominado Maquinado Electroquímico por Descarga Eléctrica (Electrochemical Discharge Machining, ECDM por sus siglas en inglés). En la Figura 1.1 se muestra la topología del mecanismo de manufactura empleado en los procesos EDM, ECM y ECDM

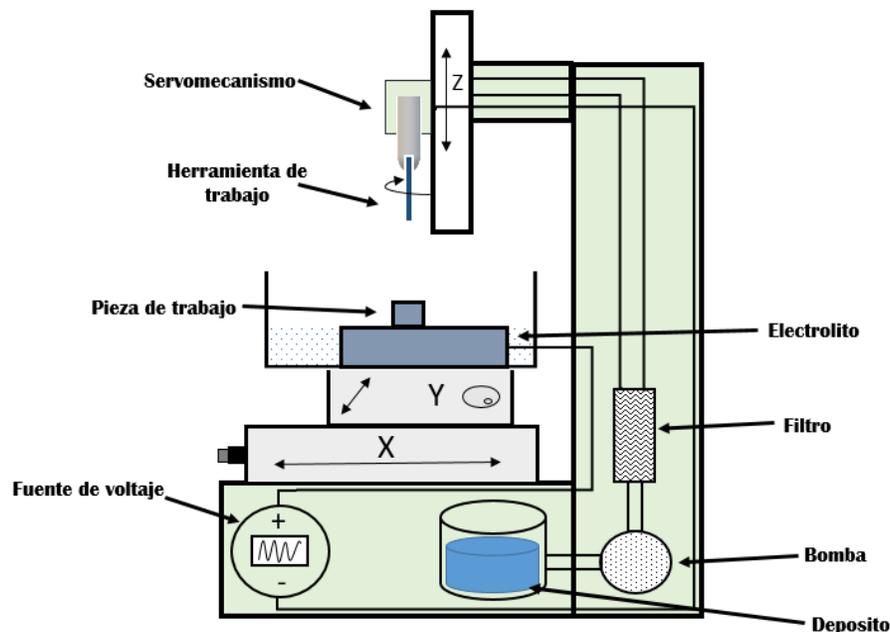


Figura 1.1 Mecanismo para procesos de manufactura EDM, ECM y ECDM (Leyva, 2018)

Los procesos de manufactura no convencional son susceptibles a ser modelados por medio de técnicas de Soft Computing, como por ejemplo la lógica difusa, que es una extensión de la lógica booleana y de la teoría de conjuntos utilizada para modelar sistemas no lineales. Esta hace uso de los datos numéricos y características lingüísticas transformados en forma matemática. En el trabajo realizado por (Antil, et al., 2014) los autores realizan un análisis de parámetros entrada/salida explicando la relación entre los mismos, el resultado es un modelo del proceso con lógica difusa, Este trabajo deja abierto el camino a la creación de modelos computacionales de los procesos de manufactura no convencional.

El proceso ECDM ha sido objeto de modelado empleando diferentes técnicas, una de ellas es lógica difusa, en dos propuestas diferentes presentadas por (Lin, et al., 2000) y (Antil, et al., 2014) donde toman como parámetros de entrada voltaje, corriente, ciclo de trabajo, polaridad de la pieza de trabajo, fluido dieléctrico, tiempo de encendido y como parámetros de salida, la tasa de remoción, desgaste de la pieza, y rugosidad de la superficie en ambos casos el proceso a modelar es validado a través de conjuntos experimentales del proceso.

A través de la revisión de la literatura se ha observado que la construcción de los conjuntos difusos se realiza a través de manera empírica dependiendo de la experiencia del operador del proceso, esto se ha visto como una de las áreas de oportunidad para el uso de técnicas heurísticas para la optimización de los conjuntos de lógica difusa. Una de estas técnicas de optimización son los algoritmos evolutivos se pueden definir como una colección de métodos heurísticos, es decir reglas obtenidas de un conocimiento previo de cierto dominio de un problema (Ergun & Hertem, 2016) que tienen pasos definidos inspirados en la mayoría de los casos por procesos biológicos como la reproducción y mutación de los seres vivos, la recombinación y la selección biológica (Chacon Montés, 1995) los cuales fueron propuestos por Charles Darwin en el libro “El origen de las especies” (Vasiljevic, 2002).

Un algoritmo soportado teóricamente en los principios evolutivos de Darwin y Mendel es el Algoritmos Genético (Genetic Algorithm, GA por sus siglas en inglés), una de las variantes de los GAs se denomina micro algoritmo genético (μ -GA), cuyo primer antecedente se documenta en (Herera, et al., 2009), donde se propone un GA simple de representación binaria, utilizando una población de 3 individuos; como resultado se obtuvo como postulado que un algoritmo puede converger sin importar el tamaño del cromosoma. En este trabajo se

aplicó los operadores genéticos hasta alcanzar una convergencia nominal conceptualizada como la generación en la cual los individuos son muy similares o se alcanza cierto número predefinido de iteraciones, obteniendo un nuevo individuo (el de mejor aptitud), para posteriormente generar de manera aleatoria los otros dos individuos que completarán la nueva población. Posteriormente Kalmanje Krishnakumar en 1990, propone un GA con población reducida (no más de 5 cromosomas) a diferencia de los 40 a 300 individuos de la versión canónica (Krishnakumar, 1990) lo cual permite obtener un algoritmo evolutivo de bajo costo computacional.

A partir de lo observado anteriormente se puede determinar que a través de técnicas de Soft Computing, tales como lógica difusa y algoritmo genéticos, en específico de tamaño reducido (de tres a cinco cromosomas) se pueden modelar procesos de manufactura no convencional. Estos modelos pueden tener aplicación potencial en el diseño y simulación de técnicas de regulación para los parámetros como el diámetro de sobre corte y la tasa de remoción. Ahora bien, desde el punto de vista de Soft Computing no existe identificado en la literatura especializada la aplicación de este conjunto de técnicas en procesos de modelado de manufactura no convencional en específico de los parámetros de diámetro de sobre corte y tasa de remoción de material. Esta aplicación es un área de oportunidad para ampliar el estado del arte sobre optimización numérica

1.2 Definición del problema

Los procesos de manufactura no convencional, muestran un comportamiento no lineal, donde la salida no presenta proporcional de acuerdo a los datos de entrada, estos es, dada una determinada combinación de parámetros de entrada se obtendrá un parámetro de salida que no estaba presente en la entrada, una técnica que permite modelar procesos no lineales y predecir los parámetros de salida a través de modelos de caja negra es la lógica difusa dado que son algoritmos considerados como aproximadores universales (Rojas, 2014) (Ortiz, 2015), cuyas funciones de membresía son calculadas, por medio de un proceso empírico de prueba y error cuando se usan algoritmos de Mamdani. Si se trata de un algoritmo de Takagi, la alternativa de cálculo es la aplicación de reglas de retro propagación del error para el secuento y el uso de mínimo cuadrados de forma recurrente para el consecutivo.

La aplicación de los métodos de retro propagación del error y los mínimos cuadrados implica una complejidad de cálculo debido al espacio de búsqueda de soluciones que satisfagan el resultado, esto incrementa en función del número de reglas, así como de conjuntos de las secciones de fuzzificación. Una alternativa para ajuste de funciones de membresía, que se ha planteado en la literatura especializada, es el uso de algoritmos evolutivos, cuya repetitividad y convergencia no suele ser estudiada dado el costo computacional. Esto puede subsanarse por medio del uso de heurísticas de tamaño reducido denominados micro algoritmos.

Los procesos no convencionales como el Maquinado Electroquímico por Descarga Eléctrica (ECDM) pueden ser modelados, este tipo de modelos desea plasmar las características del proceso empleando técnicas computacionales como lo realizan en (Antil, et al., 2014) donde se plantean modelar un proceso de maquinado por descarga eléctrica, a través de un conjunto de datos experimentales del proceso se construye y valida el modelo del proceso, este trabajo realiza el estudio de análisis y construcción de modelos donde dejan el camino abierto a para realizar modelos de los procesos de manufactura no convencional esto para la reducción en tiempo y recursos de los experimentos de acuerdo al comportamiento del mismo.

1.2.1 Objetivos de la investigación

Uno de los objetos de estudio de la manufactura no convencional es el análisis de datos experimentales de procesos como el maquinado electroquímico por descarga eléctrica (ECDM) y el maquinado electroquímico (ECM), a través de estos datos se observa el comportamiento del proceso de acuerdo a parámetros, el proceso de experimentación consume recursos tiempo y económico. Esto permite la formulación de modelos de caja negra, los cuales no implican un conocimiento extenso de la fundamentación teórica, pero si de un conocimiento de técnicas de Soft Computing. En esta propuesta de investigación se propone obtener un modelo del proceso ECDM por medio de un algoritmo Mamdani, cuyas funciones serán obtenidas por medio de un micro algoritmo genético. La presente propuesta usará Rstudio como entorno de desarrollo y R como lenguaje de programación.

1.2.2 Objetivo General

Formular un modelo computacional de caja negra del proceso de maquinado electroquímico por descarga eléctrica (ECDM) por medio de técnicas de Soft Computing, a partir de datos experimentales de este proceso.

1.2.3 Objetivos específicos

1. Diseñar los conjuntos difusos para el modelo de caja negra de los parámetros tasa de remoción de material y diámetro de sobre corte del proceso de maquinado electroquímico por descarga eléctrica (ECDM).
2. Optimizar las funciones de membresía del modelo de caja negra de los procesos de maquinado electroquímico por descarga eléctrica (ECDM).
3. Evaluar, por medio de estadística inferencial, el modelo de caja negra del proceso de maquinado electroquímico por descarga eléctrica (ECDM).

1.2.4 Preguntas de investigación

1. ¿Qué elementos deben tomarse en cuenta para realizar un modelo de caja negra para el proceso de maquinado electroquímico por descarga eléctrica (ECDM)?
2. ¿Qué algoritmo permitiría diseñar conjuntos difusos para el modelo de caja negra de los parámetros de diámetro de sobre corte y tasa de remoción de material del proceso (ECDM)?
3. ¿Cuáles son los parámetros de un micro-algoritmo genético para optimizar un modelo de caja negra de los parámetros de diámetro de sobre corte y tasa de remoción de material de los procesos de maquinado electroquímico por descarga eléctrica (ECDM)?
4. ¿Cómo se puede evaluar el modelo de caja negra de los parámetros de diámetro de sobre corte y la tasa de remoción de material para el proceso de maquinado electroquímico por descarga eléctrica (ECDM)?

1.3 Justificación

Los procesos de manufactura no convencionales requieren de tiempo y pruebas experimentales para obtener piezas con calidad de corte y superficie, los aspectos mencionados son obtenidos a través de la configuración de parámetros de entrada, dicha configuración se basa en la experiencia del operador de manera empírica, en la mayoría de las ocasiones la elección de los parámetros no es la adecuada no obteniendo los resultados deseados, esto lleva a realizar más pruebas y por ende el empleo de materiales y tiempo.

A través de la formulación de modelos de caja negra se pueden caracterizar los procesos de manufactura convencional, a través de estos modelos se puede simular el comportamiento del proceso basado en los parámetros de entrada, como resultado estos modelos permiten conocer el resultado de ciertos parámetros de salida como son el diámetro de sobre corte y la tasa de remoción de material. También es posible, por medio de modelos, la construcción de simuladores computarizados que permitan operar fuera de los límites establecidos sin comprometer los componentes electrónicos o mecánicos del sistema real.

Debido a lo anterior en la presente propuesta de investigación se busca la formulación de un modelo de caja negra del proceso (ECDM), a través de técnicas de Soft Computing en específico del uso de lógica difusa utilizando el algoritmo de Mamdani, por otra parte, los micro algoritmos, tienden a converger más rápido que las versiones de tamaño estándar, pero no han sido aplicadas a la identificación con lógica difusa.

En la presente propuesta, se usó Rstudio, el entorno gráfico del lenguaje R, dado que permite la construcción, de manera más simple en comparación con el modo consola, de representaciones gráficas de datos. Tiene instrucciones de estadística que serán necesarias para la evaluación del modelo y de la micro heurística a implementar. Actualmente su uso se ha extendido en la ciencia de datos, dado su licencia del tipo OpenSource y la acelerada curva de aprendizaje.

1.4 Requerimientos del proyecto

Para la formulación del modelo de caja negra del proceso de Maquinado Electroquímico por descarga eléctrica (ECDM).

1. Entorno de desarrollo Rstudio.
2. Computadora Laptop DELL Intel Core i7- 3540M CPU 3.0 GHz, RAM 6.0 GB.
3. Computadora MacProzl.
4. Datos experimentales del modelo ECDM.
5. Laboratorio de Computo Científico del Centro Universitario UAEM Atlacomulco.

A demás de lo enlistado se necesitará:

1. Datos experimentales del proceso ECM y ECDM.
2. Bibliografía especializada sobre lógica difusa y algoritmos genéticos.

1.5 Impactos

Se prevé que los resultados obtenidos de la presente propuesta de investigación tengan los siguientes impactos:

- Científico. Se demostrará la efectividad de las herramientas de Soft Computing (lógica difusa, algoritmo de Mamdani y micro heurísticas) en la construcción de un modelo aplicado al proceso de manufactura no convencional (ECDM)
- Tecnológico: La obtención de modelos de procesos no convencionales permitirá predecir el comportamiento del proceso y sus resultados sin comprometer recursos materiales y tiempo.
- Económico. La formulación de modelos utilizando técnicas de Soft Computing permitirá a la industria contar con modelos que ayuden a realizar estudios teóricos, seguros sin riesgo para el equipo dado que se podrán implementar simulaciones por computadora.

1.6 Hipótesis

Si se implementa un micro algoritmo genético y un algoritmo difuso se podrá formula un modelo del proceso para los parámetros de diámetro de sobre corte y tasa de remoción de material del proceso de maquinado ECDM con un porcentaje de exactitud al menos del 90%, dado que la formulación de modelados a partir de micro-heurísticas y lógica difusa no se encuentra identificado en la literatura especializada.

Capítulo 2 ESTADO DE ARTE

En esta sección se muestra una panorámica de investigaciones documentadas en el estado del arte de la construcción de modelos de fenómenos físicos a partir del uso de inteligencia computacional, es decir la sinergia entre técnicas de *Soft Computing*. En primer término, se documenta algunos aspectos fundamentales sobre la identificación de sistemas, el desarrollo de lógica difusa, esto implica conjuntos y tipos de sistemas difusos, posteriormente se describe los avances más importantes en la aplicación de lógica difusa al modelado del *DOC* y del *MRR* en procesos de manufactura no convencional.

2.1 Identificación de sistemas

En esta sección se documentan algunos conceptos teóricos sobre el modelado de sistemas, los cuales se desarrollarán de manera más extensa en las siguientes subsecciones. El eje de este apartado es la definición de identificación de sistemas, concepto necesario de definir dado constituye una de las partes del objeto de estudio del presente proceso de investigación

Una de las áreas de aplicación de las tecnologías de la información es la identificación de sistemas, que se puede definir como un conjunto de metodologías que permiten la construcción de modelos representativos de sistemas o procesos. (Ortiz, 2015). Existen tres paradigmas de construcción de modelos de acuerdo a su constitución, los de caja blanca o simbólicos, los de caja negra o conexionistas y los de caja gris o híbridos, en el primero, los datos obtenidos de una serie de pruebas no destructivas permiten la obtención de ecuaciones y parámetros basado en una sólida fundamentación teórica del proceso a modelar (De la Fuente & Calonge, 1999), (Mahner & Bunge, 2000) (Almorox, et al., 2010).

Una manera de revisar modelos de caja negra es por medio de lógica difusa la cual es una extensión de la lógica booleana y de la teoría de conjuntos utilizada para modelar sistemas no lineales, esta hace uso de los datos numéricos y características lingüísticas transformados en forma matemática, esto permite expresar conocimiento empírico en un formato de regla de inferencia de la forma:

“Si se cumple un conjunto de condiciones ENTONCES se infiere un conjunto de consecuencias”. Por lo tanto, la base de conocimiento consiste en un conjunto de R_j reglas difusas como la mostrada en la ecuación 1 (Siler & Buckley, 2005) *SI* x_1 es A_{1j} y x_2 es A_{2j} y x_n es A_{nj} **ENTONCES** z es B_j Donde: $x_1, x_2 \dots x_n$ son las variables de entrada al sistema difuso, $A_{1j}, A_{2j} \dots A_{nj}$ son etiquetas lingüísticas asociadas a las variables de entrada y a los conjuntos difusos. z es la salida del sistema B_j es la etiqueta lingüística asociada a la salida difusa (Rojas, 2014), (Yilmaz, et al., 2006).

La identificación de sistemas es una técnica que permite la construcción de modelos matemáticos a partir de datos de entrada-salida representativos de un determinado sistema a estudiar, los cuales pueden ser representados por medio de un conjunto de datos $Z = \{y_1, u_1, y_2, u_2 \dots y_n, u_n\}$ donde $y_1, y_2 \dots, y_n$ son entradas y $u_1, u_2 \dots, u_n$ son las salidas (Avilés, et al., 2002).

Por lo tanto, los modelos de sistemas pueden realizarse por medio del mapeo de datos disponibles dividiendo el conjunto Z en dos partes, los conjunto de entrenamiento (representado como Z^{n-1}) y los validación (representado como Z^{n+1}). Esto tiene como finalidad la estimación de valores de salida $\hat{y}_n = f(Z^{n-1})$, a través de una f función matemática específica que constituye el objeto de estudio del proceso de identificación de sistemas, a esto último se conoce como modelo predictivo (Avilés, et al., 2002), (Aguilar, et al., 2019)

La construcción de modelos matemáticos está ligada al Teorema de superposición de Kolmogorov. En 1900 David Hilbert, teorizó sobre la existencia de funciones continuas de múltiples variables que no se pueden descomponer como la superposición finita de funciones continuas de menos variables. Esto fue refutado por Andrey Nikolaevich Kolmogorov el cual escribió el Teorema de superposición de Kolmogorov (KST), en el cuál se especifica que para toda $n \geq 2$ y para cualquier función f , real continua de n variables en el dominio $[0,1]$, $f: [0,1]^n \rightarrow \mathbb{R}$ existen $n(2n + 1)$ funciones continuas crecientes univariadas en $[0,1]$, por lo tanto f puede ser reconstruida por medio de $f(x_1, \dots, x_n) = \sum_{q=0}^{2n} \phi_q(\sum_{p=1}^n \psi_{pq}(x_p))$. (Acevedo, 2011), (Bombal, 2013), (Gordienko, 2011)

Donde las funciones ψ_{pq} son universales monótonas crecientes para las n dimensiones dadas, independientes de f , al contrario de las funciones especificadas por ϕ_q que si son dependientes. Es importante destacar que ψ_{pq} y ϕ_q son continuas en todas sus partes pero en ninguna de ellas diferenciables. Un enfoque de aproximación de funciones es desarrollado por (Kosko, 1994) en su trabajo "Fuzzy systems as universal approximators" en el que demostró que los controladores difusos de tipo Mamdani pueden aproximar uniformemente funciones de múltiples variables La exactitud de la aproximación de funciones por medio de lógica difusa es determinada por medio del número de conjuntos y reglas usadas, por lo tanto el aumentar la precisión incrementa el costo computacional.

Cuando se realiza la identificación de sistemas aproximando funciones por medio de un sistema difuso, es necesario que sea parametrizable por medio de un vector θ formado por funciones de membresía, posiciones de las mismas y consecuentes de las reglas difusas. La elección de estas variables estás determinadas por la información histórica del fenómeno a identificar, explicitada en un determinado conjunto de datos Z . A partir del vector θ es posible estimar la salida del sistema a estudiar como $\hat{y}_n = f(Z^{n-1}|\theta)$. Particularizando Z^{n-1} en función de tratamiento que tomen los datos es posible hacer una estimación $\hat{y}_n = f(\varphi(n)|\theta)$, donde $\varphi(n)$ es conocida como vector de regresión de tal forma que el problema de identificación de sistemas se puede dividir en varios problemas, para determinar los siguientes aspectos (Chafaa, et al., 2015):

- La topología del sistema
- La función $\varphi(n)$.
- Los parámetros θ .

2.2 Topologías de sistemas difusos para la identificación de sistemas

La identificación de sistemas por medio de inferencia difusa, implica un primer problema el cual consiste en la selección de la topología del sistema de identificación de entre las opciones existentes en la literatura especializada. Algunas topologías son documentadas en esta subsección de este trabajo de tesis

En (Chafaa, et al., 2015)se presenta un método para identificar sistemas basado, en primer lugar considerando un conjunto de datos Z tal que $\vec{u} = \{u_1, u_2, \dots, u_n\} \in \mathbb{R}^n$ en la salida y ,

la información histórica disponible de f esta presentada como p pares de entrenamiento $(\vec{u}^1, y^1), (\vec{u}^2, y^2), \dots, (\vec{u}^p, y^p) \forall x^i \in \mathbb{R}^n, i = 1, 2, 3, \dots, p$, esto permite implementar un modelo primario \hat{f} , de salida $\hat{y}_n := \hat{f}(\vec{u}^n, \varphi(n))$ el cual es comparado con los datos de identificación real f , de salida $y_n := f(\vec{u}^n)$ generando un error $e_n = \hat{y}_n - y_n$, $n = 1, 2, 3, \dots, p$. Esto es representable como una topología mostrada en la Fig. 2.1.

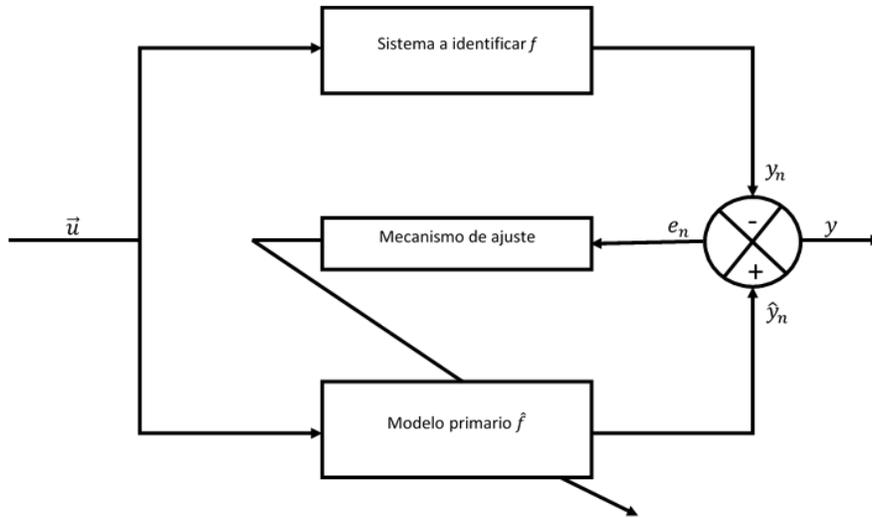


Figura 2.1 Topología de identificación de sistemas basado en minimización del error (Chafaa, et al., 2015)

De la Figura 2.1 es posible definir algunos aspectos de interés, de acuerdo a (Chafaa, et al., 2015):

1. Se propone como función estimada \hat{f} a un sistema difuso de adaptación.
2. El mecanismo de ajuste $\varphi(n)$ se define como $\varphi(e_n) \vee \varphi(\hat{y}_n - y_n)$
3. Los parámetros ajustados en \hat{f} de acuerdo a (Chafaa, 2015) son la posición del centro de funciones de membresía Gaussianas. Esto no es de carácter restrictivo, dado que pueden usarse otro tipo de funciones.

Una alternativa de mejora consiste en implementar un módulo denominado error del proceso e_p que se presenta en la Fig. 2.2, donde la salida $y_n := f(\vec{u}^n)$, y la salida $\hat{y}_n := \hat{f}(\vec{u}^n)$, por lo tanto $e_p = \hat{y}_n - y_n$ (Chafaa, et al., 2015).

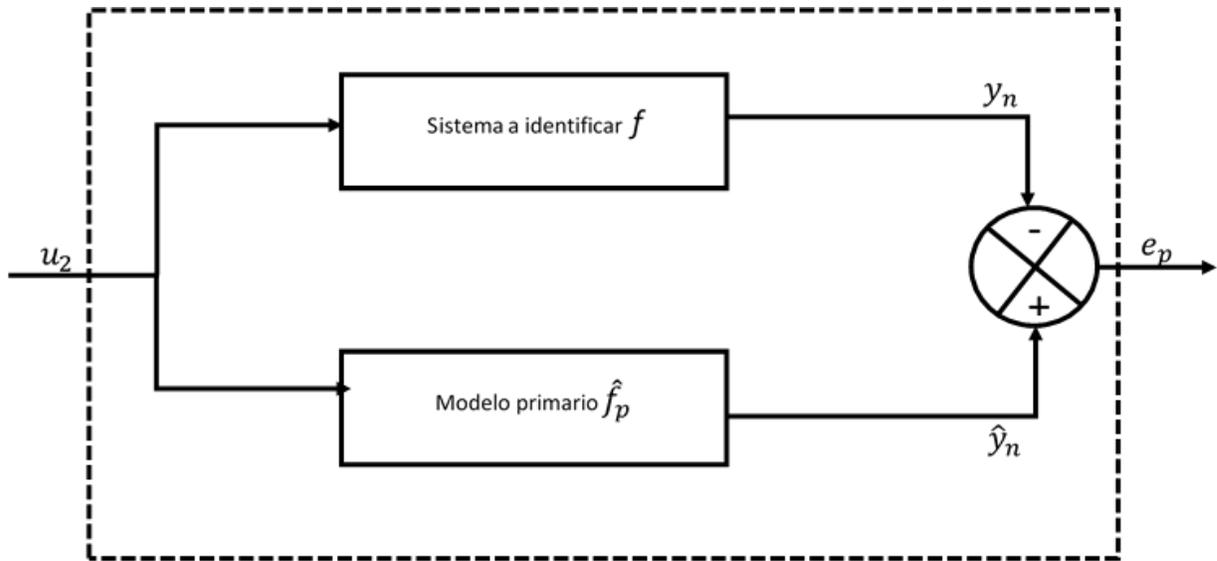


Figura 2.2 Topología de sistema difuso basado minimización del error del proceso y el modelo (Chafaa, et al., 2015).

A partir de e_p y e_n , se determina un error de estimación $e_e = e_p - e_n$ tal que $\varphi_p(n) := \varphi_p(e_e) \vee \varphi_p(e_p - e_n)$. De tal forma que $\hat{y}_n := \hat{f}(\vec{u}^n, \varphi(n), \varphi_p(n))$. Esto permite obtener un nuevo modelo de estimación que se presenta en la Fig. 2.3.

De la Fig. 2.3 se derivan las siguientes observaciones las reglas de las funciones de membresía describen la función no lineal del error del proceso de la siguiente forma: El error del proceso y el error del modelo son interconectados para generar una nueva topología donde un segundo mecanismo de ajuste será el encargado de minimizar el error. Estos 3 tipos de topologías han sido empleadas en sistemas dinámicos no lineales. Existen diferentes topologías para representar un modelo de un proceso no convencional, en la siguiente subsección se describen las topologías de sistemas tipo I y II para la identificación de sistemas.

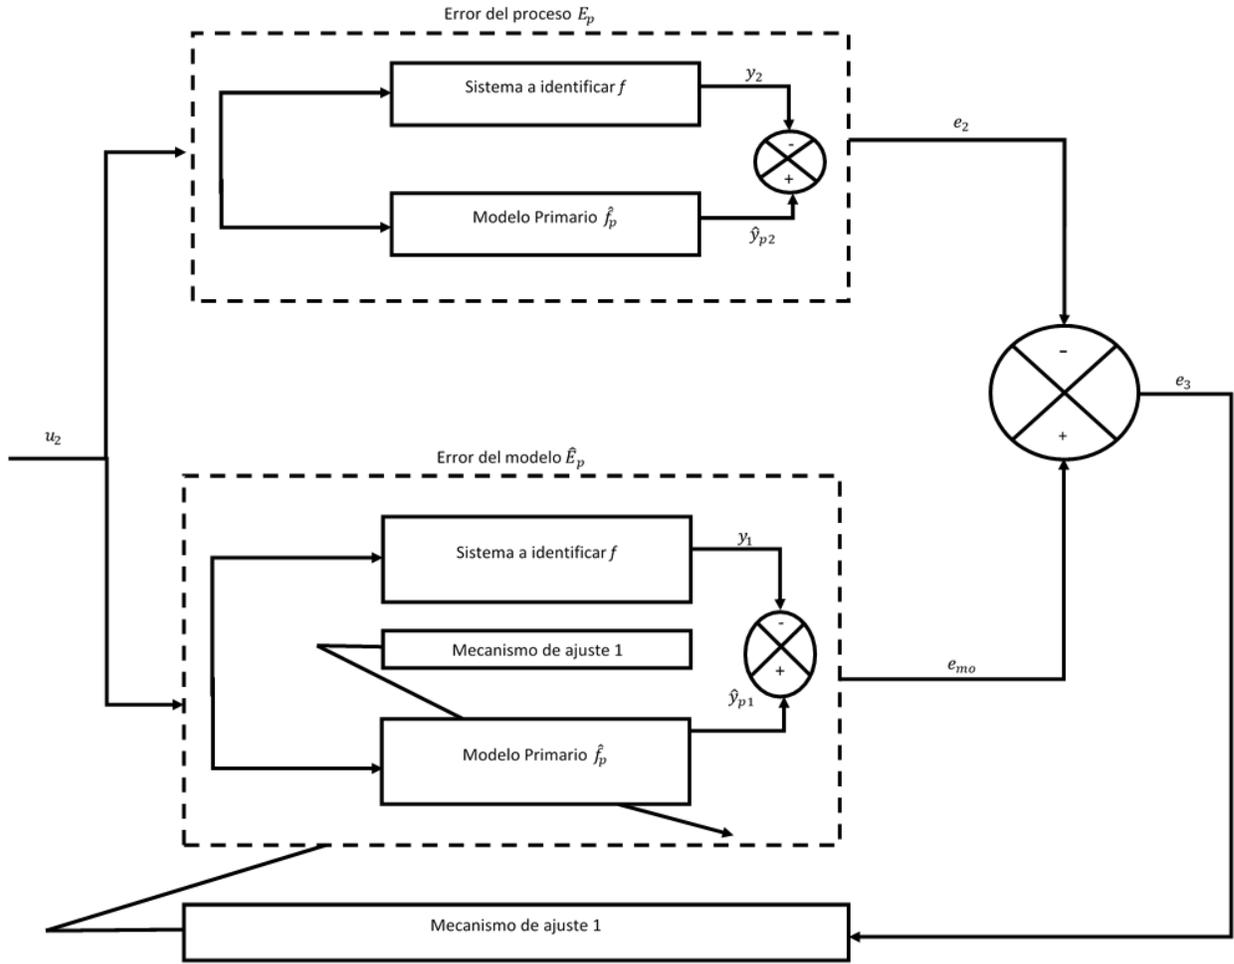


Figura 2.3 Topología de sistema difuso basado minimización del error del proceso modelo primario y mecanismos de ajuste (Chafaa, et al., 2015).

En (Jianhua, et al., 2015) se desarrolla una topología para la identificación de sistemas no lineales, en este caso representados como $f(\vec{u}) \forall u = (u_1, u_2, u_3, \dots \dots u_n) \in \mathbb{R}^n$, que genera una salida y_d de tal forma que la salida estimada \hat{y}_d pueda determinarse por medio de $\hat{f}(\vec{u}, y_d, e) \forall e = y_d - \hat{y}_d \in \mathbb{R}$. La representación esquemática de esto se puede representar en la Fig. 2.4.

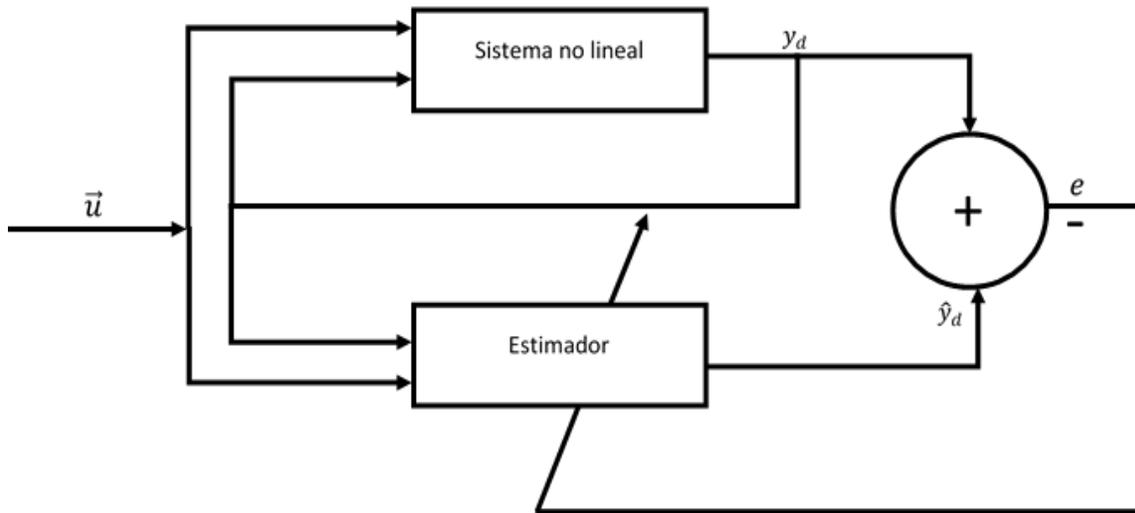


Figura 2.4 Estructura básica de un sistema de identificación no lineal (Jianhua, et al., 2015)

Cabe destacar que en (Jianhua, et al., 2015) es posible implementar a $\hat{f}(\vec{u}, y_d, e)$ a partir de un sistema de Inferencia Difuso Tipo 2 cuya topología se muestra en la Fig. 2.5, de tal forma

fue uno de sus criterios de desempeño sea $RMS = \sqrt{\frac{1}{N} \sum_{t=1}^N (y(t) - y_d(t))^2}$

Una variante del esquema mostrado anteriormente es realizable por medio de lógica difusa, la Figura 2.6 muestra el diagrama a bloques de este tipo de topología de identificación de sistemas.

En la Fig. 2.6 topología de un sistema difuso tipo 2 a través de un conjunto de datos de entrada $x = (x_1, x_2, x_3, \dots, x_n) \in \mathbb{R}^n$ es posible determinar un valor de salida (y), de esta topología se desprende el siguiente proceso: fuzzificación esta se realiza a través de la construcción de conjuntos difusos tipo 2 (\tilde{A}) denotados de la siguiente manera $\tilde{A} = \mu(x, u); x \in X, u \in J_x \subseteq [0,1] \wedge 0 \leq \mu_{\tilde{A}}(x, u) \leq 1$ también puede expresarse de la forma: $\tilde{A} = \int x \in X \int x \in J_{\tilde{A}} \mu_{\tilde{A}}(x, u) / x, u \quad J_x \subseteq [0,1]$ donde \int hacen referencia a la unión de todos los valores de x y $u \in X, J_x$ es una función de membresía primaria.

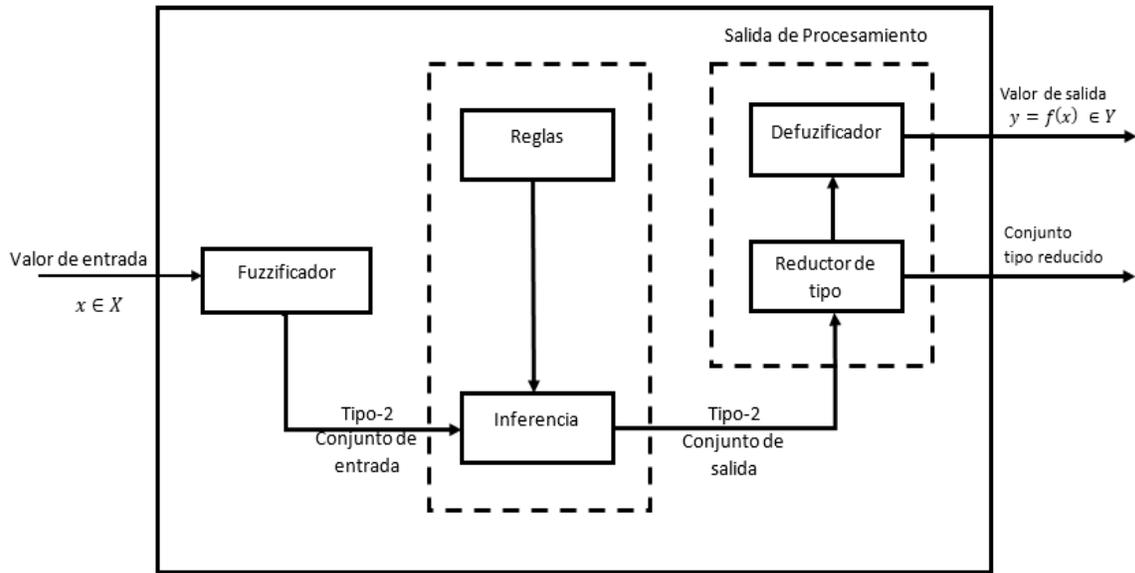


Figura 2.5 Arquitectura de un sistema Difuso Tipo-2 (Karnik & Mendel, 1998)

Una particularidad de las funciones de membresía de los sistemas de inferencia tipo 2 es la existencia de dos funciones de pertenencias, superior, denotada por la curva superior $(\bar{\mu}_{\tilde{A}}(x), \forall x \in X)$ e inferior dada por la curva $(\underline{\mu}_{\tilde{A}}(x), \forall x \in X)$, la unión de las funciones de pertenencia primarias da origen a la huella de incertidumbre; dentro de esta se pueden encontrar diferentes conjunto difusos tipo I cada conjunto tiene un centroide acotado (C_l, C_r) . En el proceso de fuzzificación del vector $\vec{x} = (x_1, x_2, x_3, \dots, \dots, x_n)$ es mapeado en conjuntos difusos tipo 2 donde las reglas siguen la siguiente estructura $R^1: SI x_1 es \tilde{F}_2^l, \dots, x_n es \tilde{F}_n^l, ENTONCES y es \tilde{G}^l, i = 1, 2, 3, \dots, M$. Otro de los componentes en un sistema de lógica difusa tipo II es el reductor, a través de los reductores se puede obtener un conjunto difuso tipo I, ya sea que el antecedente o el consecuente sean un conjunto de tipo2, finalmente el reductor convierte todos los conjuntos de tipo II a I obteniendo un “conjunto reducido”. A continuación, se describen los diferentes tipos de reductores (Karnik & Mendel, 1998):

- a) **Reducción tipo centroide:** Dentro de la huella de incertidumbre se encuentran incrustados diferentes conjuntos difusos tipo I, a través de este tipo de reductor se combina todos los conjuntos tipo 2 para encontrar su unión. El conjunto de salida se

denota como B . Donde el grado de membresía de $y \in Y$ es determinado por $\mu_{\tilde{B}^l}(y) = [\sqcup_{l=1}^M \mu_{\tilde{B}^l}(y)]$, a su vez este grado de pertenencia se obtiene encontrando la unión de las funciones de membresía de los conjuntos de tipo I, esto es representado con la siguiente expresión $\mu_{\tilde{B}^l}(y) = \mu_{\tilde{F}_1^l}(x_1) \sqcap \mu_{\tilde{F}_2^l}(x_2) \sqcap \dots \sqcap \mu_{\tilde{F}_p^l}(x_p) \sqcap \mu_{\tilde{G}^l}(y) = \mu_{\tilde{G}^l}(y) \sqcap [\sqcap_{i=1}^p \mu_{\tilde{F}_i^l}(x_i)]$. El cálculo del conjunto es determinado por la el reductor centroide se calcula para \tilde{B} a través de la siguiente expresión $Y_c(x) = \int_{\theta_1} \dots \int_{\theta_N} [\mu_{D_1}(\theta_1) \dots \mu_{D_1}(\theta_N)] / \frac{\sum_{i=1}^N y_i \theta_i}{\sum_{i=1}^N \theta_i}, D_i = \mu_{\tilde{B}^l}(y) \wedge \theta_i \in \mu_{\tilde{B}^l}(y_i) (i = 1, \dots, N)$

Para poder calcular $Y_c(x)$ es necesario :

1. Calcular el conjunto de salida combinado utilizando $\mu_{\tilde{B}^l}(y) = [\sqcup_{l=1}^M \mu_{\tilde{B}^l}(y)]$ esto es posible al calcular primero $\mu_{\tilde{B}^l}(y), l = 1, \dots, M \forall y \in Y$ a través de $\mu_{\tilde{B}^l}(y) = \mu_{\tilde{F}_1^l}(x_1) \sqcap \mu_{\tilde{F}_2^l}(x_2) \sqcap \dots \sqcap \mu_{\tilde{F}_p^l}(x_p) \sqcap \mu_{\tilde{G}^l}(y) = \mu_{\tilde{G}^l}(y) \sqcap [\sqcap_{i=1}^p \mu_{\tilde{F}_i^l}(x_i)]$
2. Discretizar el espacio de salida $Y = y_1, \dots, y_n$ en N puntos
3. Discretizar el dominio de cada $\mu_{\tilde{B}^l}(y_i) (i = 1, \dots, N)$ en un número de puntos.
4. Enumerar todos los conjuntos embebidos, ejemplo si cada $\mu_{\tilde{B}^l}(y_i)$ es discretizada en M_i puntos entonces habrá $\prod_{j=1}^N M_j$ conjuntos embebidos.
5. Calcular el conjunto de tipo reducido de centroide con $Y_c(x) = \int_{\theta_1} \dots \int_{\theta_N} [\mu_{D_1}(\theta_1) \dots \mu_{D_1}(\theta_N)] / \frac{\sum_{i=1}^N y_i \theta_i}{\sum_{i=1}^N \theta_i}, D_i = \mu_{\tilde{B}^l}(y) \wedge \theta_i \in \mu_{\tilde{B}^l}(y_i) (i = 1, \dots, N)$. En este paso el cálculo del centroide y la función de membresía se repite $\prod_{j=1}^N M_j$.

- b) **Reductor de altura:** Este reductor utiliza una función de membresía tipo Singleton para reemplazar los conjuntos de salida donde el valor de la membresía es el máximo (1) esto es aplicable para el antecedente o el consecuente, una vez que se tiene el conjunto de tipo I se hace el cálculo del centroide compuesto por los diferentes Singleton, lo anterior se realiza a través de la siguiente ecuación : $y_h(x) = \frac{\sum_{l=1}^M \bar{y}^l \mu_{B^l}(\bar{y}^l)}{\sum_{l=1}^M \mu_{B^l}}$ donde \bar{y}^l representa el punto máximo de la función de membresía para

el l_n conjunto de salida, si fuera más de un punto entonces se calcula el promedio y la función de membresía para $\mu_{B^l}(\bar{y}^l)$ será determinada como: $\mu_{B^l}(\bar{y}^l) = \mu_{G^l}(\bar{y}^l \star T_{i=1}^P \mu_{F_i^l}(x_i))$, donde \star indica la t -norma elegida. Para el grado de membresía de \bar{y}^l esta determinado de la siguiente forma $\mu_{\bar{B}^l}(\bar{y}^l) = \mu_{\bar{G}^l}(\bar{y}^l) \cap [\cap_{i=1}^P \mu_{\bar{F}_i^l}(x_i)]$. Si $D^l = \mu_{\bar{B}^l}(\bar{y}^l)$, la expresión para el conjunto reducido en versión extendida es

$$Y_h(X) = \int_{\theta_1} \int_{\theta_2} \dots \int_{\theta_M} [\mu_{D^1} \theta_1 \star \dots \star \mu_{D^M}(\theta_M)] / \frac{\sum_{l=1}^M \bar{y}^l}{\sum_{l=1}^M \theta_l} \text{ donde } \theta_l \in D^l \text{ para } l = 1, \dots, M \text{ en esta caso, } \alpha = \frac{\sum_{l=1}^M \bar{y} \theta_l}{\sum_{l=1}^M \theta_l}.$$

Finalmente para obtener $Y_h(X)$ es necesario realizar el siguiente proceso:

1. Elegir \bar{y}^l para cada conjunto de salida $l = 1, 2 \dots M$ y calcular $\mu_{\bar{B}^l}(\bar{y}^l)$ en $\mu_{\bar{B}^l}(\bar{y}^l) = \mu_{\bar{G}^l}(\bar{y}^l) \cap [\cap_{i=1}^P \mu_{\bar{F}_i^l}(x_i)]$.
2. Discretizar el dominio de cada $\mu_{\bar{B}^l}(\bar{y}^l)$ en un número adecuado de puntos, este proceso se realiza como la reducción de tipo centroide, con una diferencia donde el número de puntos del eje horizontal es M en lugar de N
3. Enumerar todas las posibles $(\theta_1, \theta_2, \dots \theta_M)$ $\theta_l \in \mu_{\bar{B}^l}(\bar{y}^l)$, un ejemplo de estos sería : Si $\mu_{\bar{B}^l}(\bar{y}^l)$ es discretizado en N_l puntos habrá $\prod_{j=1}^M N_j$ combinaciones.
4. Calcular el conjunto de altura reducido con $Y_h(X) = \int_{\theta_1} \int_{\theta_2} \dots \int_{\theta_M} [\mu_{D^1} \theta_1 \star \dots \star \mu_{D^M}(\theta_M)] / \frac{\sum_{l=1}^M \bar{y}^l}{\sum_{l=1}^M \theta_l}$. Debido a la

naturaleza del conjunto de salida combinado es discreto, es posible aplicar el producto o t -norma mínima. Para el cálculo de la suma de altura y función de membresía es necesario repetir $\prod_{j=1}^M N_j$ generalmente $\prod_{j=1}^M N_j \ll \prod_{j=1}^M N_j$ donde N es un número discreto de y puntos

c) **Reducción de tipo de centro de conjuntos:** Cada conjunto del consecuente es reemplazado por un centroide, calculando el promedio de estos, donde el peso asociado al centroide expresado como: $\prod_{i=1}^p \mu_{\tilde{F}_i^l}(x_i)$ es el grado de disparo correspondiente la regla l y así obtener el centroide del conjunto tipo I, este proceso

se obtiene a través de la siguiente expresión: $y_{cos}(x) = \frac{\sum_{l=1}^M c^l T_{i=1}^P \mu_{\tilde{F}_i^l}(x_i)}{\sum_{l=1}^M T_{i=1}^P \mu_{\tilde{F}_i^l}(x_i)}$ donde T

indica la t-norm seleccionada y c^l es el centroide del l_n del conjunto consecuente. Si el conjunto consecuente es simétrico, normal o convexo, entonces $c^l = \bar{y}^l$ y $\mu_{G^l}(\bar{y}^l) = 1$ para $l = 1, \dots, M$ por lo tanto para este caso $y_{cos}(x) = y_h(x)$.

La ecuación utilizada para el tipo reducido en versión extendida es la siguiente:

$$Y_{cos}(x) = \int_{d_1} \dots \int_{d_M} \dots \int_{e_1} \dots \int_{e_M} T_{l=1}^M \mu_{C_1}(d_l) \star T_{l=1}^M \mu_{E_l}(e_l) \left/ \frac{\sum_{l=1}^M d_l e_l}{\sum_{l=1}^M e_l} \right.$$

Donde $T \wedge \star$ indican la selección de la *t-norma*; $d_l \in C_l = C_{\tilde{G}^l}$ el centroide del l conjunto consecuente y $e_l \in E_l = \prod_{i=1}^p \mu_{\tilde{F}_i^l}(x_i)$. Para obtener $y_{cos}(x)$ es necesario realizar los siguientes cálculos:

1. Discretizar el espacio de salida Y en un número adecuado de puntos y calcular el centroide $C_{\tilde{G}^l}$ de cada conjunto del consecuente en el espacio de salida

discretizada usando $C_{\tilde{A}} = \int_{\theta_1} \dots \int_{\theta_N} [\mu_{D_1}(\theta_1) \star \dots \star \mu_{D_N}(\theta_N)] \left/ \frac{\sum_{i=1}^N (x_i \theta_i)}{\sum_{i=1}^N \theta_i} \right.$ donde

$\theta_i \in D_i$ cada punto x_i de \tilde{A} tiene un grado de membresía difusa tipo 1 $D_i = \mu_{\tilde{A}}$ asociado a este. Si se desea encontrar el centroide debe de considerarse las combinaciones $\theta_1, \dots, \theta_N$ entonces para el cálculo de $C_{\tilde{A}}$ se realiza a través de la siguiente expresión:

$$C_{\tilde{A}} = \int_{x(\theta_1, \dots, \theta_N)} [\mu_{D_1}(\theta_1) \star \dots \star \mu_{D_N}(\theta_N)] \left/ x \right. \text{ donde } (\theta_1, \dots, \theta_N) \text{ tal que } \frac{\sum_{i=1}^N x_i \theta_i}{\sum_{i=1}^N \theta_i} = x, \star$$

indica la elección de *t-norma*

2. Se calcula el grado de disparo $E_l = \prod_{i=1}^p \mu_{\tilde{F}_i^l}$ asociado con el $l = (1, 2, \dots, M)$ conjunto consecuente usando el resultado en las siguientes ecuaciones $\mu_{\tilde{B}^l}(\bar{y}^l) = \mu_{\tilde{G}^l}(\bar{y}^l) \cap \left[\prod_{i=1}^p \mu_{\tilde{F}_i^l}(x_i) \right]$,

$$Y_{cos}(x) = \int_{d_1} \dots \int_{d_M} \dots \int_{e_1} \dots \int_{e_M} T_{l=1}^M \mu_{C_1}(d_l) \star T_{l=1}^M \mu_{E_l} e_l \left/ \frac{\sum_{l=1}^M d_l e_l}{\sum_{l=1}^M e_l} \right.$$

3. Discretizar el dominio de cada $C_{\tilde{G}^l}$ en un número de puntos $M_l, l = 1, 2, \dots, M$
 4. Discretizar el dominio de cada E_l en un número de puntos $N_l, l = 1, 2, \dots, M$
 5. Enumerar todas las posibles combinaciones $[c_1, \dots, c_M, e_1, \dots, e_M]$ tal que $d_l \in C_{\tilde{G}^l} \wedge e_l \in E_l$ el total de combinaciones será dado por $\prod_{j=1}^M M_j N_j$
 6. Calcular el conjunto de tipo reducido

$$Y_{cos}(x) = \int_{d_1} \dots \int_{d_M} \int_{e_1} \dots \int_{e_M} T_{l=1}^M \mu_{C_l}(d_l) \star T_{l=1}^M \mu_{E_l}(e_l) \left/ \frac{\sum_{l=1}^M d_l e_l}{\sum_{l=1}^M e_l} \right. \text{ donde } T \wedge \star$$

= *t-norma*; $d_l \in C_l = C_{\tilde{G}^l}$ el centroide del l conjunto consecuente y $e_l \in E_l = \prod_{i=1}^p \mu_{\tilde{F}_i^l}(x_i)$ el grado de asociación del l conjunto consecuente, $l = 1, \dots, M$ en

$$\text{este caso } \alpha = \left(\frac{\sum_{l=1}^M d_l e_l}{\sum_{l=1}^M e_l} \right) \wedge b = T_{l=1}^M \mu_{C_l}(d_l) \star T_{l=1}^M \mu_{E_l}(e_l)$$

La Fig. 2.6 muestra la estructura de conjuntos Tipo 2 de un sistema de lógica difusa, formada por varios conjuntos Tipo 1, En el conjunto Tipo Reducido Y se encuentran todos estos conjuntos, en la colección de Conjunto tipo Reducido se encuentra representada la membresía de cada conjunto tipo 1, donde localizando el centroide del conjunto Reducido es posible defuzzificar el valor de salida.

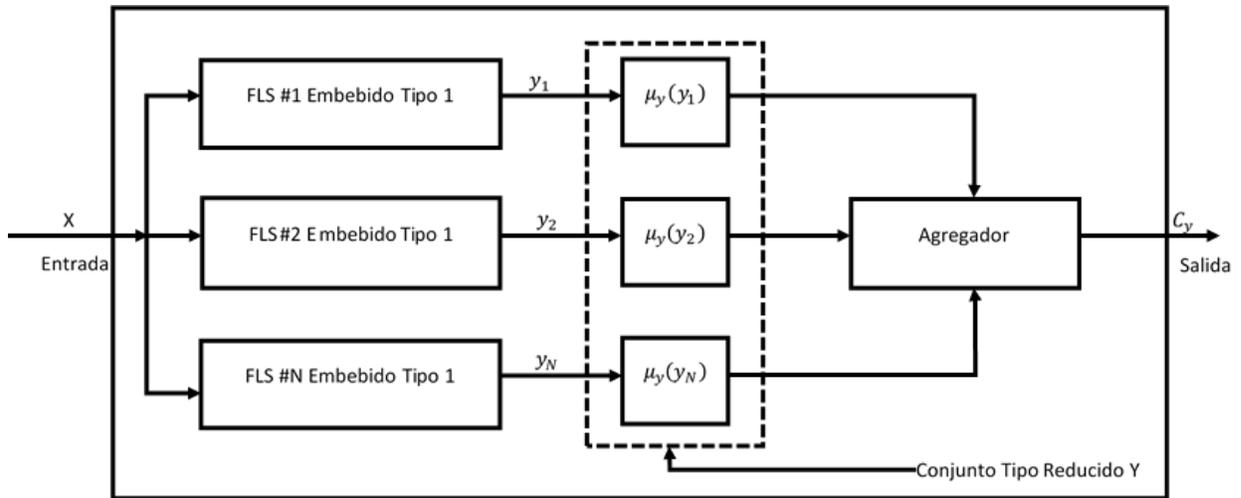


Figura 2.6 Conjuntos difusos Tipo 2 (Karnik & Mendel, 1998)

Finalmente, la defuzzificación del conjunto reducido es la etapa final de un sistema de lógica difusa tipo II la forma más sencilla es a través del centroide del conjunto tipo reducido, este centroide es el promedio de altura de todos los conjuntos difusos tipo I, donde los pesos son las membresías del conjunto tipo reducido, si en el conjunto reducido Y para x es discreto y consta de N puntos entonces el cálculo del centroide se realiza utilizando la expresión

$$C_y(x) = \frac{\sum_{k=1}^N y_k \mu_Y(y_k)}{\sum_{k=1}^N \mu_Y(y_k)}$$

2.3. Modelado de procesos de manufactura no convencional con lógica difusa

En esta sección se describe la aplicación de los sistemas de inferencia difusos en la construcción de modelos representativos de parámetros de procesos de manufactura no convencional en sus diferentes modalidades de funcionamiento.

En (Rama, et al., 2009) se modeló un proceso de maquinado electroquímico utilizando herramientas de inteligencia artificial como lo es la lógica difusa y algoritmos genéticos; los parámetros de salida del modelo fueron tasa de remoción de material y acabado de la superficie (Ra), como parámetros de entrada al algoritmo de inferencia Mamdani fueron corriente en un rango de 200 a 280 A, voltaje de 20 a 36 V, tasa de flujo entre 20 y 36 lt/min, y distancia entre electrodos (usualmente denominado como *gap*, por su denominación en inglés) entre 0.1 y 0.5 mm, el conjunto de datos de entrenamiento se formó de 200 datos

generados de manera aleatoria a través de regresión lineal, funciones de membresía triangulares como salida en los siguientes términos lingüísticos: bajo (L), medio (M) y alto (A), la desviación porcentual absoluta promedio en la predicción de la rugosidad de la superficie y la tasa de remoción de material es igual a 8.256 y 4.618% respectivamente lo cual concluyen que el modelo muestra un buen desempeño y precisión en la predicción en las variables de salida.

(Kholi, et al., 2012) desarrollaron un modelo computacional para el proceso de maquinado por descarga eléctrica, a través de este modelo buscan establecer la relación que existe entre los parámetros de entrada y los parámetros de salida de dicho proceso, como parámetros de entrada tenían la entrada de corriente de descarga (I_p), tiempo de activación (T_{on}), tiempo de desactivación (T_{off}) y como salida la tasa de remoción de material.

El proceso de modelado estuvo basado en un conjunto experimental de 20 datos previamente realizado donde utilizaron como material de trabajo acero de carbón medio y una herramienta de trabajo de cobre. Lógica difusa fue la técnica computacional utilizada para modelar el proceso, para los parámetros de entrada mencionados anteriormente se utilizaron 6 conjuntos difusos con funciones triangulares, Mamdani como método de inferencia.

Como resultado del modelo se observa una predicción de tasa de remoción de material de $250 \text{ mm}^3 / \text{min}$ con una corriente de descarga de 28.5 Volts, un tiempo de activación de 61.5 μs y tiempo de desactivación de 41.5 μs , basado en los resultados obtenidos del modelo determinan un porcentaje de error de 2.64% y una precisión de 97.36 % respecto al conjunto de datos experimentales. Para finalizar (Kholi, et al., 2012) dejan el camino abierto para modelar procesos de manufactura usando técnicas computacionales, ya que a través de la creación de modelos se puede conocer el resultado final del proceso sin la necesidad de realizar de manera empírica a prueba y error los experimentos, sin utilizar recursos materiales y tiempo.

Otra formulación de modelo es presentado (Shabgard, et al., 2013) el modelo difuso fue realizado para el proceso de maquinado por descarga eléctrica donde los parámetros de salida a predecir fueron tasa de remoción de material, rugosidad de la superficie y desgaste de la pieza de trabajo tomando en cuenta parámetros los siguientes parámetros de entrada corriente y duración de pulso, como algoritmo de inferencia utilizaron Mamdani donde el modelo

estuvo compuesto de 81 reglas y 5 conjuntos difusos para cada una de las variables de la función triangular, centroide de área como defuzzificador los resultados arrojados muestran un promedio del 90% de precisión comparado con sus datos experimentales.

(Deepak, et al., 2018) utilizaron lógica difusa para realizar el modelado de un proceso de maquinado por descarga eléctrica utilizando pulso de corriente(I), revoluciones por minuto (RPM), concentración abrasiva, y tiempo de pulso como variables de entrada, y variables de salida rugosidad de la superficie y tasa de remoción de material, para el desarrollo de este modelo utilizaron como algoritmo de inferencia difusa Mamdani compuesto de 25 reglas, con 5 conjuntos difusos: muy bajo (VL), bajo (L), medio(M), alto(H), muy alto(VH) para cada variable de entrada y para tasa de remoción de material, sin embargo para la rugosidad de la superficie los conjuntos fueron excelente(E), bueno(G), promedio(A), malo(B), y aproximado(R), el valor para cada variable se encontraba de la siguiente manera: Revoluciones por minuto 700-1300 RMP; concentración abrasiva 0-8g/L; corriente de pulso 2-10 A; tiempo de pulso de 10 a 7 μ s; tasa de remoción: 5-10 mm³/min y rugosidad de la superficie 2.8-5.8 μ m. Finalmente, las funciones de membresía utilizadas por los autores fueron, gaussianas, triangulares, trapezoidales y como defuzzificador centroide de área, los resultados obtenidos muestran que el modelo obtiene una precisión de 93.89% concluyendo lo siguiente: cuando existen aumento en la corriente (71.01), en el tiempo del pulso (17.02) y en las revoluciones por minuto (83.89) la tasa de remoción de material aumenta.

En (Yilmaz, et al., 2006) realizaron un modelo del proceso de maquinado por descarga eléctrica utilizando como pieza de trabajo AISI 4340 (acero de baja aleación al cromo, níquel y molibdeno) y un electrodo de cobre de 8 mm de diámetro, cuyo propósito de realizar la experimentación y modelado es saber la relación que existe entre los parámetros de entrada respecto a la salida de los parámetros dentro del proceso, corriente de descarga, duración del pulso e intervalo del pulso fueron los parámetros de entrada y como parámetros de salida desgaste del electrodo, rugosidad de la superficie y tasa de erosión.

El modelo lo realizaron utilizando lógica difusa donde definieron 5 conjuntos difusos para cada una de las variables tanto de entrada como salida, la base de conocimiento se formó de 125 reglas bajo el algoritmo de inferencia Mamdani donde los autores mencionan que es el más común utilizado en la literatura, no mencionan el tipo de defuzzificador, como

conclusiones pueden observar que el modelo muestra un buen desempeño y para ello lo validan con los datos experimentales del maquinado.

En (Skrabalak, et al., 2004) representaron el proceso de maquinado electroquímico por descarga eléctrica a través de lógica difusa, las variables de entrada del modelo fueron: voltaje, corriente, tasa de flujo y distancia entre electrodos, como variables de salida tasa de remoción de material y rugosidad de la superficie, las funciones de membresía utilizadas fueron las triangulares donde para cada variable de entrada había 3 funciones de membresía, en el sistema de inferencia utilizaron 9 reglas difusas, el entrenamiento y validación del modelo se realizó a través de los datos experimentales.

Por su parte (Lin, et al., 2000) construyeron el modelo de un proceso de maquinado electroquímico por descarga eléctrica para optimizar dicho proceso, al igual que (Kholi, et al., 2012) utilizan lógica difusa y el método Taguchi para la creación del modelo, tomando en cuenta como parámetros de entrada: polaridad de la pieza de trabajo, tiempo de encendido, factor de trabajo, voltaje de descarga y fluido dieléctrico. Los parámetros de entrada fueron sometidos a un estudio de varianza denominada ANOVA bajo el cual determinaron los parámetros más significantes, para el proceso para este proceso el conjunto de datos consistente en 18 experimentos. En la tabla 2.1 se observan un listado de los trabajos encontrados en la literatura de los modelos de proceso de manufactura no convencional (ECM, EDM y ECDM) basados en lógica difusa.

Tabla 2.1 Modelos de los procesos no convencionales de manufactura basados en lógica difusa

Trabajo	Maquinado	Parámetros entrada/ Salida	Componentes de lógica difusa	Exactitud del modelo
Fuzzy Logic-Based Forward Modeling of Electro Chemical Machining Process (Rama, et al., 2009)	Maquinado Electroquímico (ECM)	Entradas: <ul style="list-style-type: none"> • Voltaje • Tasa de flujo • Distancia entre la pieza y herramienta de trabajo Salidas: <ul style="list-style-type: none"> • Tasa de remoción de material • Rugosidad de la superficie 	Fuzzificador: No menciona M. de inferencia; No menciona Defuzzificador: No menciona	No menciona
Optimization of material removal rate in electrical discharge machining using fuzzy logic. (Kholi, et al., 2012)	Maquinado por Descarga Eléctrica (EDM).	Entradas: <ul style="list-style-type: none"> • Corriente de descarga. • Tiempo de activación. • Tiempo de desactivación. Salidas: <ul style="list-style-type: none"> • Tasa de remoción de material 	M. de inferencia: Mamdani	97.36%
Fuzzy approach to select machining parameters in electrical discharge machining (EDM) and ultrasonic assisted. (Shabgard, et al., 2013)	Maquinado por Descarga Eléctrica (EDM).	Entradas: <ul style="list-style-type: none"> • Duración del pulso. • Corriente. Salidas: <ul style="list-style-type: none"> • Tasa de remoción de material. Rugosidad de la superficie 	M. de inferencia: Mamdani	90%

<p>Fuzzy logic-based model predicting material removal rate and average Surface roughness of machined Nimonic 80 A using abrasive mixed electro discharge diamond Surface grinding</p> <p>(Deepak, et al., 2018)</p>	<p>Maquinado por Descarga Eléctrica (EDM).</p>	<p>Entradas:</p> <ul style="list-style-type: none"> • Revoluciones por minuto de la rueda. • Concentración del dieléctrico. • Corriente. • Pulso activo <p>Salidas:</p> <ul style="list-style-type: none"> •Tasa de remoción de material. •Rugosidad de la superficie 	<p>M. de inferencia: Mamdani</p> <p>Defuzzificador: Método de centroide de área</p>	<p>93.89%</p>
<p>A User-friendly fuzzy based system for the selection of electro discharge machining process parameters</p> <p>(Yilmaz, et al., 2006)</p>	<p>Maquinado por Descarga Eléctrica (EDM)</p>	<p>Entrada:</p> <ul style="list-style-type: none"> • Corriente de descarga. • Duración del pulso. • Intervalo del pulso. <p>Salidas:</p> <ul style="list-style-type: none"> • Desgaste del electrodo • Rugosidad de la superficie. Tasa de erosión. 	<p>M. de inferencia: Mamdani</p> <p>Defuzzificador: Método centroide de área.</p>	<p>No menciona</p>
<p>Optimization of the electrical discharge.</p> <p>(Lin, et al., 2000)</p>	<p>Maquinado electroquímico por descarga eléctrica (ECDM).</p>	<p>Entradas:</p> <ul style="list-style-type: none"> • Polaridad de la pieza de trabajo. • Tiempo de encendido. • Ciclo de trabajo. • Voltaje de descarga. • Fluido eléctrico <p>Salidas:</p> <ul style="list-style-type: none"> • Tasa de remoción de material. • Desgaste del electrodo. 	<p>M. de inferencia: Método Taguchi</p> <p>Defuzzificador: Método centro de gravedad</p>	<p>El desgaste de la herramienta disminuyo 2.07% y la tasa de remoción de material aumento de 0.00159 a 0.000383.</p>

<p>Building of rules base for fuzzy logic control of the ECDM process. (Skrabalak, et al., 2004)</p>	<p>Maquinado por descarga eléctrica (ECDM).</p>	<p>Entradas:</p> <ul style="list-style-type: none"> • Voltaje. • Corriente. • Tasa de Flujo. • Distancia entre electrodos. <p>Salidas:</p> <ul style="list-style-type: none"> • Tasa de remoción de material. • Rugosidad de la superficie 	<p>—</p>	<p>La desviación porcentual absoluta de la rugosidad de la superficie y la tasa de remoción es de 8,256 y 4.618 respectivamente</p>
<p>Modelado del proceso de Maquinado ECDM mediante lógica difusa. (Leyva, 2018)</p>	<p>Maquinado Electroquímico por Descarga Eléctrica (ECDM).</p>	<p>Entradas:</p> <ul style="list-style-type: none"> • Voltaje de gap. • Corriente pico. • Frecuencia de voltaje. <p>Salidas:</p> <ul style="list-style-type: none"> • Tasa de remoción de material. • Diámetro de sobre corte. 	<p>Fuzzificador: Singleton M. de inferencia: Mamdani Defuzzificador: M. del centro de área, bisectriz, medida de máximos.</p>	<p>92.68%</p>

2.4 Sistema Híbrido de Inferencia Neuro-difuso.

En la construcción de modelos por medio de lógica difusa es posible tratar como problema de optimización la reducción del error, es decir la diferencia entre los valores predichos y los valores de validación. Esto se puede realizar por medio de técnicas de optimización combinatorias que permiten también la reducción de número de reglas simplificando el modelo a partir de un método heurístico, el más usado en este contexto es el denominado Sistema Híbrido de Inferencia Neuro-difuso.

Un Sistema Híbrido de Inferencia Neuro-difuso (*Hybrid neural Fuzzy Inference System*, *HyFIS* por sus siglas en inglés) es un método desarrollado por Kim y Kasabov en los años 90's, el cual combina los sistemas difusos y las redes neuronales, es utilizado principalmente como un método de optimización de funciones de membresía y reglas, sus principales ventajas es el tratamiento de la imprecisión, vaguedad o ambigüedad de la información además del poder de aprendizaje de las redes neuronales (Kim & Kasabov, 1999). Un ejemplo de la aplicación de este tipo de método es en el área financiera, específicamente para la predicción del precio índice bursátil Español (IBEX-35) presentado en el trabajo de (Oliver, 2020), donde crean dos modelos; uno utilizando una red neuronal backpropagation y otro con un red neuronal fuzzy híbrida, para el caso del modelo *HyFIS* crearon 18 modelos tomando en cuenta parámetros como conjuntos difusos y etiquetas lingüísticas, el error del modelo fue evaluado utilizando el error medio (ME), error cuadrático medio (RSME), error absoluto (MAE), error porcentual medio (MPE) y error porcentual medio (MAPE), donde la precisión del modelo se encuentra por arriba del 98% de precisión, mostrando un mejor desempeño que una red neuronal backpropagation.

Un trabajo más donde utilizan un método *HyFIS* es presentado por (Jozi, et al., 2019) donde utilizan una red neuronal difusa para la toma de decisiones respecto a la predicción del consumo de energía eléctrica, a través de datos entrenan y refinan modelos para pronosticar el consumo de energía considerando el uso de energías renovables donde aspectos como el clima, la humedad se ven involucrados en este proceso. El objetivo de la investigación presentada por estos autores es la construcción de una aplicación que permita al usuario utilizar diferentes técnicas de la inteligencia artificial en la previsión para predecir el consumo de energía eléctrica en edificios, entre estos están: Redes neuronales, Máquina de

Soporte Vectorial, Algoritmos genéticos, Wang Mendel, *HyFIS*. El desempeño de estas técnicas fue medido en términos del error tomando en cuenta el Error Porcentual Absoluto Medio (MAPE por sus siglas en inglés *Mean Absolute Percentage Error*), obteniendo un MAPE de 4.93% para Máquina de soporte Vectorial, 5.81% para *HyFIS*, 5.99% para Wang Mendel, 7.45% para algoritmos genéticos y 9.83% para redes neuronales. Observando que un método *HyFIS* es el segundo más bajo en términos del error. A través de la revisión de la literatura se puede observar que el método *HyFIS* obtiene un buen desempeño como optimizador de conjuntos reglas para la construcción de modelos. A través de la Fig. 2.7 se muestra la arquitectura general de un sistema *HyFIS*, a partir de esta Figura se describe lo siguiente; el sistema *HyFIS* se compone de 2 módulos (Wang & Mendel, 1992), (Kim & Kasabov, 1999):

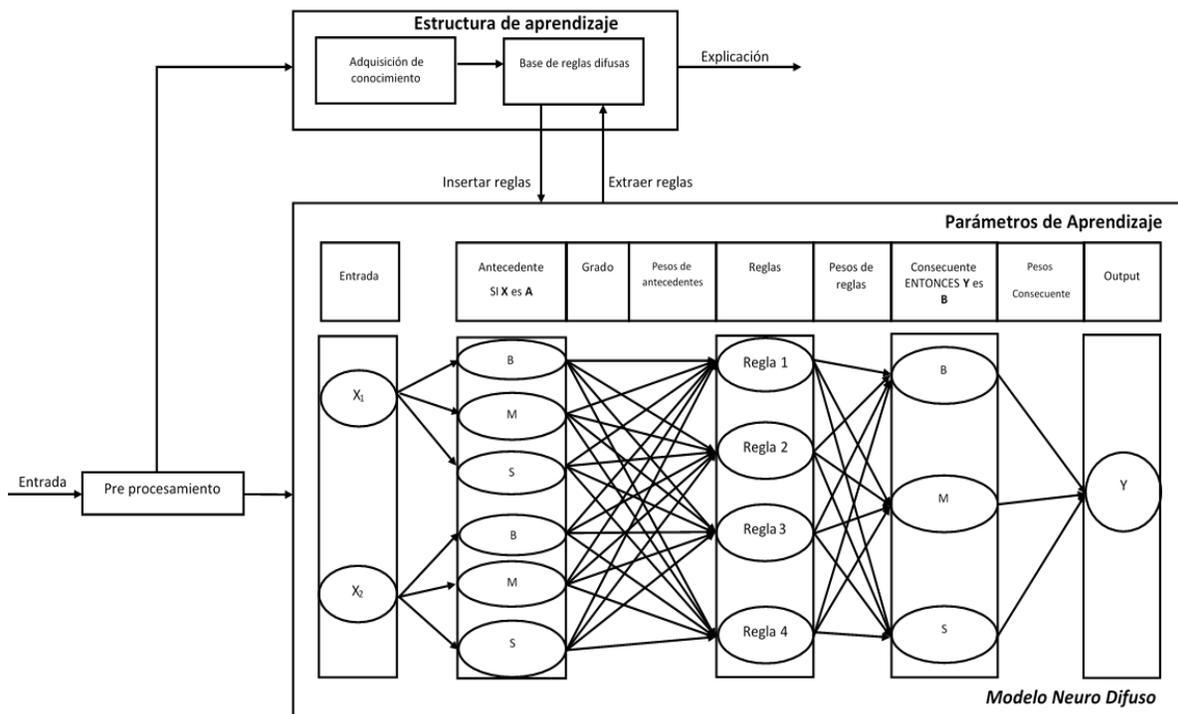


Figura 2.7 Arquitectura del método *HyFIS* (Kim & Kasabov, 1999)

1. **Módulo de adquisición de conocimientos (Búsqueda de reglas):** En este se realiza la definición de los conjuntos difusos, que serán objeto de optimización en el segundo módulo, así como la definición de las reglas difusas para la base de conocimiento y el motor de inferencia. El proceso de derivación de reglas se lleva a cabo a través del método propuesto por (Wang & Mendel, 1992), el cual se compone en 5 etapas que

se observan en la Figura 2.7, en la primer etapa se definen los conjuntos difusos para el conjunto de datos de entrada (x) y el conjunto de salida (y) como pares, teniendo en cuenta el intervalo del dominio de cada una de las variables. En la etapa de generación de reglas candidatas primero se calcula el grado para cada una de las variables respecto a las regiones difusas, posteriormente se crean las reglas de acuerdo al cálculo, al hacer este cálculo surgen reglas con antecedentes o consecuentes iguales para estos casos donde existe este conflicto se pasa a la siguiente etapa donde se calcula el grado D para las i -ésimas reglas en los conjuntos o regiones difusas μ_A, μ_B, μ_C , para las entradas x_1, x_2 y la salida (y). por medio de la expresión $D_i = \mu_A(x_1) \mu_B(x_2) \mu_C(y)$

Una vez asignado el grado a cada una de las reglas se procede crear la base de reglas utilizando las reglas creadas a partir del conjunto de datos (entrada-salida) comparándolas con las reglas generadas por el experto. Finalmente se realiza el proceso de defuzzificación utilizando la siguiente expresión: $\frac{\sum_{i=1}^k m_{oi}^i \bar{y}^i}{\sum_{i=1}^k m_{oi}^i}$. Donde \bar{y}^i representa el valor del centro de la región o^i y k es el número de reglas difusas de la base.

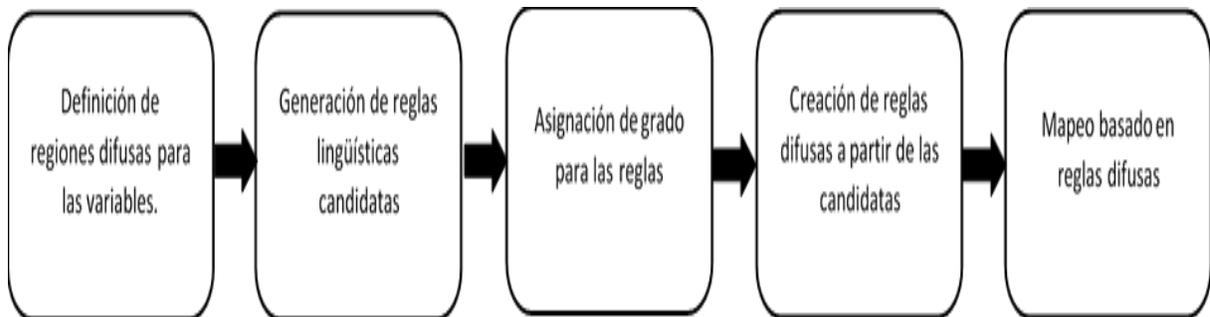


Figura 2.8 Derivación de reglas difusas a través del método (Wang & Mendel, 1992).

2. **Parámetros de aprendizaje (Fase de aprendizaje):** La función principal de este módulo es ajustar las funciones de pertenencias que fueron previamente definidas en el primer módulo, A través del uso de una red multicapa utilizando un algoritmo de aprendizaje basado en el gradiente descendiente, la red neuronal se compone de 5 capas.

La primer capa recibe el conjunto de datos de entrada $x_1, x_2, x_3, x_4, x_5, x_6 \dots \dots x_n$, en la segunda capa se realiza el proceso de fuzzificación, donde se realiza el cálculo de grado de pertenencia (μ_x) para el cada dato del conjunto de entrada (x_i), este cálculo se realiza a través de funciones de membresía gaussiana tomando en cuenta dos parámetros: σ que presenta el ancho y c que representa el centro de la campana, utilizando la expresión: $y_i = \exp^{-\left(\frac{(x-c)^2}{\sigma^2}\right)}$ la salida de este nodo (y_j) es el grado de pertenencia de cada conjunto, cada nodo de la capa 3 representan el antecedente candidato de la regla difusa, donde la función de la capa está determinada por la siguiente expresión: $y_j = \min_{i \in I_j} (y_i)$ donde I_j corresponde a los índices de los nodos de la capa 2 que se conectan al nodo j en la capa 3, y_i es la salida del nodo i correspondiente en la capa 2. La capa 4 representa el consecuente candidato para la regla, todos los nodos de las capas anteriores se encuentran conectados, los pesos de estas conexiones está dado por W_{kj} donde k son las pesos de la capa 4 y j los de la capa 3, los pesos iniciales entre la capa 3 y la capa 4 generados aleatoriamente entre un rango de $[-1,1]$, la función de esta capa está dada por la siguiente expresión : $y_j = \max_{j \in I_k} (y_j w_{kj})$ donde I_k representa a los índices de los nodos de la capa 3 que se encuentran conectados a los nodos k de la capa 4. Finalmente, la capa 5 funciona como un defuzzificador, los valores de salida son calculados utilizando el método de centro de gravedad (*Centre of Gravity* por sus siglas en inglés COA) o Centro de área (*Centre of Area*, por sus siglas en inglés COA), el defuzzificador es calculado por la siguiente expresión matemática: $y_l = \frac{\sum_{k \in I_l} y_k \sigma_{lk} c_{lk}}{\sum_{k \in I_l} y_k \sigma_k}$, I_l son los índices de los nodos de la capa 4 que se conectan a los nodos l de la capa 5 y c_{lk} y σ_{lk} corresponden al centro y ancho de la función de membresía gaussiana (Kim & Kasabov, 1999).

Una característica esencial de los sistemas neuro-difusos es la capacidad de combinar el conocimiento proporcionado por un conjunto de datos y el conocimiento adquirido por el experto transformándolo en sistemas difusos, esto hace que el desempeño de modelos creados a partir de este esquema sea superior a los modelos por si solos que utilizan lógica difusa o redes neuronales.

2.5 Algoritmos Evolutivos.

Los modelos difusos de los procesos de manufactura son susceptibles a convertirse en problemas optimización. Esta es una una de las áreas de la ingeniería, que se constituye como un conjunto de postulados cuya finalidad es encontrar en un espacio de búsqueda el mejor resultado posible o la óptima solución a problemas de alguna rama del conocimiento científico en entornos económicos, sociales y naturales si y solo si estos son modelables a través de funciones matemáticas del formato $f(x_1, x_2, \dots, x_n)$ maximizadas (o minimizadas, dependiendo del problema) por medio de un vector solución $\vec{x} = \{x_1, x_2, \dots, x_n\}$ en presencia o ausencia de determinadas consideraciones teórico/prácticas denominadas restricciones

Matemáticamente se puede formular un problema P de optimización sin restricciones como una terna $P = (f, SS, F)$, definida como $P = \begin{cases} \text{opt: } f(x), \\ \text{s. a,} \\ x \in F \subset SS \end{cases}$, donde f es la función para optimizar (se desea encontrar su máximo o mínimo), F el conjunto de soluciones factibles y SS el espacio de soluciones.

Por otra parte, un problema P con restricciones se puede modelar como $P = \begin{cases} \text{opt: } \min f(x), \\ \text{s. a,} \\ x \in F \left\{ \begin{array}{l} x | g_i(x) \leq 0, \\ i = 1, 2, 3, \dots, m, \end{array} \right\} \end{cases}$, donde f es la función para optimizar (se desea encontrar el mínimo o máximo valor de esta variable), F el conjunto de soluciones factibles donde x cumple las restricciones dadas por $g_i(x) \leq 0$ y $i = 1, 2, 3, \dots, m$

Cuando el problema P del entorno real al ser modelado presenta varias funciones objetivo f es necesario encontrar una o varias soluciones que satisfagan a todas las funciones. Esto es conocido como un problema de optimización multi-objetivo el cual puede ser representado

matemáticamente como $P = \begin{cases} f_m(x) & m = 1, 2 \dots, M, \\ \text{s. a,} \\ g_i(x) \geq 0 & i = 1, 2 \dots, I, \\ h_k = 0 & k = 1, 2 \dots, K, \\ x_j^l \leq x_j \leq x_j^u & j = 1, 2 \dots, J. \end{cases}$ Donde $x = (x_1, x_2, \dots, x_j)$ es el

vector de variables de estado que se desea encontrar y que cumple con el conjunto de restricciones dadas y donde las funciones objetivo se optimicen. El espacio de solución es

construido a partir de todas las combinaciones posibles en el rango de las variables, a partir de este se genera un segundo espacio vectorial, llamado espacio objetivo y denotado por $f_m(x) = z = (z_1, z_2, \dots, z_m)$ (Gen & Cheng, 2000)

La optimización se puede clasificar en:

- combinatoria es aquella que permite encontrar el valor x máximo o mínimo para determinada función f , sobre un conjunto F de posibilidades finitas de soluciones. Dicha $x \in Z$ puede establecerse como un número entero Z , una permutación o una estructura de grafo (o subgrafo) (Pérez, 1996).
- numérica encuentra un valor x máximo o mínimo para determinada función f , sobre un conjunto de posibilidades infinitas F . Dicha $x \in Z$ puede establecerse como un Z real que puede representarse en forma de vector.

La optimización numérica o continua se constituye como objeto de estudio de esta propuesta de tesis y se define como el conjunto de técnicas cuya finalidad es maximizar o minimizar una o más funciones con un número finito de variables, las cuales pueden estar sujetas a determinadas restricciones. La condición para emplear técnicas de optimización numérica es que se cumpla $\vec{x} = \{x_1, x_2, \dots, x_n\} \forall x \in \mathbb{Z}$ (Du & Swamy, 2016)

Un problema de optimización numérica es resoluble, en términos generales por medio de dos tipos de técnicas: estocásticas, en las cuales no se conocen todas las posibles soluciones relevantes para una función objetivo (Heyman & Sobel, 2004) y determinísticas, donde son conocidas todas las posibles soluciones (Cavazzuti, 2013). Además, se puede clasificar de acuerdo con su dominio de acción en numérica y combinatoria.

Una forma de solucionar problemas de optimización estocásticos y determinísticos es por medio de algoritmos evolutivos, estos se pueden definir como una colección de métodos heurísticos, es decir reglas obtenidas de un conocimiento previo de cierto dominio de un problema (Ergun & Hertem, 2016) que tienen pasos definidos inspirados en la mayoría de los casos por procesos biológicos como la reproducción y mutación de los seres vivos, la recombinación y la selección biológica (Chacon Montés, 1995) los cuales fueron propuestos por Charles Darwin en el libro “El origen de las especies” (Vasiljevic, 2002). Los trabajos de Mendel y Darwin permitieron el desarrollo de las primeras técnicas computacionales como

los Algoritmos Genéticos propuestos por John Holland y David Goldberg; así como las Estrategias Evolutivas propuestas por Ingo Rechenberg (Jacob, 2001).

Un algoritmo evolutivo está formado por individuos que pueden ser representados por medio del vector $P(t) = \{x_1^t, x_2^t, \dots, x_n^t\}$ que se denominan población, cada elemento $P(t)$ representa una posible solución a un problema de optimización numérica o combinatoria. Esta población se somete a un proceso iterativo de recombinación, transformación y selección (Robusté, 2005) después de un cierto número de iteraciones se espera que el mejor individuo es decir aquel que evaluado en una función objetivo tienda a un valor fijo que será considerado la solución a un problema de optimización (Shi, 2015). En Figura 2.9 se muestra la estructura de un algoritmo evolutivo

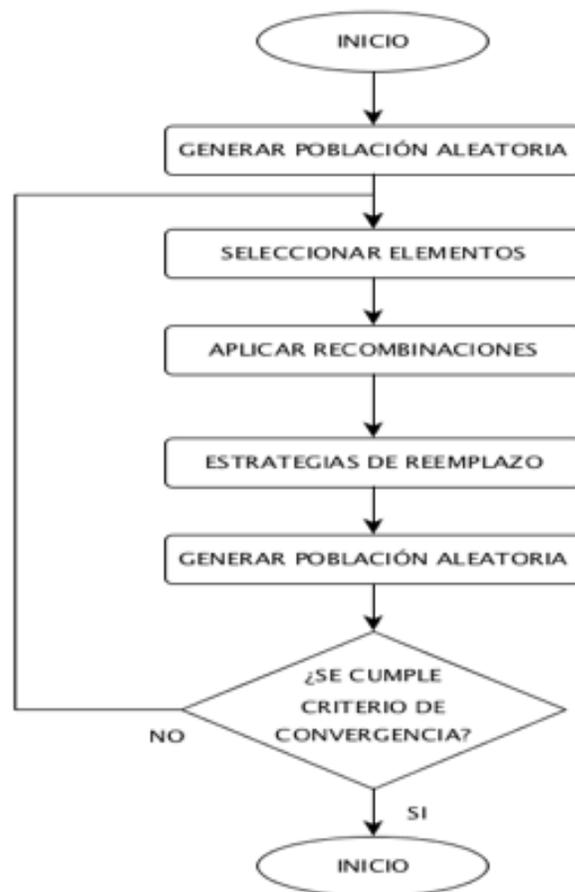


Figura 2.9.- Esquema de un algoritmo evolutivo (Gestal, 2013)

Los algoritmos evolutivos son un área de las tecnologías de la información que continúa en desarrollo, esto es justificable por el teorema “No Free Lunch” desarrollado por David Wolpert y William Macready (Lloyd, 2006), el cual determina en términos generales que no existe un algoritmo universal de solución de problemas de optimización. Es decir, una técnica que fue exitosa en un entorno no necesariamente funcionará de igual forma en otra situación (Du & Swamy, 2016)

2.6 Algoritmo genético canónico

Como se muestra en la sección anterior, un sistema neuro-difuso del tipo *HyFIS* puede reducir el número de reglas y conjuntos de un sistema de inferencia, esto es una optimización combinatoria, que tiene como finalidad eliminar las reglas que resulten redundantes a un sistema de inferencia, al cual se le puede aplicar una reducción más; esta tienen como objetivo la minimización de alguna métrica de error en función del ajuste que se realice a los conjuntos difusos, esto se puede lograr mediante algoritmo evolutivos, en específico, en este proceso investigativo, es el algoritmo genético

Los algoritmos genéticos son métodos de optimización y búsqueda basados en el principio de supervivencia y selección natural, el objetivo es encontrar la mejor solución a un problema determinado, a través de la generación de una población aleatoria, donde cada individuo representa una solución, el origen de estos algoritmos se remonta a finales del año 1950 y principios de año 1960 donde el biólogo inglés realiza una publicación de sus trabajos titulada “Simulación de sistemas genéticos por computadoras digitales automáticas”. Por otro lado, Hans-Joachin Bremermann, fue uno de los pioneros en ver el proceso de evolución como un proceso de optimización, el realizo una de las primeras simulaciones de procesamiento con cadenas binarias utilizando los operadores genéticos de reproducción, selección y mutación; esta simulación es considerada el predecesor de los algoritmos genéticos. Hacia el año 1962 John Henry Holland, intenta imitar el proceso de aprendizaje humano en una computadora (Coello & Toscano, 2001), (Abido, 2009), (Chacon Montés, 1995)

Un algoritmo genético funciona través de la generación de una población constituida por soluciones candidatas que se denominan individuos cuyo desempeño es determinado por

medio de una función objetivo. Los algoritmos genéticos son considerados procesos estocásticos, debido a su naturaleza estocástica es posible obtener resultados diferentes en las ejecuciones por lo tanto es necesario el uso de estudios estadísticos que permitan determinar la estabilidad de las ejecuciones, al ser una técnica utilizada para la resolución de problemas complejos; donde los cálculos a realizar se elevan considerablemente, al aumentar el número de genes de un cromosoma el costo computacional se eleva; por lo anterior al momento de diseñar un algoritmo genético se deben tomar en cuenta ciertos aspectos, como la forma de representación del cromosoma, el tipo de operadores genéticos a utilizar, la función objetivo que solucione el problema. En las secciones siguientes se describen los operadores que conforman un algoritmo evolutivo (Eiben & Smith, 2015), (Chipperfield, 1997).

Los algoritmos genéticos, en sus versiones canónicas o multiobjetivos tienen aplicación como métodos de solución para problemas de optimización, es posible identificar los siguientes componentes de un algoritmo genético, mostrados jerárquicamente en la Figura 2.10

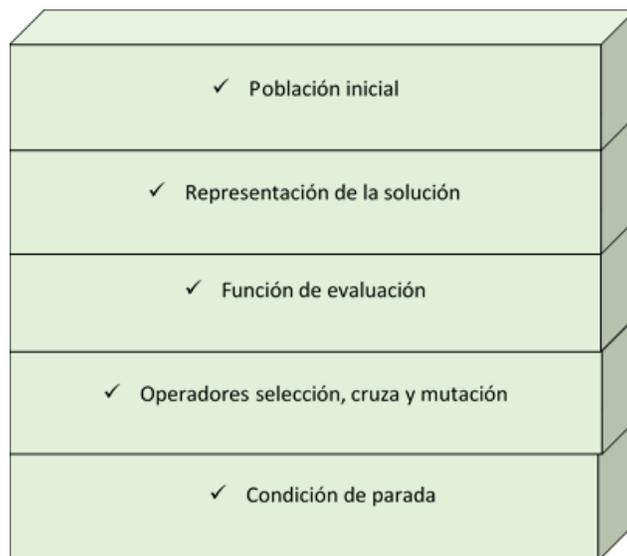


Figura 2.10 Componentes de un algoritmo genético (Peña, et al., 2011)

La población inicial o generación de población se realiza por medio de un generador de números aleatorios con una distribución aleatorio en un rango establecido por el universo del discurso del problema a tratar, la importancia de generación de la población radica en que una mala selección puede incidir en la localización de máximos locales. La unidad mínima

de un cromosoma se denomina gen y dependiendo del tipo de codificación puede representar una variable de decisión del problema de optimización. Un cromosoma representa las soluciones factibles al problema.

Las representaciones de las soluciones o cromosomas se codifican a partir de sistemas de numeración los cuales están determinados por la naturaleza del problema, la cual puede ser combinatoria o numérica

En (Chang & Chen, 1998) diseñan dos algoritmos genéticos para optimizar la función aplicado al diseño de un modelo de yacimiento de control de inundaciones; uno fue representado utilizando la codificación binaria y otro con codificación real .

En la codificación binaria el cromosoma se encuentra representado por cadenas de bits 0 y 1, este se conforma de genes los cuales representan una parte de la solución del problema ejemplo de esta representación se puede observar en la Figura 2.10. Dependiendo de la problemática a resolver es tipo de representación elegida, algunos ejemplos donde se ha utilizado la representación binaria es en el problema de la mochila, al agente viajero o el problema de las 8 reinas (Anrraz de la Peña & Parra, s.f.),((Chang & Chen, 1998)), los cuales son problema de optimización numérica. Una variante de este tipo de codificación es basada en el código Gray, una cadena de unos y ceros que no tienen ponderación (Ginzburg, 2002), que impide la aparición de clones en la etapa de recombinación o cruce, su representación es idéntica a la presentada en la Figura 2.11

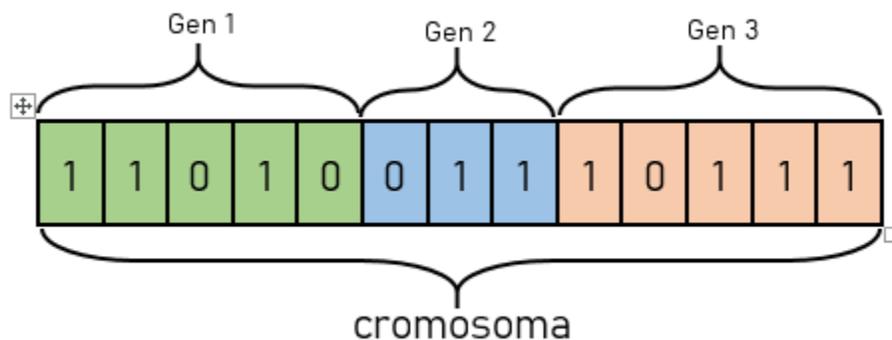


Figura 2.11 Cromosoma con codificación binaria (Gestal, 2013)

A diferencia de la representación binaria, los genes de un cromosoma con codificación real tomaran valores reales, de esta manera el cromosoma se ve como un vector de números reales como se puede ver el ejemplo en la Figura 2.11. (Chang & Chen, 1998) mencionan que existen diferencias significativas entre la representación real y binaria; por un lado (Antonissess, 1989) y (Wright, 1991) mencionan que una representación binaria obtendría mejores resultados comparada con la real, esta apreciación es equivocada dado que como se demostró en la sección de optimización la codificación está determinada por el tipo del problema, esto es comprobado por (Davis, 1991a) los genes no tienen que ser una potencia de dos, poseen la capacidad de granularidad, es decir ante cambios en los parámetros los cambios serán pequeños en la función.

0.25	0.12	0.15	0.89	0.69	0.50	0.25	0.89	0.42	0.63	0.13	0.11
Gen1	Gen2	Gen3	Gen4	Gen5	Gen6	Gen7	Gen8	Gen9	Gen10	Gen11	Gen12

Figura 2.12 Cromosoma con codificación real (Chang & Chen, 1998)

En los problemas de optimización y por lo tanto en los algoritmos genéticos el eje principal es la función objetivo, una expresión matemática que modela un determinado problema, esta ecuación mide el desempeño de las probables soluciones (Chipperfield, 1997). Una función objetivo $f(\vec{x})$ donde \vec{x} representa las variables de decisión de mismo debe de satisfacer algunas condiciones tales como las definidas por (Lahoz, 2004):

- La función $f(\vec{x})$ debe ser monótona creciente.
- $f(\vec{x})$ debe asegurar durante el proceso evolutivo la convergencia de la población hacia el valor óptimo representado por el máximo global de $f(x)$.
- $f(x)$ no debe ser una función negativa, evitando además los valores nulos, ya que los individuos no deben tener valores negativos o iguales a cero.
- $f(x)$ debe incluir parámetros con los que se pueda ajustar la forma y el rango de la función

A partir de las teorías evolutivas y leyes de la herencia propuestas por Darwin y Mendel solo los individuos más aptos tienen una mayor probabilidad de sobrevivir y generar descendencia, de esta manera, transmitir su herencia biológica a las nuevas generaciones (Sanbueza, et al., 1999).

Como se estipuló en secciones anteriores los algoritmos evolutivos tienen una colección de operadores que permiten la recombinación de las soluciones iniciales en la población, en el caso específico de los algoritmos genéticos estos operadores corresponden a los principios biológicos de selección, cruce y mutación, los cuales se explican en las siguientes secciones de esta propuesta de tesis

En algoritmos genéticos la selección es el proceso mediante el cual se eligen a los individuos encargados de ser los progenitores, durante esta etapa se pueden elegir a los mejores individuos, sin embargo, es posible también existe la probabilidad de elegir a un individuo no tan apto, existen diferentes tipos de operadores de selección, uno de estos es el operador de ruleta, como su nombre lo indica hace referencia a una ruleta donde la proporcionalidad dentro de esta dependerá de la aptitud obtenida por el individuo, de esta manera existen una gran probabilidad de elegir individuos con una alta aptitud, este tipo de operador ha sido el más usado desde los inicios de los algoritmos genéticos, fue propuesto por De Jon en la Figura 2.13 se puede observar la representación gráfica que ejemplifica una ruleta (Gestal, 2013), (Coello, 1995).



Figura 2.13 Operador ruleta (Gestal, 2013)

En el operador de Torneo, es otra alternativa para realizar la selección, en los cromosomas que componen la población son mezclados con la finalidad de integrar grupos de tamaño predefinido, usualmente parejas, los individuos que tengan el valor de aptitud más alto de cada grupo formado son mezclados de nueva cuenta. Esta técnica garantiza la obtención de múltiples copias del mejor individuo entre los padres de la siguiente (Nedjah, Abraham, & de Macedo Mourelle, 2006). La Figura 2.14 muestra el proceso de selección por Torneo.

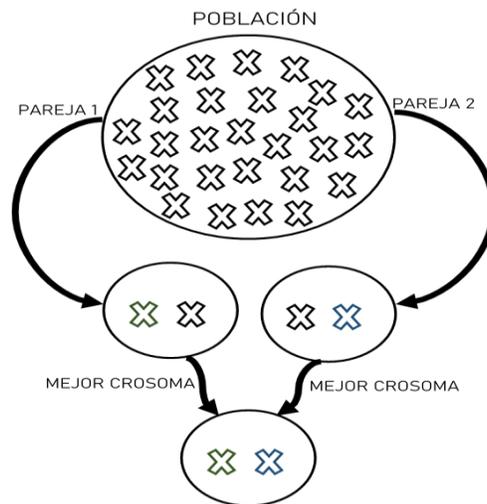


Figura 2.14 Esquema de selección de torneo (Elaboración propia).

La Selección Aleatoria es un operador donde los cromosomas son seleccionados en términos de una distribución aleatoria, de tal forma que todos los individuos de la población tienen la misma probabilidad de recombinarse, sin importar su densidad de probabilidad generada al ser evaluados en la función objetivo. Es simple de implementar computacionalmente pero no favorece la convergencia, ni la exploración de la totalidad del espacio de búsqueda (Sivanandam & Deepa, 2008)

Otro operador usado para seleccionar cromosomas a recombinar se denomina Elitismo, es un operador que privilegia la conservación de los individuos más aptos de tal forma que logren trascender en cada iteración, pero no favorece la exploración de todo el espacio de búsqueda. Esto permite que el mejor cromosoma de la presente generación trascenderá a la siguiente, los peores, es decir los de la valuación menor de la función objetivo son descartados progresivamente (Duriez, Brunton, & Noack, 2017), (Sivanandam & Deepa, 2008).

Posterior a la etapa de selección los cromosomas seleccionados son recombinados por medio de algún operador, el cual es determinado por el tipo de codificación, es decir, si $\vec{x} = [x_1, x_2, x_3 \dots x_n], \forall x \in \mathbb{Z}$, el dominio del problema es discreto y por lo tanto se trata de un problema de optimización combinatoria el operador de recombinación usado es el binario simple. Este se realiza sobre un punto p_i en un intervalo $[0, L - 1]$ el cual es elegido de forma aleatoria sobre la longitud L de la cadena binaria representativa del cromosoma involucrado (Lee, et al., 2006)

A partir del cruzamiento binario se realiza el intercambio de material de los 2 individuos o cromosomas, tal como se muestra en la Figura 2.15. Este tipo de operador es empleado sobre dos cromosomas y tiene como resultado, en la siguiente generación, dos descendientes. Cuando el punto de cruce es cualquiera de los dos extremos de la cadena no se realiza la cruce.

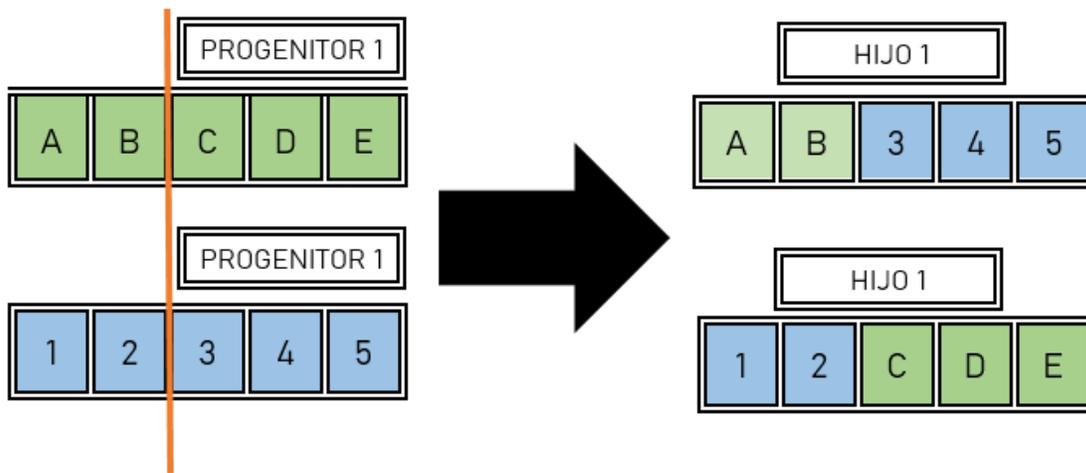


Figura 2.15 Cruzamiento binario de un punto (Gestal, 2013)

Otra variante de cruzamiento aplicado a vectores es el cruzamiento de dos puntos en este tipo de cruce se realizan 2 cortes de manera aleatoria en los cromosomas progenitores, estos puntos de corte no debes ser en los extremos del cromosoma de cada uno de los progenitores, una vez habiendo realizado los puntos de corte se procede a generar los nuevos descendientes combinando los genes del centro del cromosoma progenitor, este procedimiento se puede observar gráficamente en la Figura 2.16

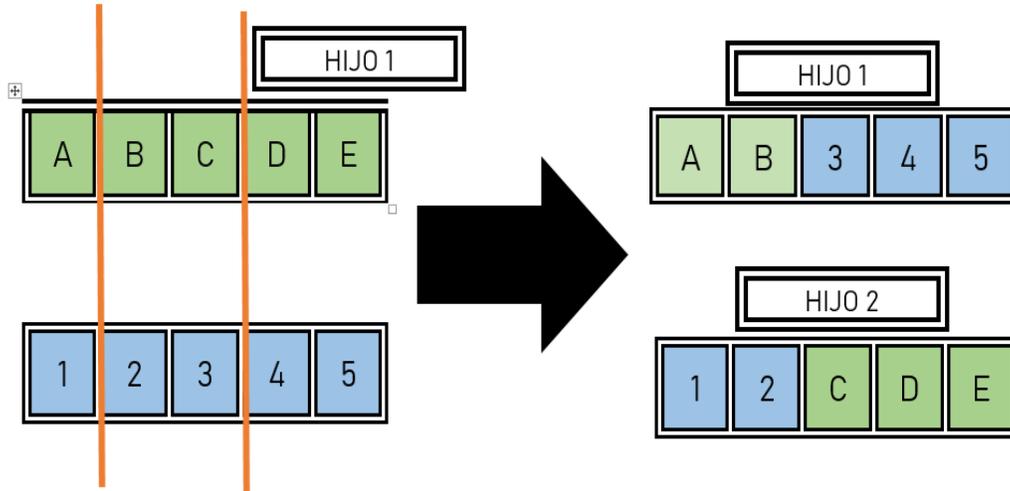


Figura 2.16 Cruzamiento binario de dos puntos (Gestal, 2013)

Cuando los cromosomas son codificados por medio de un sistema de codificación hexadecimal es posible aplicar el siguiente operador de recombinación o cruce conocido como *Uniform Point Crossover por sus siglas en inglés (UPX)* a través de una máscara es posible saber la posición se intercambiarán los genes de los progenitores para formar al descendiente, en el ejemplo de la Figura 2.17 se observa cómo se realiza este cambio, del progenitor 1 se tomara el primer, cuarto , sexto y séptimo gen para ser parte en esa misma posición del descendiente, del progenitor dos se tomaran los genes que se encuentran en la segunda, tercera y quinta posición para colocarlos en ese orden correspondiente. (Gestal, 2013).

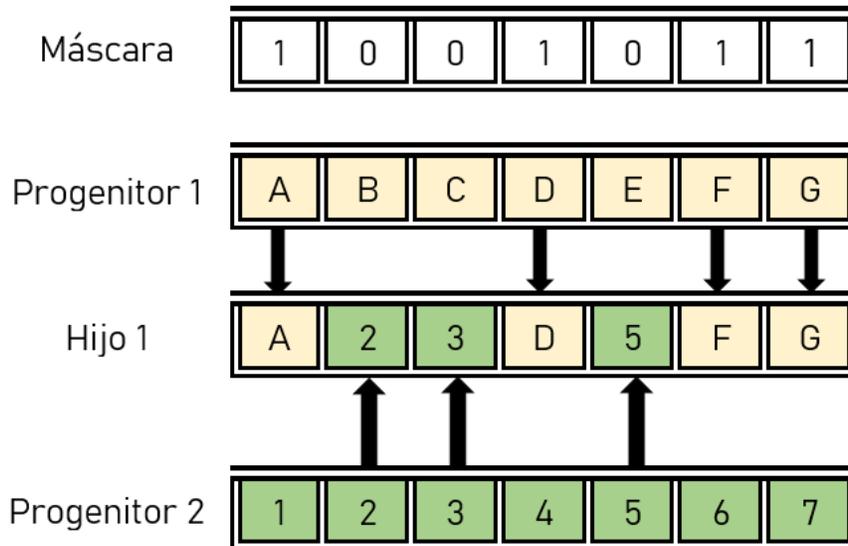


Figura 2.17 Cruzamiento uniforme (Gestal, 2013)

Si el vector de soluciones tiene la forma $\vec{x} = [x_1, x_2, x_3 \dots x_n]$, $\forall x \in \mathbb{R}$ las soluciones pertenecen a un problema del dominio continuo y se trata de un problema de optimización numérica, para esto existen diversas formas de recombinación. Una de ellas es el Cruzamiento Binario Simulado (*Simulated Binary Crossover*, SBX, por sus siglas en inglés). Este operador se inspira en el cruzamiento binario de un solo punto. Partiendo de dos cromosomas C^1, C^2 se pueden obtener dos cromosomas descendientes $C^{H1} = 0.5 * [(1 + \beta) * C_n^1 + (1 - \beta) * C_n^2], C^{H2} = 0.5 * [(1 - \beta) * C_n^1 + (1 + \beta) * C_n^2]$ (Olague, 2016).

Donde el valor de $\beta = \begin{cases} (2 * u)^{\frac{1}{\eta_{x+1}}} & \text{si } u < 0.5 \\ (\frac{1}{2 * (1-u)})^{\frac{1}{\eta_{x+1}}} & \text{si } u > 0.5 \end{cases}$ Para toda $u \in [0,1]$ y η_x un valor no

negativo que es representativo de distribución de los cromosomas descendientes en relación con sus progenitores.

Otro operador de cruce o recombinación es el operador de cruzamiento aritmético a partir de dos cromosomas progenitores C^{H1}, C^{H2} que generan dos cromosomas $C_n^{H1} = \beta * C_n^1 + (1 - \beta) * C_n^2, C_n^{H2} = \beta * C_n^2 + (1 - \beta) * C_n^1$, donde el valor de $\beta u \in [0,1]$. La constante β puede no cambiar durante todo el proceso tratándose de un cruzamiento aritmético uniforme, de caso contrario es un cruzamiento aritmético no uniforme.

De manera alternativa para los operadores antes descritos existe el operador de cruzamiento por mezcla (Blend Crossover, BLX- α , por sus siglas en inglés), a partir de dos cromosomas progenitores C^{H1} y C^{H2} , genera de forma aleatoria un descendiente $C^H = rand[(h_{min} - I * \alpha), (h_{max} + I * \alpha)]$ 2.143 (Gwiazda, 2006). Donde C^H es el cromosoma descendiente $h_{min} = \min(C_i^1, C_i^2)$, $h_{max} = \max(C_i^1, C_i^2)$, $I = h_{max} - h_{min}$, $\alpha = rand[0,1]$ con distribución uniforme. Cabe destacar que se pueden producir los descendientes que sean necesarios.

Derivado del operador de cruzamiento BLX- α (Simon, 2013) propuso el operador de cruzamiento plano (Flat crossover, FLX, por sus siglas en inglés) es una alternativa de cruzamiento derivado del operador BLX cuando $\alpha = 0$, por lo tanto, la expresión matemática de este operador se muestra en $C^H = rand[h_{min}, h_{max}]$, donde C^H es el cromosoma descendiente $h_{min} = \min(C_i^1, C_i^2)$, $h_{max} = \max(C_i^1, C_i^2)$. En este operador se generan tantos descendientes como sea necesario.

En (Simon, 2013) reporta el operador de cruzamiento lineal como un procedimiento de recombinación que a partir de dos cromosomas C^{H1}, C^{H2} genera tres descendientes $C_n^{H1} = 0.5 * C_n^1 + 0.5 * C_n^2$, $C_n^{H2} = \frac{3}{2} * C_n^1 - \frac{1}{2} * C_n^2$, $C_n^{H3} = -\frac{1}{2} * C_n^1 + \frac{3}{2} * C_n^2$

Posteriormente de la aplicación de algún operador de cruza, es necesario aplicar un operador de mutación, la cual, desde la biología se define como cambios moleculares en las secuencias de ADN los cuales son permanentes y trascienden generacionalmente (Solari, 2007), es decir sus características son traspasadas a la siguiente generación. En los algoritmos genéticos se emula este proceso con la finalidad de introducir variabilidad genética, es decir, impedir que los cromosomas tiendan de manera prematura a un óptimo local lo cual se traduciría en una convergencia prematura. La forma de este operador es determinada por el tipo de decodificación del cromosoma. Si se trata de un cromosoma con codificación binaria, es decir que tenga el formato $\vec{x} = [x_1, x_2, x_3 \dots x_n]$, $\forall x \in \mathbb{Z}$. Este se realiza sobre un p gen de preferencia más cercano al bit MSB sobre un intervalo $[0, L - 1]$ el cual es elegido de forma aleatoria sobre la longitud L de la cadena binaria representativa del cromosoma en cuestión, cambiando el punto en cuestión por su complemento, un ejemplo se muestra en la Figura 2.18 (Jamshidi, et al., 2003).

Gen antes de mutar

1	1	0	1	0	0	1	1	0
---	---	---	---	---	---	---	---	---

Gen después de mutar

1	1	0	0	0	0	1	1	0
---	---	---	---	---	---	---	---	---

Figura 2. 18 Mutación binaria (Jamshidi, et al., 2003).

A partir del operador descrito en la Figura 2.16 es posible diseñar una variación donde ahora se determinan varios puntos p dentro del intervalo $[0, L - 1]$ los cuales son elegidos de forma aleatoria con una distribución de probabilidad uniforme (Eiben & Smith, 2015). Un ejemplo de esto se muestra en la Figura 2.19 donde se realiza la mutación sobre tres puntos.



Figura 2. 19 Mutación sobre varios puntos (Eiben & Smith, 2015).

Cuando los cromosomas tienen una representación de la forma $\vec{x} = [x_1, x_2, x_3 \dots x_n]$, $\forall x \in \mathbb{R}$ no se pueden aplicar las técnicas antes descritas, por lo tanto es necesaria la aplicación de otro tipo de operador como la mutación al azar, a partir de la cadena de números representativa de un cromosoma se modifica un gen g elegido al azar cambiando su valor por otro ubicado en un intervalo determinado. También se conoce como mutación uniforme.

La mutación no uniforme (Non uniform Mutation) es una variante del operador de mutación uniforme, donde el gen g a mutar adquiere un valor g' determinado como $g' =$

$$\begin{cases} [g + (b - x)f(G)], & \text{if } r < 0.5 \\ [g - (x + a)f(G)], & \text{if } r \geq 0.5 \end{cases} \text{ (Gen \& Cheng, 2000) donde } f(G) = \left[r_2 \left(1 - \frac{G}{G_{max}} \right) \right]^b, r \text{ y } g, \text{ para otro caso}$$

r_2 son números aleatorios de distribución uniforme en un rango de 0 a 1, G es la generación actual y G_{max} es el número máximo de generaciones (Gen & Cheng, 2000) y b es un parámetro de forma que recibe usualmente un valor de 5 (McAllister & Bulmer, 2002), cabe destacar que existen algunas variantes sobre este operador, a partir del valor que puede adquirir r el cual puede ser binario 0 o 1 (McAllister & Bulmer, 2002).

Otro operador encargado de modificar a un determinado cromosoma es la mutación Gaussina, la cual modifica a un cromosoma específico C elegido al azar por medio de una distribución de probabilidad gaussina de media 0 y varianza definida como $\sigma_k = \frac{T-t}{T} \frac{(g_k^{max} - g_k^{min})}{3}$, donde t es la generación actual, T es el máximo número de generaciones contempladas en el algoritmo de tal forma que el cromosoma mutado es determinado por $C' = C + N(0, \sigma_k)$. Posterior a la recombinación o cruce es necesario definir el mecanismo de reemplazo, es decir que sucederá con los cromosomas usados en la recombinación. Una de las opciones de reemplazo es el simple, descrito por (Goldeberg & Holland, 1988). En cada generación el algoritmo crea una nueva población de individuos a partir de la cual se repite el proceso. La vieja población es desechada en cada generación. Cuando se desea conservar el tamaño de la población original la nueva población se forma a partir de la población vieja y sus descendientes. Para conformar la nueva población el usuario debe especificar el porcentaje de individuos viejos a reemplazar en cada generación por los nuevos individuos. Otra opción de reemplazo es el incremental, en el que cada generación solo uno o dos descendientes sobreviven (Goldeberg & Holland, 1988).

Después de realizar el reemplazo de población se debe de establecer los criterios de paro o terminación de las ejecuciones del algoritmo, estos supuestos que debe de satisfacer son cumplir un número determinado de generaciones, cuando el mejor individuo de la población cumpla el valor predeterminado de la función de aptitud, cuando la población alcance un punto de convergencia (Goldeberg & Holland, 1988).

La relación entre los operadores descritos en las secciones anteriores se puede observar en la Figura 2.20, la cual representa el diagrama de flujo de un algoritmo genético canónico

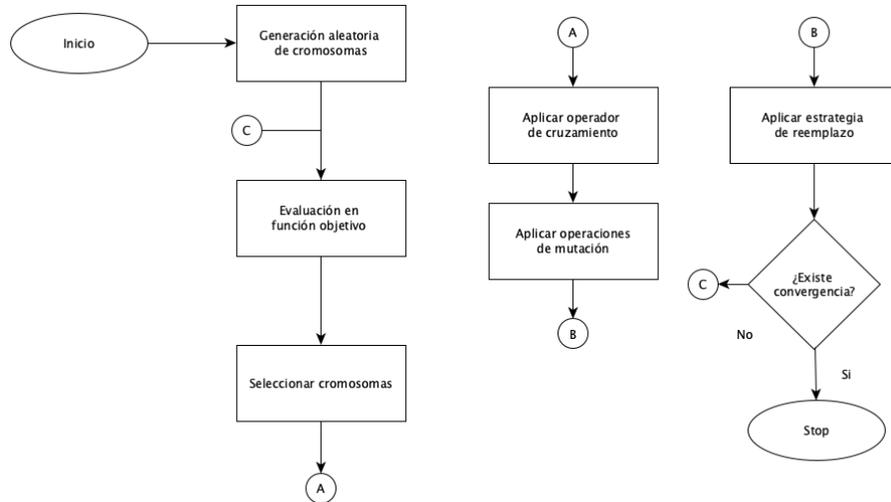


Figura 2.20 Diagrama de flujo de un algoritmo genético canónico (Goldeberg & Holland, 1988)

2.7 Micro algoritmo genético.

Uno de los inconvenientes de los algoritmos genéticos es su convergencia prolongada, es decir requiere un número alto de iteraciones necesarias para lograr la convergencia, es decir el número de generaciones necesarias para encontrar un óptimo local o global. Por lo tanto, existe posturas teóricas que buscan una alternativa que redunde en menos iteraciones, uso de procesador y consumo de memoria necesaria para su ejecución.

Una alternativa para reducir los costos computacionales de un AG canónico, es desarrollada por Goldberg y consiste en la creación de los micro algoritmos, es decir una variante de los algoritmos genéticos, donde observa que a través de una población pequeña de cromosomas 3 para ser exactos es posible que esta converja sin importar el tamaño del cromosoma, Goldberg aplica operadores genéticos a esta población pequeña hasta que esta obtenga una convergencia nominal, es decir que todos los cromosomas de la población sean muy parecidos en sus genes, después de esto se genera una nueva población conformada por los mejores obtenidos de la convergencia nominal el resto de los individuos que también formaran a la nueva población son generados de manera aleatoria. El proceso de un micro algoritmo genético se puede observar en el diagrama de flujo de la Figura 2.17 (Coello, 1995), (Coello & Toscano, 2001) (Gutiérrez, et al., 2007) :

- i. Generación de la población de memoria (P), dividida en dos; reemplazable (Pr) y no reemplazable (Pnr).
- ii. Obtención de la población de trabajo (Pt)
- iii. Aplicación de filtro y selección de 2 soluciones: C_1 , C_2 ,
- iv. Comparación de las soluciones, para formar parte de la nueva población
- v. Se insertan en el archivo histórico
- vi. Comienza el nuevo ciclo hasta la condición de parada.
- vii. Se aplican los operadores genéticos de selección, cruza, mutación y elitismo, para llegar a la convergencia nominal cuando se cumplan el número de iteraciones determinadas.

Uno de los primeros micro algoritmos que fueron diseñados e implementados son los presentados por (Krishnakumar, 1989) donde utilizo una población de 5 cromosomas , con un porcentaje de cruza de 1 y un porcentaje de mutación 0, emplearon como operador de selección elitista donde el mejor cromosoma era elegido para ser parte de la nueva población, a su vez (Krishnakumar, 1989) realizo una comparación entre su micro algoritmo genético y la versión canónica, en la versión canónica los parámetros fueron una población de tamaño 50, con un porcentaje de cruza de 0.6 y mutación de 0.00, los resultados mostraron resultados eficiente sobre 2 funciones estacionarias, y un problema de control de ingenierías del mundo real.

Por su parte (Coello & Toscano, 2001) diseñaron un micro algoritmo genético multiobjetivo, el objetivo del micro algoritmo genético era optimizara las siguientes funciones, encontradas en la revisión de la literatura, donde utilizo un operador de selección de torneo, un operador de cruza de 2 puntos, y una mutación uniforme.

El micro algoritmo con 150 iteraciones y un porcentaje de mutación de 0.556, ejecuto las corridas con un promedio de tiempo de 0.017 segundos, 0.107 segundos, 0.704 segundos 0.26896. Un trabajo más es presentado por (Gutiérrez, et al., 2007) se construye un micro algoritmo genético aplicado a un portafolio de accionario, la representación utilizada para el cromosoma fue binaria, formado por 72 genes, donde cada uno representaba un activo

financiero, el tamaño del gen fue de 20 bits y un total de 1480 bits para el cromosoma, aplicando 100 generaciones, como operadores genéticos utilizaron como operador de selección torneo binario con una base de dominancia y relación rentabilidad/ riesgo, con una probabilidad de cruce de 50% y dos puntos de cruce y una probabilidad de mutación de 0.002027027 utilizando una mutación bit a bit,

El uso de los micro algoritmos genéticos se ha popularizado debido a las ventajas que presenta, estos son una técnica eficiente, a aplicada a problemas donde el objetivo de optimización no es uno sino varios, además de su fácil implementación, el costo computacional es considerablemente menor comparado con el que presenta un algoritmo en su versión canónica; donde se dice que esto se debe al tamaño de la población, entre mayor sea el número de cromosomas más tiempo se requiere para explorar el espacio de búsqueda con el fin de encontrar la mejor solución a la problemática (Abido, 2009) (Coello & Toscano, 2001), (Lee, et al., 2006).

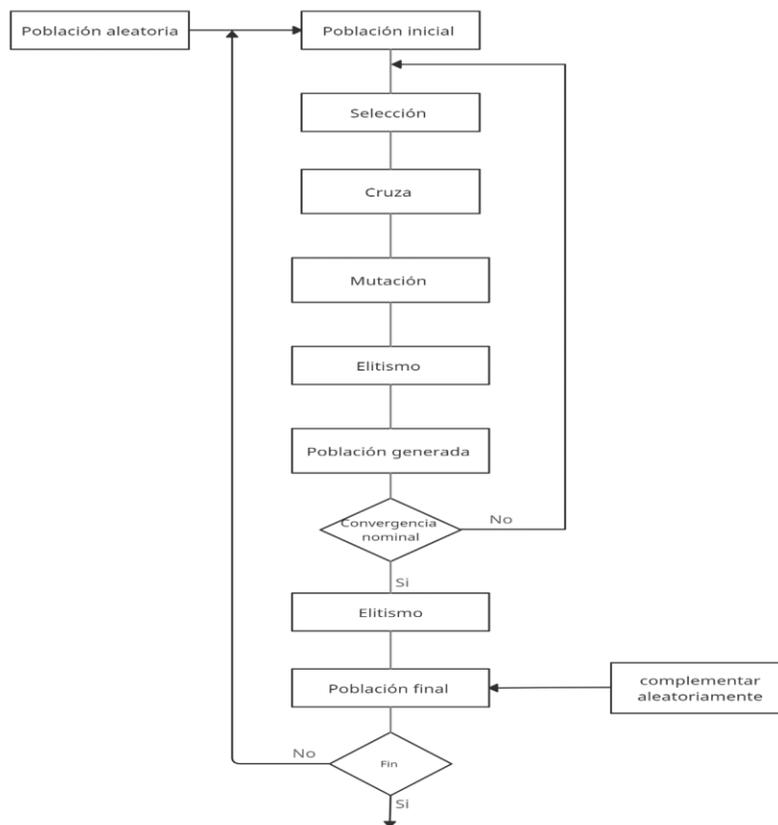


Figura 2.21 Diagrama de flujo de un micro algoritmo genético (Coello, 1995)

Capítulo 3 METODOLOGÍA

En esta sección se muestra la metodología empleada en este trabajo, la cual consiste en esencia en una serie de experimentos que tienen como finalidad demostrar la utilidad del micro algoritmo genético, con respecto al ajuste realizado por medio de prueba y error presentado en (Leyva, 2018). Cabe destacar que en el método heurístico empleado enfatiza la codificación real sobre la binaria, debido al dominio del discurso involucrado en la creación del modelo esta expresado en dominio continuo.

En primer término, en esta sección se muestra la descripción del enfoque de la presente investigación, posteriormente por medio de diagramas se explica el proceso de experimentos que permitirá confirmar la pertinencia de un micro algoritmo genético. Por último, se muestra la descripción de los experimentos. Estos tienen como finalidad determinar cuáles son los parámetros que permiten el diseñar el mejor modelo representativo del modelo de maquinado

3.1.- Tipo de Investigación

El tipo de investigación de este trabajo es de corte cuantitativo, dado que el comportamiento de un modelo de manufactura se evalúa en función de un criterio de desempeño tal el error promedio absoluto (*MAPE*). Este valor se puede manipular por medio de la sintonización de los conjuntos difusos por medio de un micro algoritmo genético con codificación real documentado en el capítulo anterior. Esto permite inferir que el tipo de investigación es experimental, dado que la manipulación de parámetros permite la obtención de error promedio absoluto menor en los parámetros diámetro de sobrecorte (*DOC*) y tasa de remoción de material (*MRR*)

El objeto de estudio de la propuesta que se documenta en este trabajo es la optimización un modelo del proceso de Maquinado Electroquímico por descarga eléctrica (*ECDM*) por medio del uso de un micro algoritmo genético, por lo tanto, es necesario de manera previa codificar un algoritmo genético canónico con codificación real. La Figura 3.1 muestra el esquema general del proceso metodológico, donde se observa la relación de las etapas necesarias para la comprobación/rechazo de la hipótesis formulada en el capítulo 1.

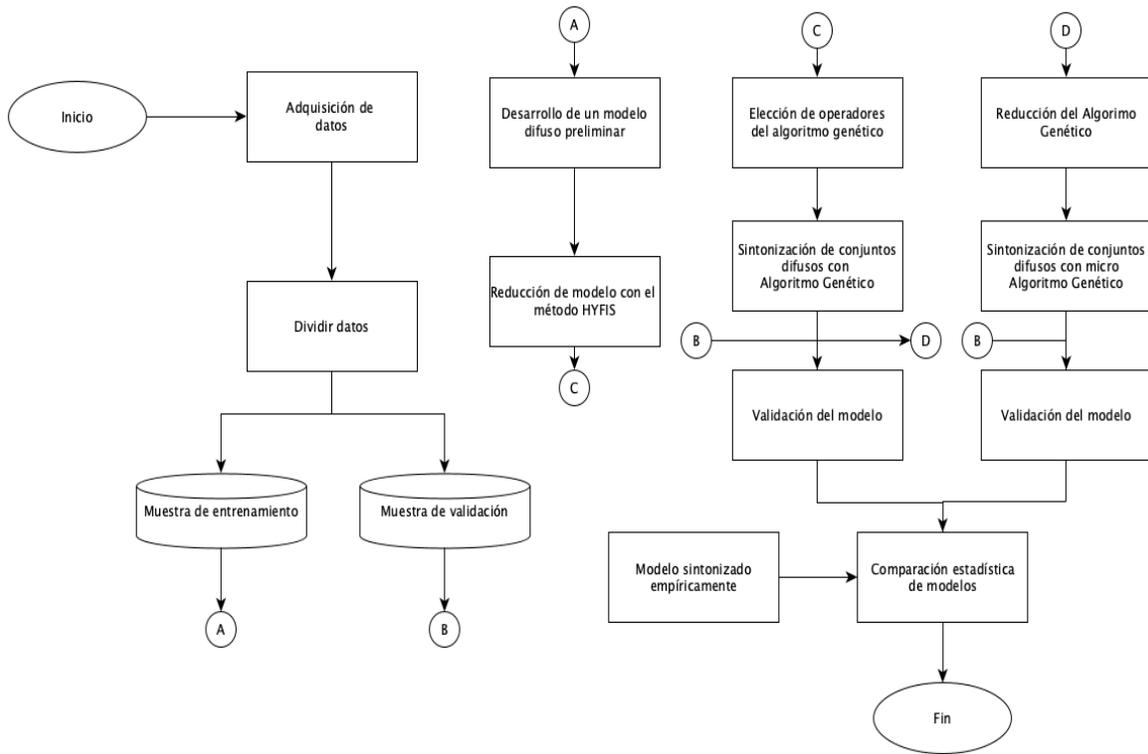


Figura 3.1 Esquema metodológico propuesto (Elaboración propia)

La naturaleza estocástica de los algoritmos evolutivos en términos generales hace preciso que se realice un estudio estadístico que tiene como finalidad determinar la estabilidad del algoritmo, establecer si existen parámetros estadísticos entre los algoritmos evolutivos usados en esta propuesta y verificar el rechazo aprobación de la hipótesis, este procedimiento es mostrado en la Figura 3.2

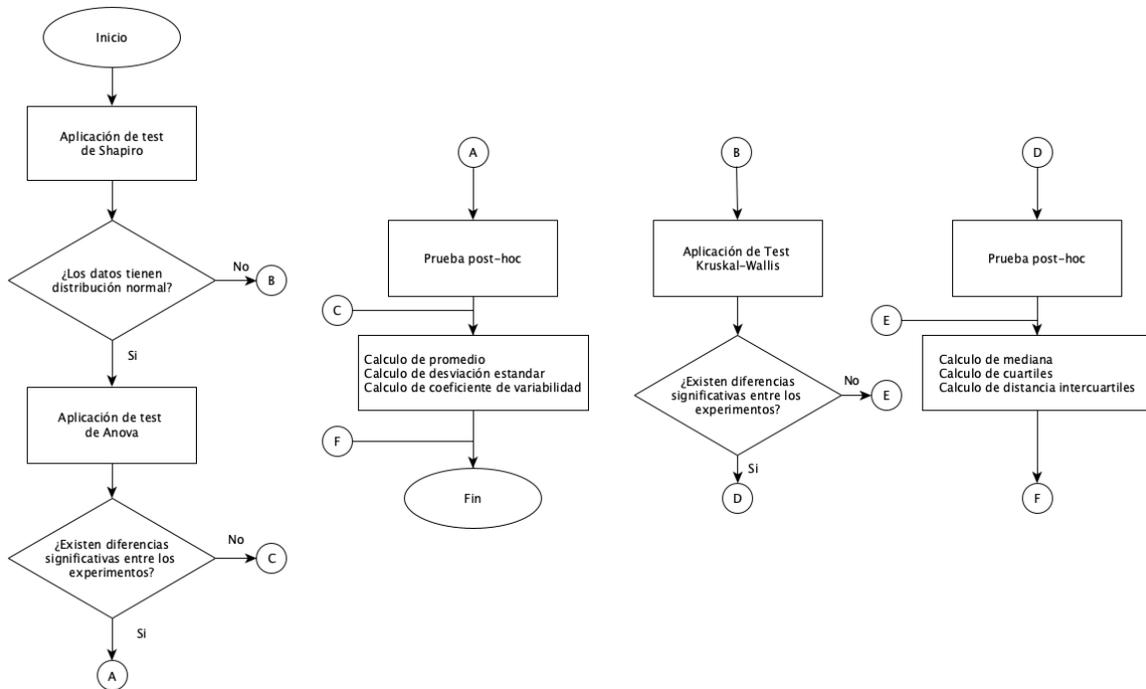


Figura 3.2 Esquema estadístico propuesto (Elaboración propia)

El comportamiento de los algoritmos evolutivos implementados es obtenido mediante los tests estadísticos mostrados en la Figura 3.2 a partir de los resultados obtenidos de una serie de 40 ejecuciones, determinadas en términos del teorema de límite central (Voget, 1996) realizadas sobre cada uno de los experimentos que se describen en la sección 3.2 de este documento . Este tratamiento a los resultados es soportado por el teorema de muestreo estadístico. Los estadísticos descriptivos que se emplean son la media, la desviación estándar y el coeficiente de variabilidad (desviación estándar entre la media), esta es una medida normalizada del porcentaje de datos que se separan de la media.

El test de Shapiro es una prueba estadística, se usa para determinar si los resultados de las ejecuciones siguen una distribución de probabilidad Gaussiana o Normal con una media μ y una varianza σ . Cuando una serie de datos presenta una distribución normal se asume que provienen de un proceso estocástico (Miller & Freund, 1963).

Cuando se comprueba que los resultados después de múltiples ejecuciones de un algoritmo tienen una distribución normal, se realiza un análisis de Anova, es decir un análisis de las

varianzas, el cual tiene como finalidad describir si existen diferencias estadísticamente significativas entre los experimentos que se desarrollan en esta sección (Goos & Meintrup, 2016). Es decir, mediante esta técnica estadística es posible determinar si existen diferencias significativas entre el Algoritmo Genético Canónico y el desarrollado en este trabajo.

Cuando se han determinado que los datos presentan diferencias estadísticamente significativas se aplica un test de Tukey, el cual es una prueba post ad-hoc del análisis de varianza (Levine, 2012). Este se usa para determinar los grupos a los que pertenecen una serie de datos estadísticos. En este trabajo se usa para poder determinar la pertenencia de los datos a un cierto segmento estadístico.

Si el test de Shapiro confirma que la distribución de probabilidad es diferente a la de una campana de Gauss, es decir, presenta un comportamiento determinístico, los datos pueden estudiarse con el test de Kruskal-Wallis (Ott & Longnecker, 2010), mientras que el test de Wilcoxon permite comparar y determinar los grupos de datos de una distribución diferente a la curva de Gauss.

3.2.- Datos a utilizar

El conjunto de datos para entrenamiento y validación se tomaron del trabajo presentado en (Leyva, 2018), estos fueron obtenidos de manera practica en la Corporación Mexicana de Investigación en Materiales (COMMINSA). El material de las piezas de trabajo que se empleó fue acero de alta resistencia, el proceso de maquinado fue realizado por medio de una maquina EDM, de marca River, en la cual se sustituyó el agua desionizada por una solución electrolítica, esto permite establecer un proceso ECDM. En la Tabla 3.1 se muestra el conjunto de datos para la validación del modelo, mientras que en la Tabla 3.2 se muestran los datos usados en la etapa de entrenamiento.

Tabla 3.1. Datos de validación

Dato	Voltaje Vs(V)	Corriente Ip(A)	Frecuencia (kHz)	<i>MRR</i>	<i>DOC</i>
1	70	25	40	30.4399	1.2966
2	60	20	10	19.2061	1.59
3	50	25	15	11.4841	2.2908
4	50	22	30	10.4108	2.31
5	60	10	25	9.6031	2.4966
6	50	15	40	7.4829	2.6832
7	50	20	25	10.1085	2.3632
8	60	25	10	22.0871	1.43
9	70	10	25	11.0356	2.0966

Tabla 3.2. Datos de entrenamiento.

Dato	Voltaje Vs(V)	Corriente Ip(A)	Frecuencia (kHz)	<i>MRR</i>	<i>DOC</i>
1	70	10	40	11.7076	2.2433
2	70	20	40	27.2508	1.3634
3	70	20	10	28.3038	1.33
4	50	20	10	9.73115	2.3617
5	50	20	40	10.02815	2.27
6	70	10	10	13.8689	1.8984
7	60	15	25	17.5689	1.79
8	50	10	10	4.3124	3.8433
9	50	10	40	5.2226	3.4157
10	50	15	25	7.0915	3.03
11	70	15	25	21.0499	1.51
12	50	17	17	7.2949	3.29
13	70	13	10	19.3858	2.25
14	70	15	5	11.7111	2.15

3.3.- Topología del micro-algoritmo a usar

Para la construcción de micro algo genético se definieron los siguientes parámetros; como operador de cruce a usar en esta propuesta de investigación es el BLX-alpha, fue elegido por su simplicidad computacional, además de los efectos que tienen sobre el espacio de búsqueda, el cual se expande fuera de los límites de los cromosomas, al utilizar este tipo de operador se evita la pérdida de diversidad genética y la convergencia prematura, el funcionamiento de este se muestra de manera gráfica en la Figura 3.2 (Herrera, et al., 2002), (Herrera, et al., 2007), (Avalar, et al., 2019)

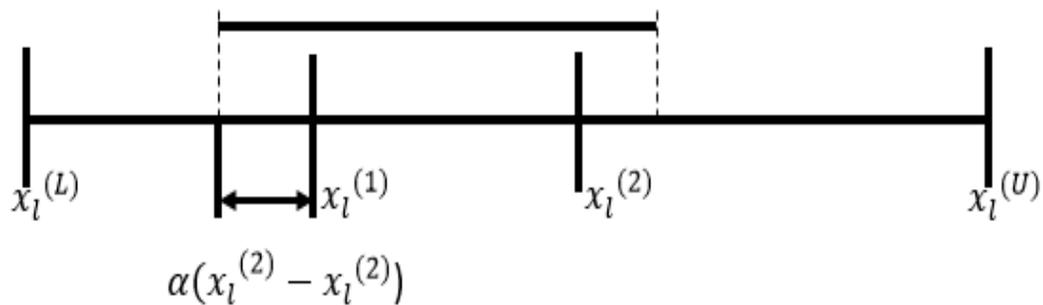


Figura 3.2 Respuesta de un cruce BLX-alpha (Herrera, et al., 2002)

El efecto de búsqueda ampliada en el espacio de soluciones se ejemplifica a través de la selección de 2 cromosomas progenitores: x_1, x_2 se generan dos cromosomas descendientes; y_1, y_2 , los genes de los cromosomas descendientes se cruzan a través del intervalo $x_{min} - I_\alpha, x_{max} + I_\alpha$, donde $x_{max} = \max[x_1, x_2], x_{min} = \min[x_1, x_2], I = x_{max} - x_{min}, \alpha \in [0.1]$, el valor de α , permite que algoritmo explore a profundidad en el espacio de búsqueda para encontrar la mejor solución, (Abido, 2009) (Cervantes, et al., 2014). Por otra parte, el operador de mutación elegido para el desarrollo de esta propuesta fue el operador gaussiano dado el impacto mínimo en los cambios que se generan en los genes, pero suficiente para evitar convergencias prematuras además de su simplicidad de implementación. El operador de selección fue la ruleta, dado que, para el caso del micro algoritmo es más simple de implementar, garantizando el carácter estocástico. Se propone una ejecución de 200 iteraciones las cuales, para el tipo de algoritmo, es suficiente para encontrar la convergencia.

El micro algoritmo genético por implementar, al ser una particularización de un algoritmo genético canónico usa los mismos operadores, la modificación importante se encuentra en el número de iteraciones del ciclo interno y externo.

3.4.- Propuesta del modelo difuso

Las funciones de membresía usadas comúnmente para la creación de un modelo de un proceso ECDM de acuerdo con la literatura y el trabajo de (Leyva, 2018) son las funciones triangulares debido a su simplicidad, las cuales se describen como $f(x; a, b, c) =$

$$\begin{cases} 0, & x < a \\ \frac{x-a}{b-a}, & a \leq x \leq b \\ 1, & b \leq x \leq c \\ \frac{b-x}{b-c}, & c \leq x \leq b \\ 0, & b < x \end{cases}, \text{ donde } x \text{ corresponde al universo del discurso, mientras que } a \wedge b \text{ son}$$

constantes, que determinan el comportamiento mostrado en la Figura 3.3

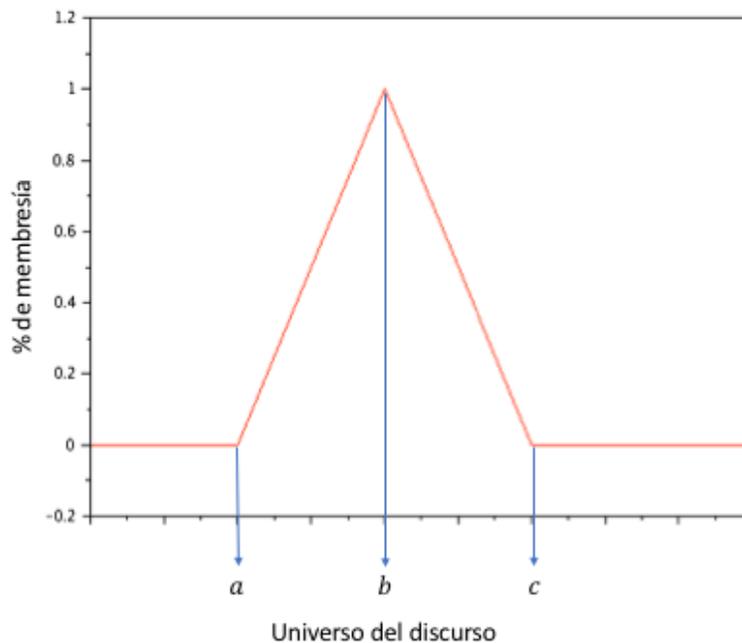


Figura 3.3 Función difusa triangular

El segmento de la ecuación $f(x; a, b, c) = 0 \forall x < a \wedge f(x; a, b, c) = 0 \forall b < x$ introduce una restricción en los algoritmos genéticos tal que, para las variables de entrada y/o salida no pueda tener valores de conjuntos difusos igual a 0. Esto aumentaría la dificultad de programación por esa razón en esta propuesta se usan funciones gaussianas especificadas matemáticamente como $f(x; \sigma, c) = e^{-\frac{(x-c)^2}{2\sigma^2}}$.

En la Figura 3.4 se puede observar el comportamiento matemático, en la constante c se encuentra el centro de la campana de Gauss y el valor σ determina el ancho de la campana tal forma que este es $\frac{1}{\sigma}$

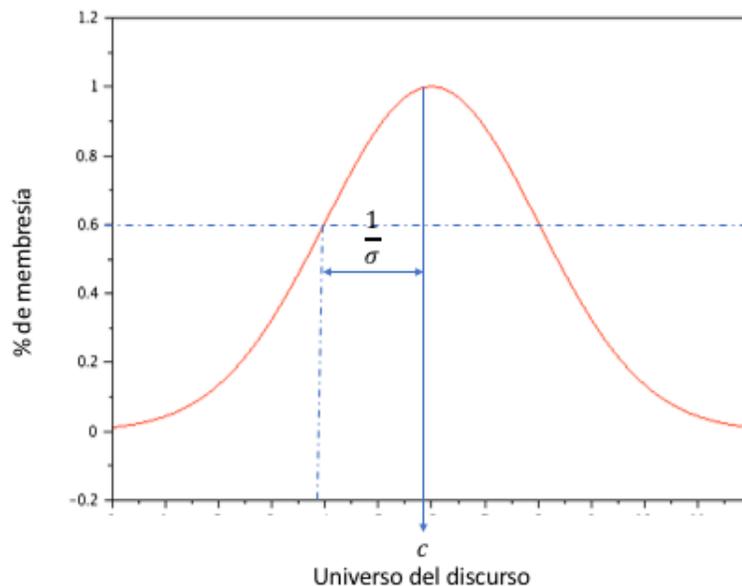


Figura 3.4 Función difusa Gaussiana

La Figura 3.5 muestra un sistema de inferencia difuso de tipo MISO, “Múltiples Entradas Una Salida” (*Multiple Inputs One Output*) el cual es del tipo Mamdani con 14 reglas ya simplificadas y es construido por medio del método *HYFIS*. Es importante mencionar que los conjuntos de entrada se encuentran normalizados, así como el de la salida, misma que es desnormalizada durante el proceso de defuzzificación. El defuzzificador empleado en esta propuesta fue el método de Centro de Gravedad (*COG*) y Método de Promedio Ponderado (*WAM*).

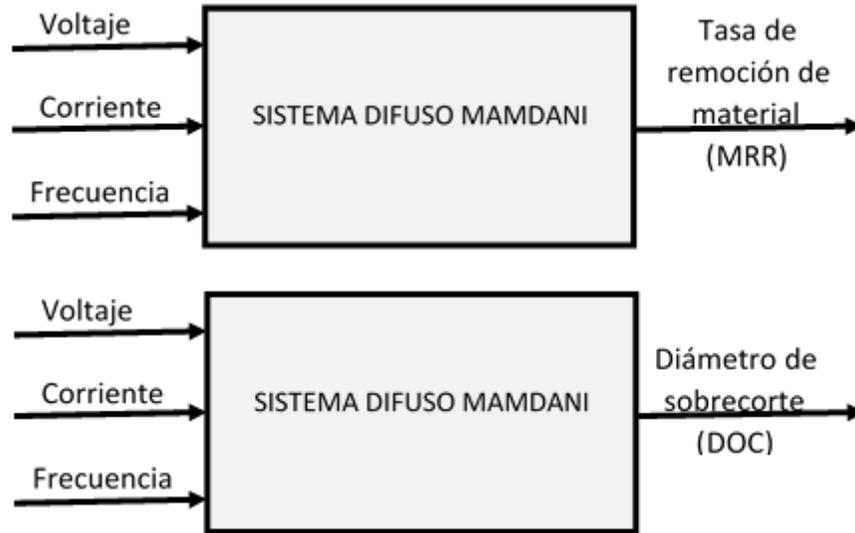


Figura 3.5 Sistema difuso MISO

Por lo tanto, el cromosoma a generar tendrá la forma $c = |g_1, g_2, g_3, \dots, g_{28}, g_{29}, g_{30}|^T$ donde g son los genes, que representan parámetros de los conjuntos difusos empleados. Los genes g_{2n+1} , que corresponden al valor medio de las medias de las funciones gaussianas se consideraran como constantes, mientras que los genes $c_{2n} = rand[0.1,0.3]$

Tabla 3.3 Conjuntos del Sistema difuso propuesto

Variable de Entrada	Conjuntos Difusos	Función de membresía
V (voltaje)	s pequeño	$\mu_{gausina}(V: c_1, c_2)$
	m mediano	$\mu_{gausina}(V: c_3, c_4)$
	l grande	$\mu_{gausina}(V: c_5, c_6)$
F (Frecuencia)	vs muy pequeño	$\mu_{gausina}(F: c_7, c_8)$
	s pequeño	$\mu_{gausina}(F: c_9, c_{10})$
	l grande	$\mu_{gausina}(F: c_{11}, c_{12})$
	vl muy grande	$\mu_{gausina}(F: c_{13}, c_{14})$
I (Corriente)	vs muy pequeño	$\mu_{gausina}(I: c_{15}, c_{16})$
	s pequeño	$\mu_{gausina}(I: c_{17}, c_{18})$
	m mediano	$\mu_{gausina}(I: c_{19}, c_{20})$
	vl muy grande	$\mu_{gausina}(I: c_{21}, c_{22})$
Variable de Salida	Conjuntos Difusos	Función de membresía

<p style="text-align: center;"><i>MRR</i> (Tasa de Remoción de Material)</p>	vs muy pequeño	$\mu_{gausina}(MRR: c_{23}, c_{24})$
	s pequeño	$\mu_{gausina}(MRR: c_{25}, c_{26})$
	m mediano	$\mu_{gausina}(MRR: c_{27}, c_{28})$
	l grande	$\mu_{gausina}(MRR: c_{29}, c_{30})$
<p style="text-align: center;"><i>DOC</i> (Diámetro de Sobrecorte)</p>	vs muy pequeño	$\mu_{gausina}(DOC: c_{23}, c_{24})$
	s pequeño	$\mu_{gausina}(DOC: c_{25}, c_{26})$
	m mediano	$\mu_{gausina}(DOC: c_{27}, c_{28})$
	l grande	$\mu_{gausina}(DOC: c_{29}, c_{30})$

3.5.- Experimentos

A partir de las consideraciones generadas en este apartado de metodología es posible generar los experimentos propuestos en las tablas 3.4 y 3.5 para este proceso investigativo, los cuales tienen como finalidad determinar cuáles son los parámetros que permiten encontrar la mejor reducción del parámetro *MAPE*.

Tabla 3.4 Diseño de experimentos propuestos para la sintonización del MAPE con un GA

No. De test	Operado de selección	Operado de cruce	valores α	Operador de mutación	Defuzzificador
1	Ruleta	BLX- <i>alpha</i>	0.1	Mutación gaussiana	Centro de área de gravedad (COG)
2			0.2		
3			0.3		
4			0.4		
5			0.5		
6			0.6		
7			0.7		
8			0.8		
9			0.9		
10			random [0,1]		

Tabla 3.5 Experimentos propuestos para la sintonización del MAPE con un uGA

No. De test	Operador de selección	Operado de cruce	valores α	Operador de mutación	Defuzzificador
1	Ruleta	BLX- <i>alpha</i>	0.1	Mutación gaussiana	Método de Promedio Ponderado (WAM)
2			0.2		
3			0.3		
4			0.4		
5			0.5		
6			0.6		
7			0.7		
8			0.8		
9			0.9		
10			random [0,1]		

Capítulo 4 RESULTADOS Y DISCUSIONES

En esta sección de la presente propuesta se muestran los resultados de los experimentos mostrados en el apartado de metodología los cuales permiten la construcción de un modelo difuso del proceso ECDM, en primer término, se muestra el modelo difuso de proceso MRR, obtenido por medio de un algoritmo genético canónico. Este ha sido desarrollado en conjunto con los Doctores Juan Fernando García Mejía, Everardo Efrén Granda Gutiérrez, Carlos Eduardo Torres Reyes y la Doctora Pamela Chiñas Sánchez y será publicado en el volumen 14 numero 3 de la revista Programación matemática y software, editada por la Universidad Autónoma del Estado de Morelos, posteriormente se muestran los resultados del proceso de modelado del *DOC* con ambas estrategias de optimización propuestas en este trabajo de investigación: El algoritmo *AG* y el *uAG*

4.1 Modelado del MRR con lógica difusa y un algoritmo genético canónico.

Al ser un artículo en proceso de publicación solo se muestran los resultados que se consideran pertinentes con fines comparativos con el micro algoritmo genético. La configuración del algoritmo genético canónico que tiene los mejores resultados en MAPE y en la comprobación estadística es el que muestra mayor estabilidad, este es mostrado en la Tabla 4.1

Tabla 4.1 *Mejor experimento para ajuste de MRR*

No. De test	Operado de cruce	valores α	Operador de mutación	Defuzzificador
10	BLX-alpha	random [0,1]	uniforme	COG

La Tabla 4.2 muestra la representación de los conjuntos difusos que forman el modelo obtenido por la topología del algoritmo mostrado en la Tabla 4.1

Tabla 4.2 Cromosoma resultante para ajuste de MRR

c1=3.978390e-07	c9=0.25	c17=0.25	c25= 0.2478422
c2=0.1557306	c10=0.13419777	c18=0.55297490	c26=0.3692076
c3=0.5	c11=0.75	c19=0.5	c27=0.80543396
c4=0.1016734	c12=0.26868394	c20=0.03839904	c28=0.02594472
c5=1	c13=1	c21=1	c29= 0.947786
c6=0.2243793	c14=0.31511896	c22=0.32757467	c30=0.087500
c7=7.065481e-12	c15=7.065481e-12	c23=0	
c8=0.16325164	c16=0.05257506	c24= 0.1935294	

La Figura 4.1 muestra la convergencia obtenida por el algoritmo de esta configuración, consiguiéndose la convergencia en cerca de 80 iteraciones, mientras que las Figuras 4.2, 4.3, 4.4 y 4.5 muestran los conjuntos difusos de las variables voltaje, frecuencia, corriente y MRR

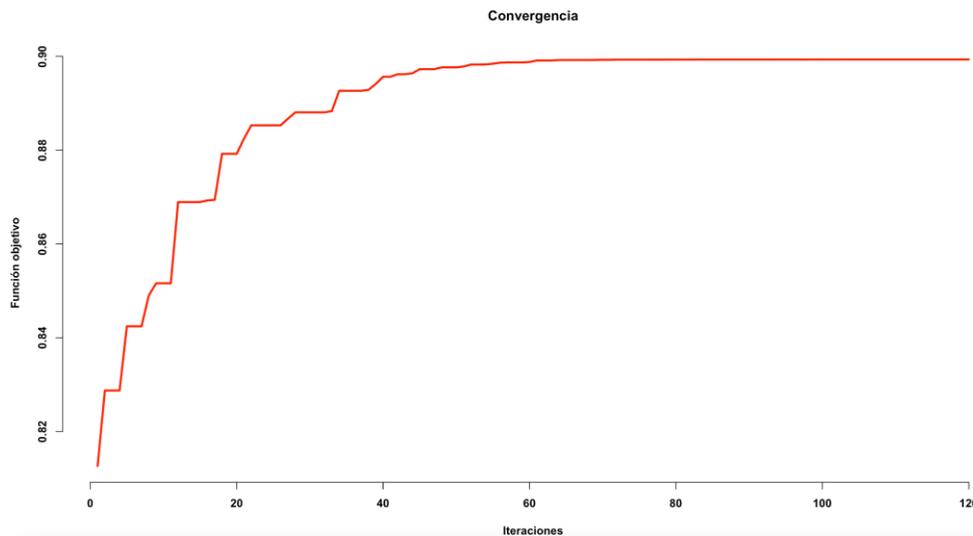


Figura 4.1 Convergencia del Algoritmo genético canónico para MRR.

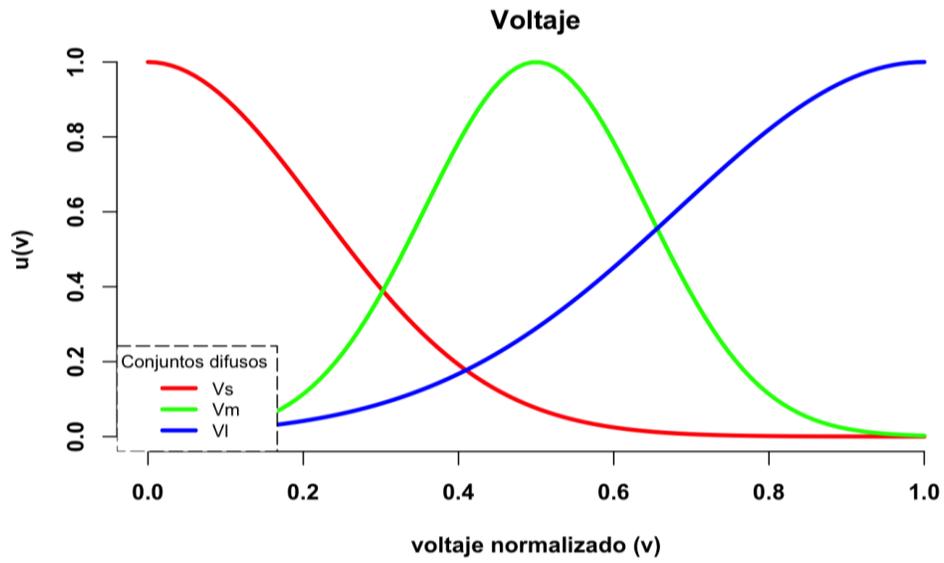


Figura 4.2 Conjuntos difusos para la variable voltaje

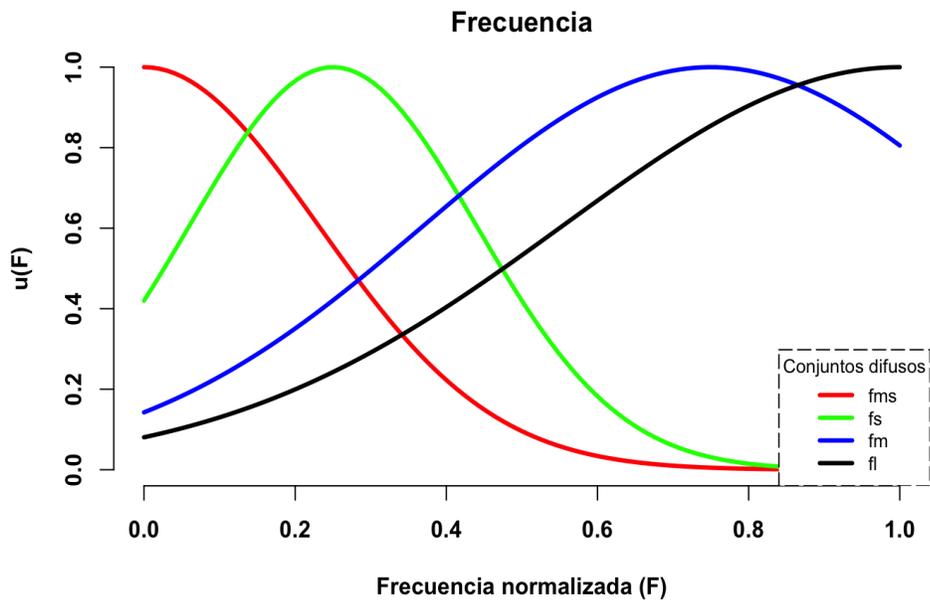


Figura 4.3 Conjuntos difusos de variable frecuencia

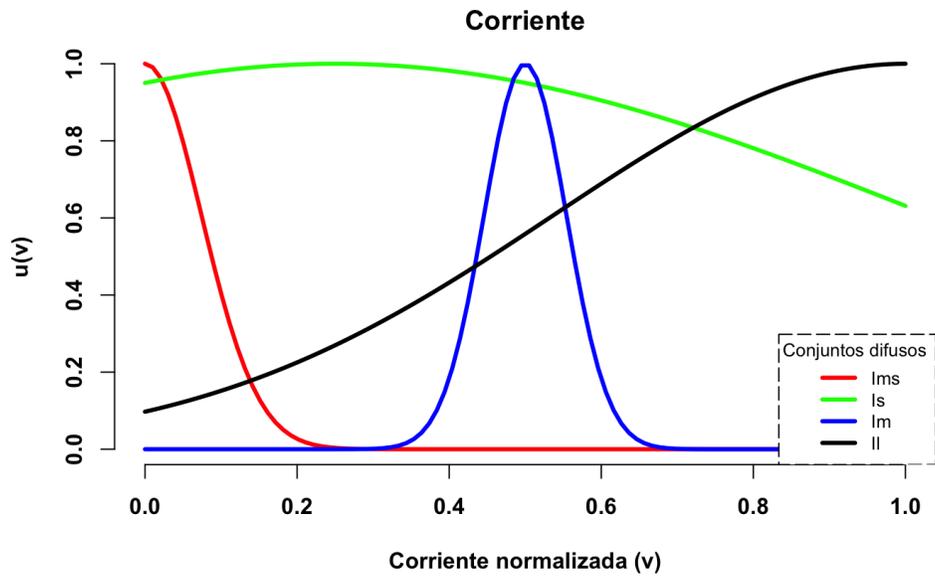


Figura 4.4 Conjuntos difusos de variable corriente

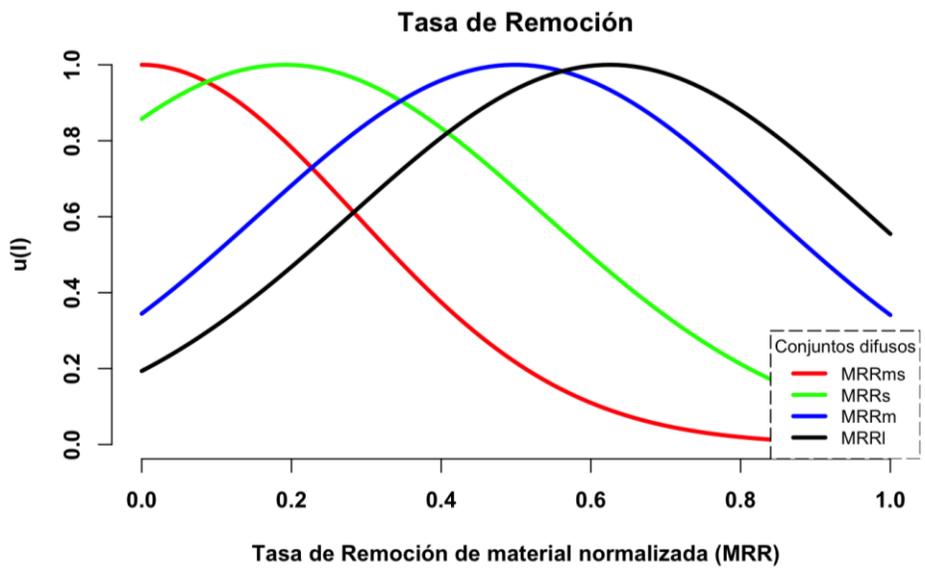


Figura 4.5 Conjuntos difusos de variable MRR

4.2. Modelado del *MRR* con lógica difusa y un micro algoritmo genético canónico

Para el cálculo de *MRR* cada uno de los test descritos en la tabla 3.5 se ejecutan 40 ecuaciones, usando los datos de entrenamiento mostrados en la tabla 3.2, esto con la finalidad de realizar un estudio estadístico que tiene como finalidad modelar el comportamiento del algoritmo y determinar los mejores parámetros del algoritmo genético que garantice el menor valor de MAPE. La Tabla 4.3 muestra los valores del test de normalidad aplicado, marcando con (*) los valores que cumplan la hipótesis de normalidad

Tabla 4.3 Tests de Normalidad

No. De test	Valores de significancia p
Test1	0.543937672198351
Test2	0.422789318385899
Test3	0.298741762692829
Test4	0.631321589149563
Test5	0.264189259791285
Test6	0.486258561125711
Test7	0.102070480374312
Test8	0.276599878413082
Test9	0.729555649796981
Test10	0.211033609707515

Como se muestra en la Tabla 4.3 todos los experimentos presentan normalidad, por lo tanto, para determinar si existen diferencias significativas entre los experimentos se propone un análisis de ANOVA cuyo valor de significancia es 0.000231, por lo tanto, se asume que los datos al menos difieren en un par por lo tanto se propone el uso del test de Tuckey para determinar las diferencias significativas desde el punto de vista estadístico. Los resultados se

muestran en la Tabla 4.4, marcando en color verde los experimentos que son estadísticamente diferentes entre sí, siendo los que tienen el valor de significancia menor a 0.05

Tabla 4.4 Tests de Normalidad

	Test1	Test10	Test2	Test3	Test4	Test5	Test6	Test7	Test8
Test10	1								
Test2	1	1							
Test3	1	1	1						
Test4	1	1	1	1					
Test5	0.002028	0.073830	0.0115748	0.0537060	0.1315454				
Test6	1	1	1	1	1	0.72371			
Test7	1	1	1	1	1	0.0343	1		
Test8	1	1	1	1	1	0.0027212	1	1	
Test9	1	1	1	1	1	2.950900E-05	0.24988	1	1

De la Tabla 4.4 se desprende que el test 5 es diferente con el 1, 2,7,8,9, por lo tanto, dado que la distribución de datos es normal los estadísticos que describen el comportamiento del algoritmo se muestra en la tabla 4.5.

Tabla 4.5 Estadísticos MRRR micro genético

	Media	Desviación estandar	Coefficiente de variación
Test1	0.1275943	0.01513232	11.85%
Test 2	0.1219435	0.01012566	8.3035%
Test 7	0.117896	0.01153266	9.78%
Test 8	0.124593	0.0145789	11.70%
Test 9	0.121902	0.0112893	9.26%
Test 5	0.1023568	0.0101230	9.88%

Se observa que el menor valor de media del modelo es el Test 5 por lo tanto el cromosoma se muestra en la Tabla 4.6

Tabla 4.6 Cromosoma resultante para ajuste de MRR con micro GA

c1=3.978390e-07	c9=0.25	c17=0.25	c25= 0.2478422
c2=0.1915228	c10=0.12207902	c18=0.2118368	c26=0.17235252
c3=0.5	c11=0.75	c19=0.5	c27=0.80543396
c4=0.1462861	c12=0.20019728	c20=0.18815223	c28=0.19935984
c5=1	c13=1	c21=1	c29= 0.947786
c6=0.20571172	c14=0.22741873	c22=0.26244339	c30=0.20520212
c7=7.065481e-12	c15=7.065481e-12	c23=0	
c8=0.15977834	c16=0.20215652	c24= 0.20210745	

La Figura 4.6 muestra la convergencia de esta configuración, consiguiéndose la convergencia en cerca de 80 iteraciones, mientras que las figuras 4.7,4.8,4.9,4.10 muestran los conjuntos difusos de las variables voltaje, frecuencia, corriente y MRR

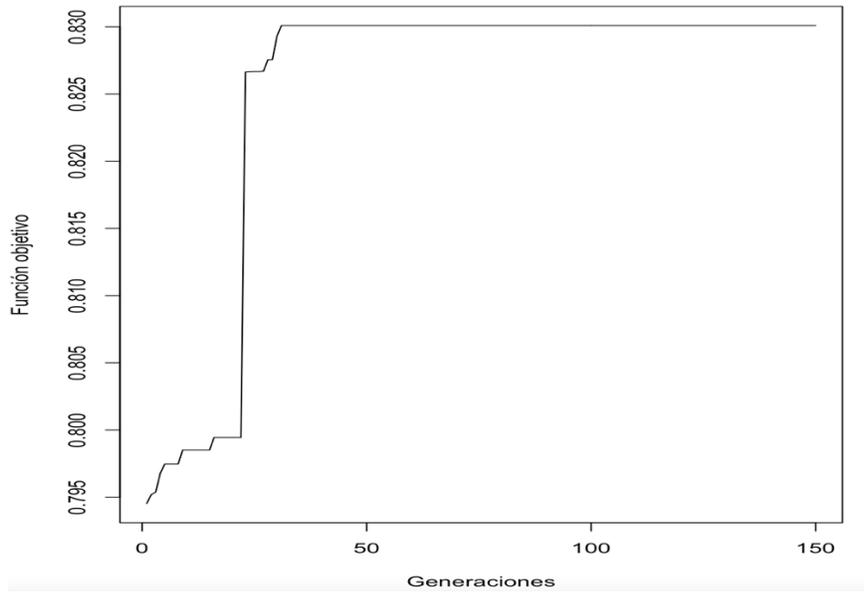


Figura 4.6 Gráfica de convergencia para MRR

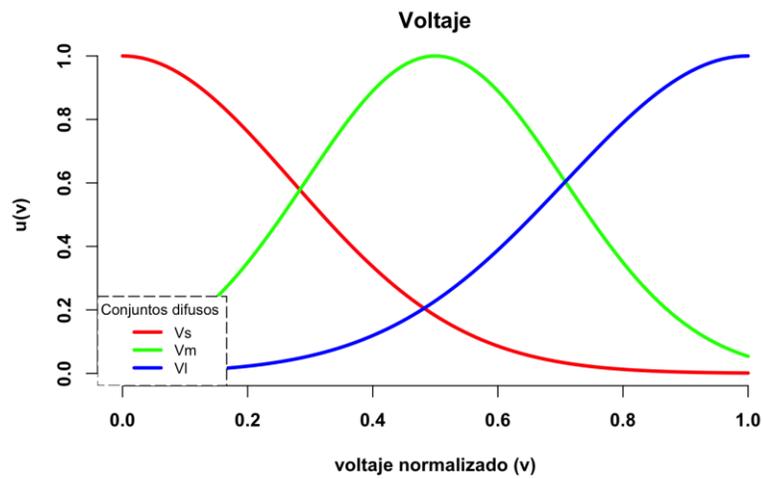


Figura 4.7 Conjuntos difusos de voltaje MRR

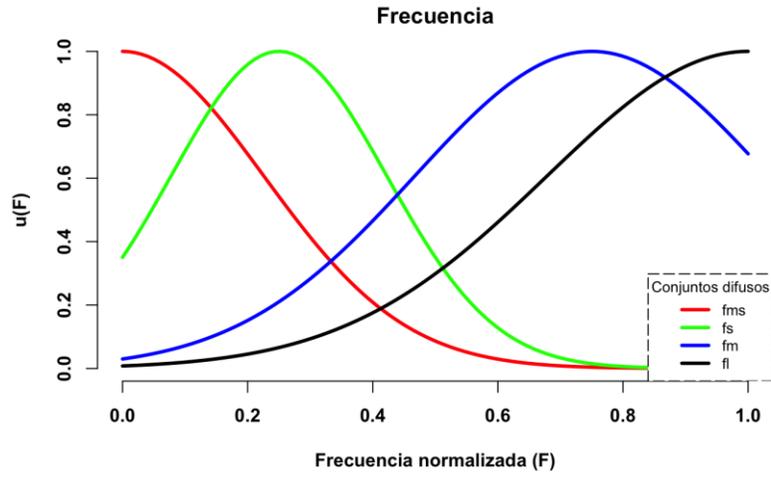


Figura 4.8 Conjuntos difusos de frecuencia MRR

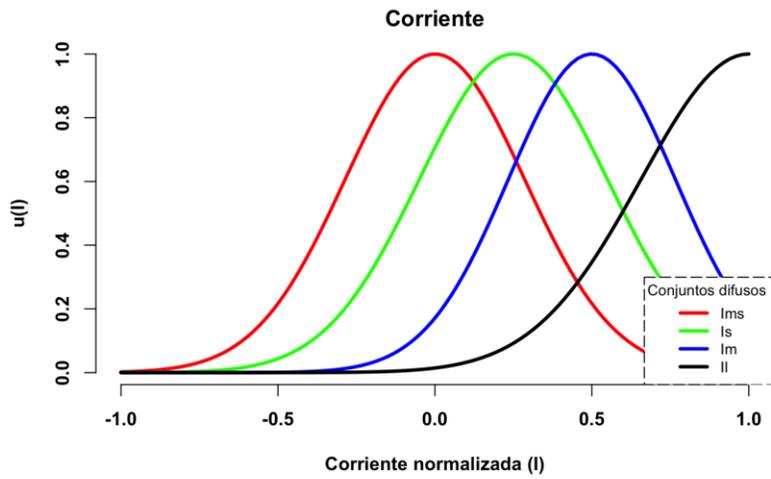


Figura 4.9 Conjuntos difusos de corriente MRR

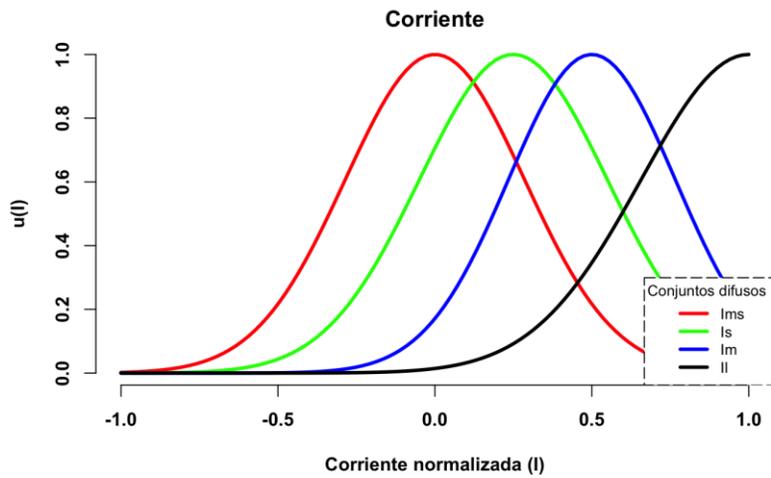


Figura 4.10 Conjuntos difusos de voltaje MRR

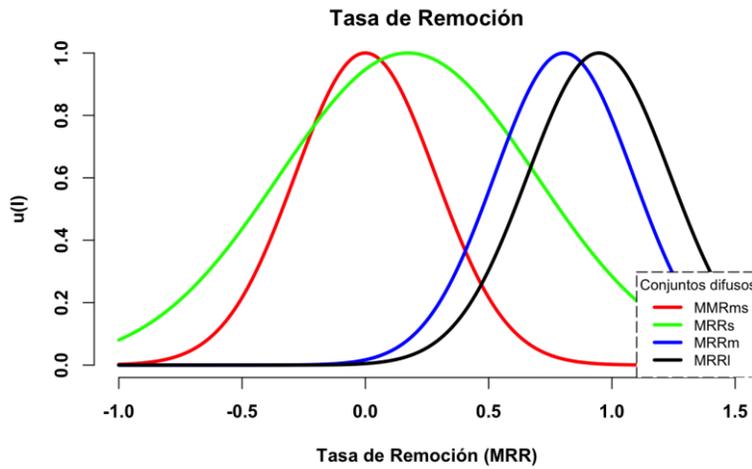


Figura 4.11 Conjuntos difusos de Tasa de Remoción de Material MRR

4.3. Modelado del *DOC* con lógica difusa y un algoritmo genético canónico

Para el cálculo del diámetro de sobrecorte (*DOC*), cada uno de los test descritos en la tabla 3.5 se ejecutan 40 veces, usando los datos de entrenamiento mostrados en la tabla 3.2, esto con la finalidad de realizar un estudio estadístico que tiene como finalidad modelar el comportamiento del algoritmo y determinar los mejores parámetros del algoritmo genético que garantice el menor valor de *MAPE*. La Tabla 4.7 muestra los valores del test de normalidad aplicado, marcando con (*) los valores que cumplan la hipótesis de normalidad

Tabla 4.7 Test de Normalidad

No. De test	Valores de significancia p
Test1	0.543397433523168(*)
Test2	0.927753249066925(*)
Test3	0.490473693264659(*)
Test4	0.182359657307212(*)

Test5	0.698864692931189(*)
Test6	0.229917148603235(*)
Test7	0.00120878101959705
Test8	0.17768927268187(*)
Test9	0.0470919315435772
Test10	0.018187945118569

Como se observa en la Tabla 4.8 la tesis de normalidad no se cumple para los Test 7,9 y 10. Para determinar si existen diferencias entre estos se aplica la prueba de Kruskal-Wallis la cual tiene un valor de significancia $p = 0.292$, por lo tanto no tiene diferencias estadísticamente significativas entre sí. Dado las no diferencias se puede usar el experimento 10, dado que suele ser el usado en la literatura especializada y los estadísticos aplicados son determinados por la distribución de datos y son mostrados en la Tabla 4.4.

Tabla 4.8 Estadísticos del Test 10

Tests	medianas	cuartil1	cuartil3	Distancia Intercuartil
Test10	0.0799497112644727	0.0774716581899971	0.0833401586484235	0.00586850045842637

Como se observa la tesis de normalidad se cumple para los Test 1,2,3,4,5,6,8, por lo tanto, para determinar si existen diferencias entre los demás test se aplica la prueba de ANOVA la cual tiene un valor de significancia $p = 0.139$, por lo tanto, es posible asumir que no existen diferencias estadísticamente significativas, dado esto se plantea usar el experimento descrito en el Test 5 los estadísticos aplicados son determinados por la distribución de datos y son mostrados en la Tabla 4.9

Tabla 4.9 Estadísticos del Test 5

Tests	Promedio	Desviación Estándar	Coefficiente de Variabilidad

Test	0.08643	0.006921284	8.007965
5			

Dado el resultado de las Tablas 4.8 y 4.9 es posible determinar que el modelo se obtiene por medio del experimento 10 el cual genera el cromosoma que se muestra en la Tabla 4.10, así como la convergencia del algoritmo visualizada en la Figura 4.12

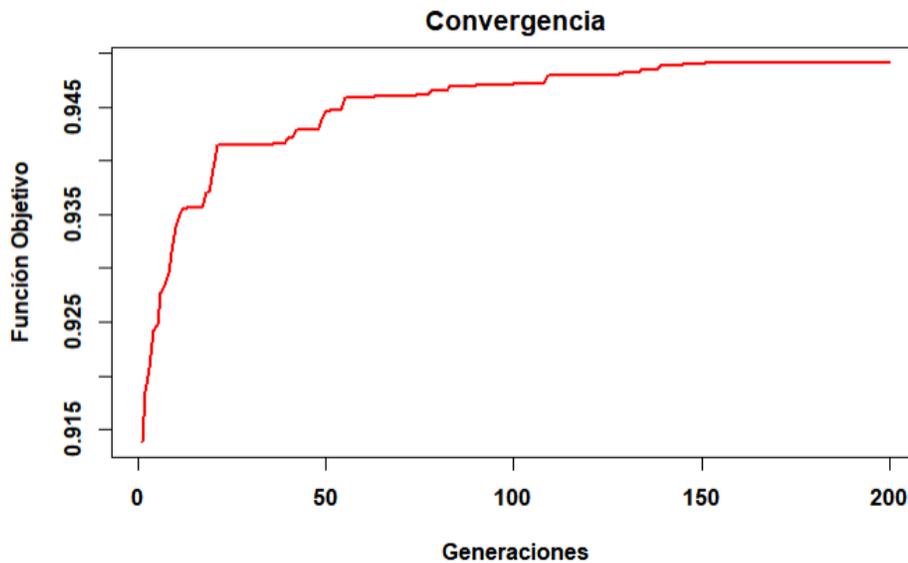


Figura 4.12 Convergencia del micro-algoritmo para DOC

Tabla 4.10 Cromosoma resultante para ajuste de DOC

c1= 8.866944e-07	c9=0.25	c17=0.25	c25=0.1915620
c2= 0.175638769	c10= 0.125088679	c18= 0.203348669	c26=0.24429422
c3=0.5	c11=0.75	c19=0.5	c27=0.49880750
c4= 0.137251306	c12= 0.184766622	c20= 0.216988957	c28=0.24164481
c5=1	c13=1	c21=1	c29= 0.62531715
c6= 0.184809154	c14= 0.178377085	c22=0.32757467	c30=0.24402344
c7= 5.509133e-12	c15= 8.22736E-09	c23=0	

c8= 0.254588847	c16= 0.191617409	c24= 0.208853317	
-----------------	------------------	------------------	--

Las Figuras 4.13, 4.14, 4.15 y 4.16 muestran los conjuntos difusos de las variables; voltaje, frecuencia, corriente y diámetro de sobrecorte obtenidos por el micro-algoritmo genético.

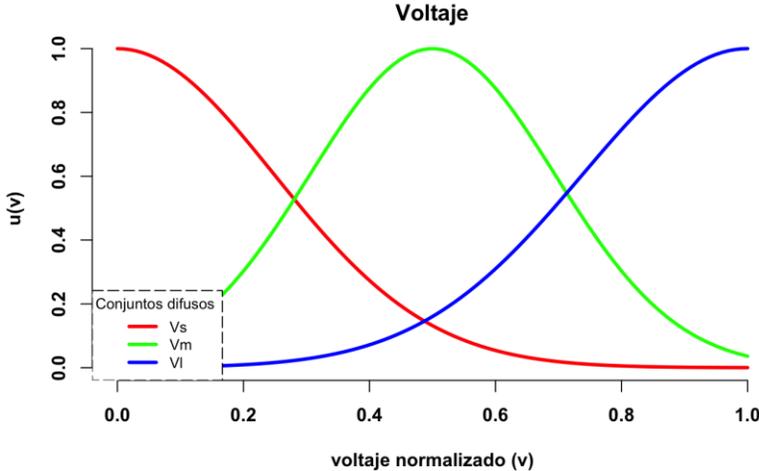


Figura 4.13 Conjuntos difusos de variable voltaje

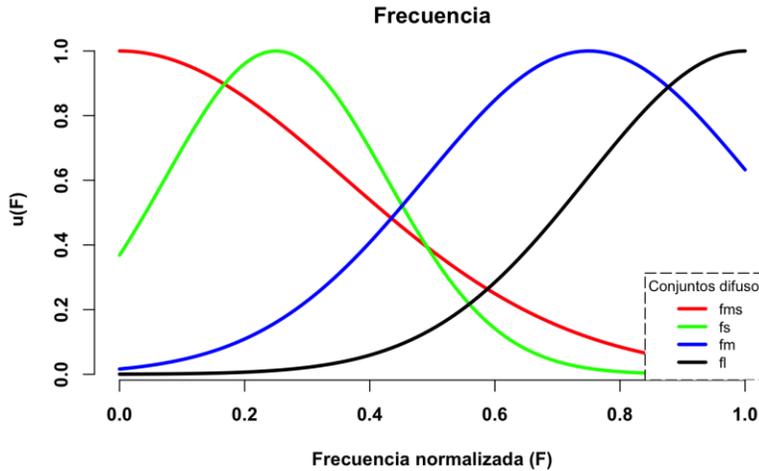


Figura 4.14 Conjuntos difusos de variable frecuencia

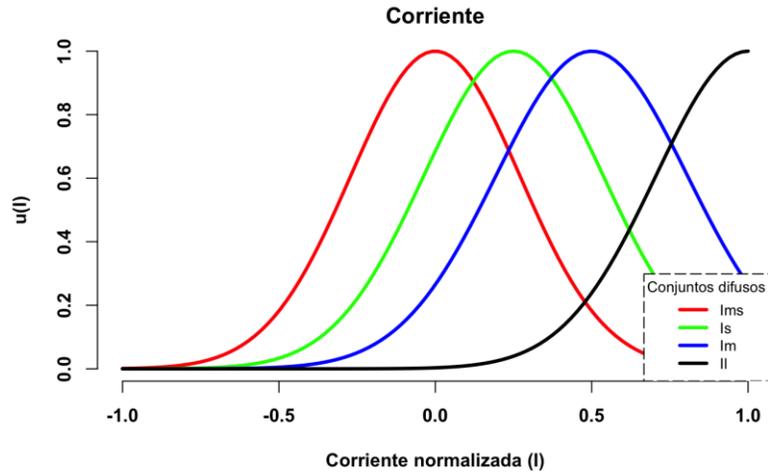


Figura 4.15 Conjuntos difusos de variable corriente

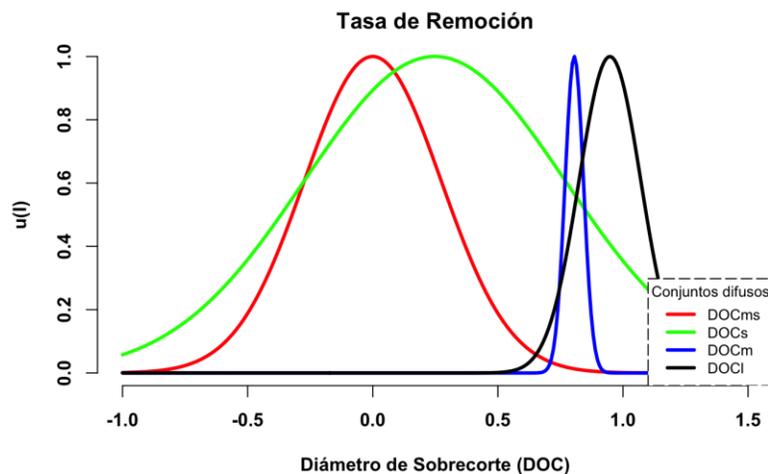


Figura 4.16 Conjuntos difusos de variable Diámetro de Sobrecorte (DOC).

4.4. Modelado del *DOC* con lógica difusa y un micro genético.

Cada uno de los test descritos en la tabla 3.5 se ejecutan 40 veces, usando los datos de entrenamiento mostrados en la tabla 3.2, esto con la finalidad de realizar un estudio estadístico que tiene como finalidad modelar el comportamiento del algoritmo y determinar los mejores parámetros del algoritmo genético que garantice el menor valor de MAPE. La Tabla 4.11 muestra los valores del test de normalidad aplicado, marcando con (*) los valores que cumplan la hipótesis de normalidad

Tabla 4. 11 Tests de normalidad

No. De test	Valores de significancia p
Test 1	0.00129304
Test 2	0.09545855*
Test 3	0.64701847*
Test 4	0.00315287
Test 5	0.0015586
Test 6	0.47925074*
Test 7	0.83017817*
Test 8	0.40948024*
Test 9	0.01410454
Test 10	0.25189546*

Como se observa la tesis de normalidad se cumple para los Test 2,3,6,7,8 y 10. Para determinar si existen diferencias entre los demás test se aplica la prueba de Kruskal-Wallis la cual tiene un valor de significancia $p = 1.361e - 12$, por lo tanto, es posible asumir que al menos una pareja de test son diferentes entre sí, para poder determinar cuáles son los experimentos que difieren entre si se aplica una prueba post-hoc, en este caso la prueba de Wilcoxon, cuyo resultado se muestra en la Tabla 4.12, marcando en rojo las parejas que son estadísticamente iguales

Tabla 4.12 Test de Wilcoxon

	Test1	Test4	Test5
Test4	0.122027662248956	NA	NA
Test5	0.26386548052309	0.000896512876515532	NA
Test9	2.192430719342E-07	6.60552397697202E-06	3.914280399966E-16

Los estadísticos aplicados a los Test 1,4,5,9 son determinados por la distribución de datos y son mostrados en la Tabla 4.13, colocando en verde aquellos que tienen el valor menor de medianas y distancias intercuartil del MAPE.

Tabla 4.13 Estadísticos tests

Tests	medianas	cuartil1	cuartil3	Distancia Intercuartil
Test1	0.0845288980223038	0.078503877787946	0.0916562414043629	0.0131523636164169
Test4	0.0814014885585922	0.0764110075288659	0.084238379261773	0.00782737173290719
Test5	0.0851063630382755	0.0816787283423278	0.0905551522763258	0.00887642393399796
Test9	0.0754392976198955	0.0711980964115717	0.0779549130538929	0.0067568166423212

Como se observa la tesis de normalidad solo se cumple para los Test 2,3,6,7,8 y 10, por lo tanto, para determinar si existen diferencias entre los demás test se aplica la prueba de ANOVA la cual tiene un valor de significancia $p = 2.2e - 16$, por lo tanto es posible asumir que al menos una pareja de tests son diferentes entre sí, para poder determinar cuáles son los experimentos que difieren entre si se aplica una prueba post-hoc, en este caso el test de Tuckey, cuyo resultado se muestra en la Tabla 4.14, marcando en rojo las parejas que son estadísticamente iguales

Tabla 4.14 Resultados del test de Tuckey

	Test10	Test2	Test3	Test6	Test7
Test2	3.750033414E-100	NA	NA	NA	NA
Test3	1.0032492134E-98	0.5447627374341	NA	NA	NA
Test6	4.2159088285E-96	0.0898742744541	0.273942201380356	NA	NA
Test7	1.45042096E-97	0.27495318816312	0.6261642324713	0.5432305772137	NA
Test8	4.13602567E-99	0.6576779559184	0.8707977076529	0.2091309783132	0.51594227238

Los estadísticos aplicados a los Test 2,3,6,7,8 y 10 son determinados por la distribución de datos y son mostrados en la tabla, colocando en verde aquellos que tienen el valor menor de media y de coeficiente de variabilidad

Tabla 4.15 Estadísticos del test

Test	Promedio	Desviación Estándar	Coficiente de Variabilidad
Test 2	0.07529	0.005299272	7.038562
Test 3	0.07783	0.005531828	7.107338
Test 6	0.08243	0.004886367	5.927798
Test 7	0.07988	0.005416172	6.780539
Test 8	0.07715	0.00455391	5.902686
Test10	0.2312	0.04447217	19.23818

Dado el resultado de las Tabla 4.14 y 4.15 es posible determinar que el modelo se obtiene por medio del experimento 2, dado que tiene el valor más menor de Promedio de MAPE en comparación con los demás experimentos el cual genera el cromosoma que se muestra en la Tabla 4.16

Tabla 4.16 Cromosoma resultante para ajuste de DOC con micro algoritmo genético

c1= 8.866944e-07	c9=0.25	c17=0.25	c25=0.1915620
c2= 0.18331259	c10= 0.12405018	c18=0.20189876	c26=0.2292291
c3=0.5	c11=0.75	c19=0.5	c27=0.17265432
c4= 0.13852447	c12= 0.17640717	c20= 0.21555084	c28=0.24164481
c5=1	c13=1	c21=1	c29= 0.62531715
c6= 0.20695052	c14= 0.18176981	c22=0.24283464	c30=0.18548702
c7= 5.509133e-12	c15= 8.22736E-09	c23=0	
c8= 0.19669035	c16= 0.20290785	c24=0.20134249	

Como resultado de la Tabla 4.16 el cromosoma resultante de cada uno de los conjuntos de las variables voltaje, frecuencia, corriente y diámetro puede visualizarse en las Figuras 4.17,4.18,4.19 y 4.20 respectivamente.

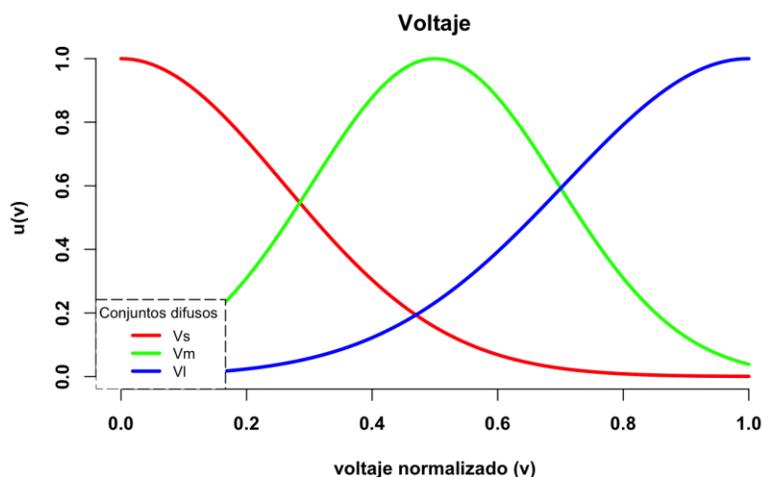


Figura 4.17 Conjuntos difusos de variable voltaje

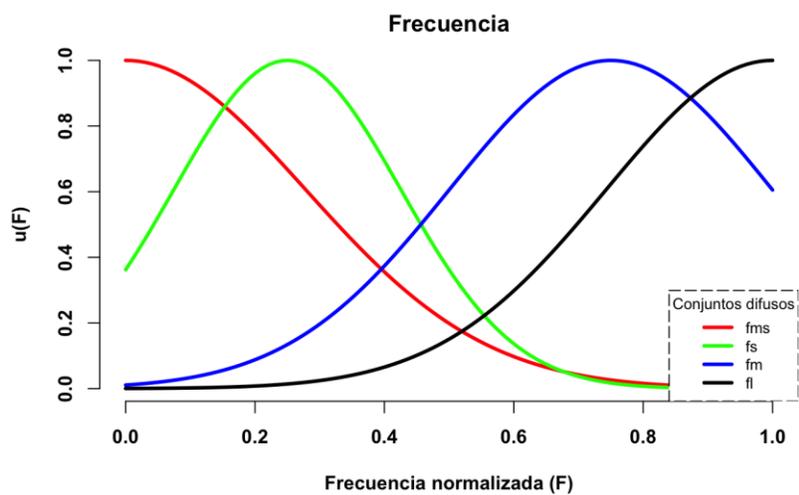


Figura 4.18 Conjuntos difusos de variable frecuencia

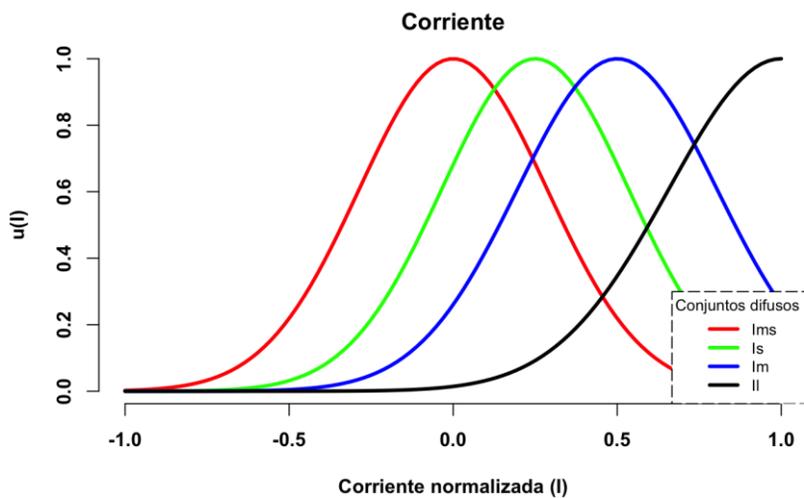


Figura 4.19 Conjuntos difusos de variable corriente

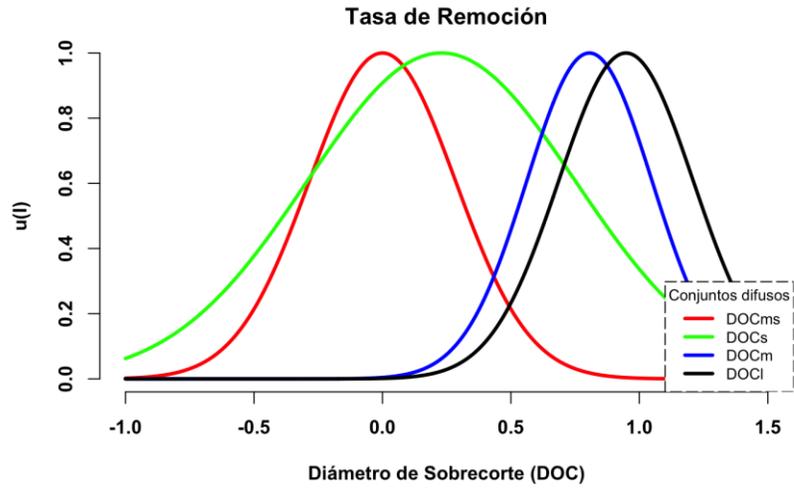


Figura 4.20 Conjuntos difusos de variable Diámetro de Sobrecorte (DOC)

CONCLUSIONES

La construcción de modelos computacionales son un área de oportunidad para implementar técnicas *Soft Computing*, la sinergia de estas técnicas, permiten crear modelos de procesos no convencionales, empleado lógica difusa es posible transformar el conocimiento el conocimiento de un expertise para la creación de un modelo difuso, a su vez el conjunto de datos es transformado para generar conocimiento implementando algoritmo como *HIFYS*.

Como se puede observar en la investigación los objetivos planteados han sido completados, se construyeron los modelos computacionales de caja negra para el proceso de Maquinado Electroquímico por Descarga Eléctrica, para los parámetros de Tasa de Remoción de Material (MRR) y Diámetro de Sobrecorte (DOC), en el proceso de construcción se realizaron la elección de los parámetros parara los algoritmos de los modelos, basándose en la revisión de la literatura. Se optimizaron los conjuntos difusos con la implementación de un micro algoritmo genético, así como la evaluación del modelo con estadística inferencia.

Derivado delo anterior se concluye, que la hipótesis planteada en la presente investigación se ha cumplido ya que los modelos para los parámetros MRR y DOC ha superado el 90% que se planteó inicialmente, a través del desarrollo de la presente investigación, los resultados obtenidos se muestran en las Tablas4.17 y 4.18.Se ha observado que la combinación de técnicas de *Soft Computing* permite crear modelos robustos y fiables capaces de predecir resultados de manera óptima minimizando el error, además de la sintonización automática de los conjuntos difusos a través de la implementación de un algoritmo genético en su versión canónica y un micro algoritmo genético, finalmente, el análisis estadístico realizado permite evaluar el modelo, esto deja el camino para que en futuras investigaciones el análisis estadístico sea parte esencial para la evaluación de los modelos.

Tabla 4.17 Resultados MAPE para la Tasa de Remoción de Material (MRR)

	Modelo con conjuntos ajustados empíricamente	Modelo con conjuntos ajustados por sistema neurodifuso y algoritmos genéticos	Modelo con conjuntos ajustados por sistema neurodifuso y micro algoritmo genético
MAPE	10.74 %	8.05%	7.06%
Número de reglas	27	14	14
Número de conjuntos difusos	14	15	15
Tipos de conjuntos	Triangulares y trapezoidales	Gaussianos	Gaussianos

Tabla 4.18 Resultados MAPE para el Diámetro de Sobrecorte (DOC)

	Modelo con conjuntos ajustados empíricamente	Modelo con conjuntos ajustados por sistema neurodifuso y algoritmos genéticos	Modelo con conjuntos ajustados por sistema neurodifuso y micro algoritmo genético
MAPE	11.07 %	8.15%	7.99%
Número de reglas	27	14	14
Número de conjuntos difusos	14	15	15
Tipos de conjuntos	Triangulares y trapezoidales	Gaussianos	Gaussianos

REFERENCIAS

- Abido, M., 2009. Multiobjective Evolutionary Algorithms for Electric Power Dispatch Problem. *Computational Intelligence*, pp. 47-82.
- Acevedo, N., 2011. *El Teorema de Consistencia de Kolmogorov en la Construcción de Procesos Estocásticos Cuánticos*.(Tesis de Posgrado inédita). Universidad Autónoma Metropolitana: s.n.
- Aguilar, R., Torres, J. & Martín, C., 2019. Aprendizaje Automático en la Identificación de Sistemas. Un caso de estudio en la predicción de la generación eléctrica de un parque eólico. *Revista Iberoamericana de Automática e Informática Industrial* , Volumen XVI, pp. 114-127.
- Almorox, J., López, F. & Rfaelli, S., 2010. *La degradación de los suelos por erosión hídrica. Metodos de estimación*. Primera ed. España: Ediciones de la Universidad de Murcia (EDITUM).
- Anrraz de la Peña, J. & Parra, A., s.f. Algoritmos genéticos.
- Antil, P., Singh, S. & Manna, A., 2014. A Study on Input Parameters Affecting Metal Removal Rate And Surface Roughness in Electrochemical Discharge Machining Process. *International Journal of Advance Research In Science And Engineering*, III(12), pp. 400-4005.
- Antonissess, H., 1989. A new interpretation of schema notation that overums the binary encodign constraint. *Proc. Third. International Conference on Genetic Algorithms*, Issue 86-91.
- Asokan, P., Jeyapaul, R. & Santhi, M., 2008. Development of multi-objective optimization models for electrochemical machining process. *The International Journal of Advanced Manufacturing Technology*, XXXVIII(1), pp. 55-63.
- Avalar, H., Gutiérrez, L., Zuñiga, I. & Sánchez, Z., 2019. Diseño e implementación de un algoritmo genético para la predicción de una variable. *Research in Computing Science*, CLXXXVII(8), pp. 187-197.
- Avilés, O., Niño, P. & Solaque, L., 2002. Identificación de parámetros de sistemas dinámicos. *Ciencia e ingeniería* , Volumen 12, pp. 41-51.
- Barbosa, A., Mar, C. & Molar, J., 2019. *Manufatura:Conceptos y aplicaciones*. Primera ed. -- -: Patria.
- Bombal, F., 2013. David Hilbert: La búsqueda de la certidumbre. *Revista Real Academia Ciencias Exactas Físicas y Naturales*, pp. 123-145.
- Cavazzuti, M., 2013. *Optimization Methods: From Theory to Design. Scientific and Technological Aspects in Mechanics*. New York: Springer.

- Cervantes, A., Mezura, E. & Coello, C., 2014. an empirical Comparison of Two Crossover Operators in Real-Coded Genetic Algorithms for Constrained Numerical Optimization Problems. *IEEE International Autumn Meeting on PowerSpecial Session On Evolutionary Computation, ROPEC 2014*, pp. 1-5.
- Chacon Montés, P., 1995. Algoritmos Evolutivos: algoritmos genéticos y cuasiespecie. En: *Vida Artificial*. Castilla, España: niversidad de Castilla-La Mancha.
- Chafaa, K., Ghanai, M. & Saidi, L., 2015. General Fuzzy models for dinamical systems. *27th International Conference on Microelectronics (ICM)* , pp. 27-30.
- Chang, F.-J. & Chen, L., 1998. Real-Code Genetic Algorithm for Rule-Based Flood Control Reservoir Management. *Water Resources Management*, Volumen 12, pp. 185-198.
- Chipperfield, A., 1997. Introduction to Genetic Algorithms. En: *Genetic algorithms in engineering systems*. Londres: The Institution of Electrical Engineers, pp. 1-45.
- Coello, C., 1995. Introducción a los algoritmos genéticos, soluciones avanzadas. *Tecnologías de Información y Estrategias de Negocios*, III(7), pp. 5-11.
- Coello, C. & Toscano, G., 2001. A Micro-Genetic Algorithm for Multiobjective Optimization. *Springer*, Volumen 1993.
- Davis, L., 1991a. Hybridization and numerical representación . En: Davis, ed. *The Handbook of Genetic Algorithms*. New York : s.n., pp. 61-71.
- De la Fuente, M. & Calonge, T., 1999. *Aplicaciones de las redes de neuronas en supervisión, diagnostico y control de procesos*. Primera ed. Venezuela : Equinoccio .
- Deepak, U., Mohsen, B., Suhas, M. & Harlal, M., 2018. Fuzzy logic-based model for predicting material removal rate and averagesurface roughnes of machined Nimonic 80A using abrasive mixed electro-discharge diamond surface grinding. *Neural Computing and Applications*, XIX(9), pp. 647-662..
- Du, K. & Swamy, M., 2016. Search and optimization by metaheuristics. *Techniques and Algorithms Inspired by Nature*.
- Duriez, T., Brunton, S. L. & Noack, B. R., 2017. *Machine Learning Control - Taming Nonlinear Dynamics and Turbulence*. Verna: Springer.
- Eiben, A. E. & Smith, J. E., 2015. *Introduction to Evolutionary Computing*. Berlín: Springer.
- Ergun, H. & Hertem, D., 2016. HVDC Grid Planning. En: *HVDC Grids: For offshore and Supergrid of the Future*. New Jersey,Estados Unidos: IEEE Press, pp. 143-172.
- Gen, M. & Cheng, R., 2000. *Genetic algorithms and engineering optimization*. John Wiley & Sons ed. s.l.:s.n.
- Gestal, M., 2013. Introducción a los algoritmos genéticos.

- Ginzburg, M. C., 2002. *Técnicas Digitales con Circuitos Integrados*. Barcelona: Editorial Reverté.
- Goldeberg, D. & Holland, G., 1988. Genetic Algorithms and Machine Learning.. *Machine Learning*. Springer, Volumen 3, pp. 95-99.
- Goos, P. & Meintrup, D., 2016. *Statics with JMP: Hypothesis tests, Anova and Regression*. New Jersey: John Wiley & Sons.
- Gordienko, E., 2011. Andrey Kolmogorov: El último gran matemático universal. *Miscelánea Matemática*, Volumen LII, pp. 1-29.
- Groover, M., 2007. *Fundamentos de manufactura moderna y materiales*. Tercera ed. Guadalajara: MCGRAW-HILL.
- Gutiérrez, M., Gálvaez, P. & Germán, P., 2007. Optimización de portafolios accionarios a través de un micro algoritmo genético. *Industrial Data* , X(2), pp. 12-20.
- Gwiazda, T. D., 2006. *Genetic Algorithms Reference Volume I: Crossover for single-objective numerical optimization problems*. Lomianki: Tomaszgwiazda e-books.
- Herera, J., Calvo, C., Taud, H. & Portilla, E., 2009. Propuesta de una Metodología Generalizada para Diseñar Micro. *Congreso Internacional de Cómputo en Optimización y Software, Memorias del 7mo Congreso de Cómputo*, pp. 17-20.
- Herrera, F., Lozano, M. & Sanchez, A., 2002. Operadores de Cruce con Múltiples descendientes para algoritmos genéticos con codificación real: Estudio Experimental. *trabajo soportado por la RED HEUR TIC2002-10866-E y el Proyecto TIC2002-04036-C05-01..*
- Herrera, F., Lozano, M. & Sánchez, A., 2007. Algoritmos genéticos con codificación real: Operadores de cruce híbridos basados en entornos con múltiples descendientes. *Actas del Congreso MAEB*, pp. 827-834.
- Heyman, D. & Sobel, M., 2004. Stochastic models in operations research: stochastic optimization. II(Courier Corporation).
- Jacob, C., 2001. *Illustrating Evolutionary Computation with Mathematica*. San Diego(California): Academic Press.
- Jamshidi, M., Coelho, L., Krohling, R. & Fleming, P., 2003. *Robust Control Systems with Genetic Algorithms*. Boca Raton: CRC Press Taylor & Francis Group.
- Jianhua, Z., Hongjie, C. & Rubin, W., 2015. Nonlinear Dynamical System Identification Based on Evolutionary Interval Type-2 TSK Fuzzy Systems. *The 27th Chinese Control and Decision Conference* , pp. 2871-2876.
- Jozi, A., Isabel, P. & Vale, Z., 2019. Decision Support Application for Energy Consumption Forecasting. *Applied Sciences*, IV(4), p. 699.

Kalpakjian, S. & Schmid, S., 2002. *Manufactura ingeniería y tecnología*. Cuarta ed. México: Prentice Hall.

Karnik, N. & Mendel, J., 1998. Type-2 Fuzzy Logic Systems: Type Reduction. *SMC'98 Conference Proceedings. 1998 IEEE International Conference on Systems, Man, and Cybernetics (Cat. No.98CH36218)*, Volumen II, pp. 2046-2051.

Kholi, A., Wadhwa, A. & Virmani, T., 2012. Optimization of material removal rate in electrical discharge machining using fuzzy logic. *World Academy of Science, Engineering and Technology International Journal of Mechanical and Mechatronics Engineering*, VI(12), pp. 1674-1679.

Kim, J. & Kasabov, N., 1999. HyFIS: adaptative neuro-fuzzy inference systems and their application to nonlinear dynamical. *Neura Networks*, XII(9), pp. 1301-1319.

Kosko, 1994. Fuzzy system as universal approximators. *Transactions on Computers*, IVIII(11), pp. 1329-1333.

Krishnakumar, K., 1989. Micro-genetic algorithms for stationary and non-stationary function optimization. *SPIE Proceedings: Intelligent Control and Adaptive Systems*, pp. 289-296.

Krishnakumar, K., 1990. Micro-genetic algorithms for stationary and non-stationary function optimization. *Intelligent control and adaptive systems*, Volumen MCXCVI, pp. 289-296.

Lahoz, B., 2004. *Bioinformática: simulación, vida artificial e inteligencia artificial..* Madrid: Ediciones Díaz de Santos.

Lee, J., Kim, S. & Hyo, S., 2006. Algorithms, Optimum desing of cold-formed steel columns by using micro genetic. *Thin- Walled Structures*, XLIV(9), pp. 952-960.

Levine, G., 2012. *A Guide to SPSS for Analysis of Variance*. New York: Routledge.

Leyva, J., 2018. *Modelado del proceso de maquinado ECDM mediante lógica difusa*. Saltillo, Coahuila: Corporación Mexicana de Investigación en Materiales (COMIMSA).

Lin, J., Wang, K., Yan, B. & Tamg, Y., 2000. Lin, J. L., Wang, K. S., Yan, B. H., & Tarng, Y. S. (2000). Optimization of the electrical discharge machining process based on the Taguchi method with fuzzy logics. *Journal of Materials Processing Technology*, CIII(1-3), pp. 48-55.

Lloyd, S., 2006. How Smart Is the Universe?. En: *Intelligent Thought: Science Versus the Intelligent Design Movement*. New York: Vintage Books, pp. 179-191.

Mahner, M. & Bunge, M., 2000. *Fundamentos de biofilosofía*. Primera ed. México: Siglo veintiuno editores.

- McAllister, R. & Bulmer, M., 2002. A game of corruption in stylized south-east asian timber industry: A Genetic Algorithm Approach. En: *Operations Research/Management Science at Work*. New York: Springer Science+Business Media, pp. 93-110.
- Miller, I. & Freund, J. E., 1963. *Probabilidad y Estadística para Ingenieros*. Barcelona: Reverté Ediciones.
- Nedjah, N., Abraham, A. & de Macedo Mourelle, L., 2006. *Genetic Systems Programming: Theory and Experiences*. Berlín: Springer.
- Olague, G., 2016. *Evolutionary Computer Vision: The first footprints*. Berlín: Springer.
- Oliver, J., 2020. Red neuronal fuzzy híbrida versus red neuronal backpropagation: Aplicación ala predicción del índice bursatil Ibex-35. *Finance, Markets and Valuation*, VI(1), pp. 85-89.
- Ortiz, B., 2015. *Sistemas dinámicos en tiempo continuo: Modelado y simulación*. Primera ed. México: OmniaScience.
- Ott, R. L. & Longnecker, M., 2010. *An Introduction to Statistical Methods and Data Analysis*. Belmont: Cengage Learning.
- Peña, C., Yime, E. & Ilka, B., 2011. Cálculo dimensional óptimo de una plataforma paralela tipo Stewart-GouGh para aplicaciones padagógicas usando algoritmos genéticos. *INGE CUC-Revista de la Facultad de Ingeniería*, VII(1), pp. 127-138.
- Pérez, J., 1996. Heurísticas de búsqueda para problemas discretos de localización-asignación. *Lecturas en teoría de localización*, Volumen Universidad de Sevilla, pp. 107-134.
- Rama, R. y otros, 2009. Fuzzy Logic-Based Forward Modeling of electrochemical Machining Process. *World Congress on Nature & Biologically Inspired Computing (NaBIC)*, pp. 1431-1435.
- Rangajanardhaa, G., Rao, S., Rao, D. & Rao, M., 2009. Development of hybrid model and optimization of surface roughness in electric discharge machining using artificial neural networks and genetic algorithm. *Journal of materials processing technology*, III(CCIX), pp. 1512-1520.
- Robusté, F., 2005. *Lógica del transporte*. Barcelona, España: Edicions de la Universidad Politècnica de Catalunya .
- Rojas, K., 2014. *Control difuso adaptable de la potencia neutrónica del reactor triga Mark III (Tesis Doctoral inédita)*. División de estudios de Posgrado: Instituto Tecnológico de Toluca.
- Sanbueza, H., Harnisch, V., Díaz, R. & C, G., 1999. Aplicación de Algoritmos Genéticos al Problema de Planificación de Sistemas Eléctricos de Distribución. *Revista de la Facultad de Ingeniería*, Volumen VI, pp. 55-63.

Shabgard, M., Badamchizadeh, M., Ranjbary, G. & Amini, G., 2013. Shabgard, M. R., Badamchizadeh, M. A., Ranjbary, G., & Amini, K. (2013). Fuzzy approach to select machining parameters in electrical discharge machining (EDM) and ultrasonic-assisted EDM processes. *Journal of Manufacturing Systems*, XXXII(1), pp. 32-39.

Shi, Y., 2015. *Emerging Research on Swarm Intelligence and Algorithm Optimization*. Hershey: Information Science Reference.

Siler, W. & Buckley, J., 2005. *Fuzzy Experts Systems an Fuzzy Reasoning*. Primera ed. Estados Unidos: Wiley Interscience.

Simon, D., 2013. *Evolutionary Optimization Algorithms: Biologically-Inspired and Population-Based Approaches to Computer Intelligence*. New Jersey: John Wiley & Sons.

Sivanandam, S. N. & Deepa, S. N., 2008. *Introduction to Genetic Algorithms*. Berlín: Springer.

Skrabalak, G., Zybura, M. & Ruszaj, A., 2004. Building of rules base for fuzzy-logic control of the ECDM process. *Journal of Materials Processing Technology*, CVIII(1-3), pp. 530-535.

Solari, A. J., 2007. *Genética Humana: Fundamentos y aplicaciones en Medicina*. Buenos Aires: Editorial Médica Panamericana.

Vasiljevic, D., 2002. *Classical and Evolutionary Algorithms in the Optimization of Optical Systems*. New York: Springer Science+Business Media.

Voget, S., 1996. *Gaussian Diffusion in a Simple Genetic Algorithm*. Berlín, Springer, pp. 266-275.

Wang, L.-X. & Mendel, J., 1992. Generating Fuzzy Rules by Learning from Examples. *IEEE Transactions on systems man and cybernetics*, XXII(6), pp. 1414-1427.

Wang, L.-X. & Mendel, J., 1992. Generating Fuzzy Rules by Learning from Examples. *IEEE Transactions On System, Man and Cibernetics*, XXII(6), pp. 1414-1427.

Wright, A., 1991. Genetic algorithms for real parameter optimization. En: *Foundations of Genetic Algorithms*. s.l.:Rawlins, pp. 205-218.

Yilmaz, O., Eyercioglu, O. & Gindy, N., 2006. A user friendly fuzzy-based system for the selection of electro. *Journal of Materials Processing Technology*, 172(3), pp. 363-371.