

UNIVERSIDAD AUTÓNOMA DE BAJA CALIFORNIA
Facultad de Ciencias Químicas e Ingeniería
Maestría y Doctorado en Ciencias e Ingeniería



**OPTIMIZACIÓN DE LAS FUNCIONES DE MEMBRESÍA EN SISTEMAS
DIFUSOS TIPO-2 EN BASE AL NIVEL DE INCERTIDUMBRE
APLICADOS A LA INTEGRACIÓN DE RESPUESTA EN REDES
NEURONALES MODULARES PARA BIOMETRÍA MULTIMODAL**

TRABAJO DE TESIS

Presentado por

DENISSE PAULETTE HIDALGO AYALA

Para obtener el Grado de

DOCTOR EN CIENCIAS

Director de Tesis

DRA. ELBA PATRICIA MELIN OLMEDA

Co-Director de Tesis

DR. GUILLERMO LICEA SANDOVAL

TIJUANA, BC., DICIEMBRE 2011

Universidad Autónoma de Baja California

FACULTAD DE CIENCIAS QUÍMICAS E INGENIERÍA
COORDINACIÓN DE POSGRADO E INVESTIGACIÓN

FOLIO No. 068

Tijuana, B. C., a 11 de noviembre de 2011

C. DENISSE PAULETTE HIDALGO AYALA

Pasante de: Doctor en Ciencias

Presente

El tema de trabajo y/o tesis para su examen profesional, en la

Opción TESIS

Es propuesto, por los C. Dres. Elba Patricia Melin Olmeda y Guillermo Licea Sandoval

quienes serán los responsables de la calidad de trabajo que usted presente, referido al tema "Optimización de las funciones de membresía en sistemas difusos tipo-2 en base al nivel de incertidumbre aplicados a la integración de respuesta en redes neuronales modulares para biometría multimodal."

el cual deberá usted desarrollar, de acuerdo con el siguiente orden:

- I.- INTRODUCCIÓN
- II.- MARCO TEORICO
- III.- DESARROLLO
- IV.- RESULTADOS
- V.- CONCLUSIONES
- VI.- REFERENCIAS
- VII.- ANEXOS

UNIVERSIDAD AUTÓNOMA
DE BAJA CALIFORNIA



FACULTAD DE CIENCIAS
QUÍMICAS E INGENIERÍA

Dra. Elba Patricia Melin Olmeda
Director de Tesis

Q. Noemí Hernández Hernández
Sub-Director Secretario

Dr. Guillermo Licea Sandoval
Co-Director de Tesis

Dr. Luis Enrique Palafox Maestre
Director

RESUMEN

El presente trabajo de tesis, propone un método de optimización para las funciones de membresía de sistemas difusos tipo-2 en base a su nivel de incertidumbre. La propuesta del nuevo método de optimización consistió en tomar en cuenta tres diferentes casos de incertidumbre (Footprint of Uncertainty) y obtener un sistema difuso tipo-2 óptimo. Dichos casos los hemos llamado Caso 1, Caso 2, y Caso 3.

El primer caso se distingue por tener una misma huella de incertidumbre para todas las funciones de membresía existentes en las entradas del sistema difuso. El segundo caso, con diferente huella de incertidumbre para las distintas entradas; por último, el tercer caso, que tiene diferente huella de incertidumbre para cada función de membresía de cada entrada.

Se realizaron diferentes experimentos en los cuales se probó nuestro método de optimización de sistemas difusos tipo-2 basado en la incertidumbre de sus funciones de membresía.

ABSTRACT

This thesis proposes a method for optimizing the membership functions of type-2 fuzzy systems based on their level of uncertainty. The proposed new method of optimization considers three different cases of uncertainty (Footprint of Uncertainty) and obtains an optimal type-2 fuzzy system. Such cases have been called Case 1, Case 2 and Case 3.

The first case is distinguished by having the same footprint of uncertainty for all existing membership functions of the fuzzy system inputs. The second case has a different footprint of uncertainty for the different inputs. And finally, the third case, which has a different footprint of uncertainty for each membership function of each input.

Experimental results proved that our optimization method for type-2 fuzzy systems based on the uncertainty of their membership functions performs in an efficient and accurate fashion.

DEDICATORIA

Este trabajo de tesis está dedicado primero que nada a Dios, por darme la oportunidad de vivir, y lograr las metas que hasta hoy me he propuesto.

A mis padres Magdalena y Miguel con mucho amor y cariño por ser mi impulso para salir adelante en la vida.

A mis hermanos Ross Nena y Juan Miguel por ser siempre una guía para mí.

Y sobre todo a Ricardo; mi esposo, por ser mi compañero durante éste sueño.

Éste trabajo es para ustedes, los AMO.

AGRADECIMIENTOS

A Dios por darme una familia tan maravillosa y por mantenernos siempre unidos.

Les agradezco infinitamente a mis padres el enseñarme siempre a luchar por mis sueños con dedicación. A ellos, quienes me han dado siempre el amor y soporte para continuar adelante; la confianza necesaria para sobrellevar la distancia que nos separa y cumplir éste sueño, y por apoyar siempre mis decisiones.

A mis hermanos Ross y Juan les agradezco el apoyo incondicional que siempre he recibido de ellos y por su preocupación por mi bienestar; claro, sin dejar de mencionar el consentirme tanto.

A Ricardo por apoyarme en los momentos más difíciles, y darme la fuerza necesaria para levantarme; por comprenderme siempre. A su familia por la confianza que en todo momento nos han brindado.

A mis asesores de tesis, a la Dra. Patricia Melin, al Dr. Oscar Castillo y al Dr. Guillermo Licea por confiar en mí y por su asesoría científica; además al Dr. Antonio Rodríguez, al Dr. Juan Ramón Castro, a la Dra. Olivia Mendoza y al Dr. Fevrier, por compartir sus conocimientos, consejos, amistad y estímulo para salir adelante en mi vida profesional. A ellos, que sin su ayuda y conocimientos, yo no estaría en donde me encuentro ahora.

Agradezco a la Universidad Autónoma de Baja California y al Consejo Nacional de Ciencia y Tecnología por el apoyo otorgado a través de la beca 175883 para concluir los estudios de mi Doctorado en Ciencias.

ÍNDICE GENERAL

RESUMEN	II
ABSTRACT	III
DEDICATORIA.....	IV
AGRADECIMIENTOS.....	V
1. INTRODUCCIÓN.....	8
1.1. Biometría	8
1.2. Resumen de Contribuciones	10
1.2.1. Journal Indexado.....	11
1.2.2. Capítulos en Libro	11
1.2.3. Artículos en memorias de Congreso.....	12
2. MARCO TEÓRICO	14
2.1. Biometría Multimodal.....	14
2.2. Redes Neuronales Artificiales.....	15
2.3. Redes Neuronales Modulares (RNM).....	17
2.4. Lógica Difusa.....	19
2.5. Sistema De Inferencia Difusa Tipo-2 (FLS).....	21
2.6. Fuentes De Incertidumbre De Lógica Difusa Tipo-2	23
2.7. Funciones De Membresía Tipo-2 e Incertidumbre	24
2.8. Conjuntos Difusos Tipo-2 Por Intervalos	25
2.9. Funciones De Membresía Upper Y Lower	26
2.10. Algoritmos Genéticos	27
2.11. Elementos de un AG	28
2.12. Definición y Representación del Cromosoma	30
2.13. Criterios De Parada, Mecanismos De Reemplazo Y Población	31
3. DESARROLLO.....	33
3.1. Definición del Nuevo Método de Optimización de Funciones de Membresía de Sistemas Difusos Tipo-2.....	35
3.2. Estructura del Algoritmo Genético Propuesto	39
3.3. Casos Benchmark	41
3.3.1. Predicción de MPG (Millas por Galón) de automóviles:	41
3.3.2. Sistema de Identificación No-Lineal Box-Jenkins Gas Furnace (BJ)	41

3.3.3. Cancelación de Ruido Adaptivo (ANC).....	42
3.4. Red Neuronal Modular para Biometría Multimodal.....	42
3.4.1. A) Datos De Entrada	43
3.4.2. B) Módulos De La RNM Para Los Entrenamientos.....	45
3.4.3. C) Salida De La Red Neuronal Modular (RNM)	46
3.4.4. D) Integración De La RNM (Sistemas de Inferencia Difusa Tipo-2)	46
3.4.5. E) Optimización De Los Sistemas Difusos en base a la Incertidumbre de sus Funciones de Membresía por Medio de Algoritmos Genéticos	47
3.4.6. F) Salida Final (Activación Ganadora).....	47
4. RESULTADOS	48
4.1. Optimización de Sistemas Difusos Tipo-2 basados en el Nivel de Incertidumbre.....	48
4.1.1. Resultados con Benchmark MPG perturbando incertidumbre manualmente	49
4.1.2. Resultados con Benchmark BJ perturbando incertidumbre manualmente.....	55
4.1.3. Resultados con Benchmark ANC perturbando incertidumbre manualmente.....	61
4.1.4. Pruebas iniciales de optimización basada en incertidumbre utilizando benchmark ANC	67
4.1.5. Pruebas de optimización basada en incertidumbre utilizando benchmark MPG	71
4.1.6. Pruebas De Optimización De Funciones De Membresía Basada En Incertidumbre Como Integradores De Respuesta De Redes Neuronales Modulares	74
5. CONCLUSIONES.....	78
6. REFERENCIAS	81
7. ANEXOS	84
7.1. Graficas de comportamiento del GA para la optimización de sistemas difusos tipo-2 como integradores de redes neuronales modulares con aplicación en biometría multimodal...	84

1. INTRODUCCIÓN

1.1. Biometría

La biometría es una tecnología de seguridad basada en el reconocimiento de una característica de seguridad y en el reconocimiento de una característica física e intransferible de las personas; la definen como una rama de las matemáticas estadísticas que se ocupa del análisis de datos biológicos y que comprende temas como población, medidas físicas, tratamientos de enfermedades y otros por el estilo.

Todos los seres humanos tenemos características morfológicas únicas que nos diferencian. La forma de la cara, la geometría de partes de nuestro cuerpo como las manos, nuestros ojos y tal vez la más conocida, la huella digital, son algunos rasgos que nos diferencian del resto de seres humanos.

La medición biométrica se ha venido estudiando desde tiempo atrás y es considerada actualmente como el método ideal de identificación humana.

La biometría provee verdadera identificación de personas, ya que esta tecnología se basa en el reconocimiento de un rasgo corporal único, por lo que reconoce a las personas en función de quienes son. Solamente la identificación biométrica puede proveer un control realmente eficiente y preciso de las personas, se puede saber con toda certeza que la persona que pasó por esta forma de reconocimiento, es la persona a ser reconocida y no como sucede con firma, código de barras o banda magnética. También puede proveer un registro real de las actividades de las personas, eliminando la posibilidad de que estas accedan a lugares a los que no tienen autorización, suplantar personalidades ajenas, generen fraudes por un falso registro con su firma, etc.

Es posible encontrar artefactos que analizan factores de comportamiento como lo son la dinámica de tecleo o la manera de hablar; existen dispositivos para la evaluación de factores fisiológicos como las huellas dactilares, el iris, la retina, la geometría de dedos y manos, la voz y las proporciones faciales. Un sistema de biometría multimodal combinará el análisis de dos o más de estos indicadores. La ventaja de esta estrategia es que si alguna de las tecnologías falla, por cualquier motivo, el sistema podrá usar uno o más métodos de respaldo [25].

El objetivo principal de esta investigación fue desarrollar de la optimización de funciones de membresía de sistemas difusos tipo-2 basados en su nivel de incertidumbre aplicados a la integración de respuesta en redes neuronales modulares para biometría multimodal.

El presente trabajo de Tesis se encuentra estructurado por capítulos, los cuales se describen brevemente a continuación:

En el capítulo 2 se muestran los conceptos básicos que sirven para tener una amplia visión de las temas tratados en lo que representa el trabajo de tesis presentado; como lo son, las Redes Neuronales Modulares, Lógica Difusa Tipo-2, Incertidumbre de Funciones de membresía, Algoritmos Genéticos, entre otros.

En capítulo 3 se describe el desarrollo del método de optimización basado en la incertidumbre de sus funciones de membresía propuesto; en el capítulo 4 se muestran los resultados obtenidos, tanto de sistemas difusos como integradores de respuesta en base a su incertidumbre, como de redes neuronales modulares. También en éste capítulo se muestran las tablas que expresan a detalle los resultados de los Algoritmos Genéticos utilizados, además de las tablas de comparación.

En el capítulo 5 quedan plasmadas las conclusiones a las que llegamos después de haber realizado el presente proyecto de Tesis; en el capítulo 6 se encuentran las referencias, que presenta la bibliografía estudiada para la realización de éste proyecto de Tesis.

Por último, se encuentra la sección de Anexos, en donde se muestran las graficas obtenidas en las pruebas realizadas por el algoritmo genético, con aplicación a redes neuronales modulares para biometría multimodal.

1.2. Resumen de Contribuciones

A continuación se muestra la contribución de artículos desarrollados en este proyecto de tesis, los cuales se presentaron en journal indexado, capitulo en libro y memoria de congreso.

1.2.1. Journal Indexado

Denisse Hidalgo, Patricia Melin, Oscar Castillo: An optimization method for designing type-2 fuzzy inference systems based on the footprint of uncertainty using genetic algorithms. In Press, Corrected Proof, Available online 20 October 2011 Expert Systems with Application

1.2.2. Capítulos en Libro

Denisse Hidalgo, Oscar Castillo, Patricia Melin: Type-1 and Type-2 Fuzzy Inference Systems as Integration Methods in Modular Neural Networks for Multimodal Biometry and Its Optimization with Genetic Algorithms. Soft Computing for Hybrid Intelligent Systems 2008: 89-114

Denisse Hidalgo, Patricia Melin, Guillermo Licea: Optimization of Modular Neural Networks with Interval Type-2 Fuzzy Logic Integration Using an Evolutionary Method with Application to Multimodal Biometry. Bio-inspired Hybrid Intelligent Systems for Image Analysis and Pattern Recognition 2009: 111-121

Denisse Hidalgo, Patricia Melin, Oscar Castillo, Guillermo Licea: Comparative Study of Type-2 Fuzzy Inference System Optimization Based on the Uncertainty of Membership Functions. Soft Computing for Recognition based on Biometrics. Patricia Melin, Janusz Kacprzyk, and Witold Pedrycz (Eds.). Springer Verlag: 103-120

1.2.3. Artículos en memorias de Congreso

Denisse Hidalgo, Patricia Melin, Guillermo Licea: Genetic Optimization of type-2 fuzzy systems as integration methods in modular neural networks to explore different levels of uncertainty. GrC 2011: 247-252

Denisse Hidalgo, Patricia Melin, Olivia Mendoza: Evolutionary optimization of type-2 fuzzy systems based on the level of uncertainty. FUZZ-IEEE 2010: 1-6

Denisse Hidalgo, Patricia Melin, Oscar Castillo: Optimal Design of Type-2 Fuzzy Membership Functions Using Genetic Algorithms in a Partitioned Search Space. GrC 2010: 212-216

Denisse Hidalgo, Patricia Melin, Oscar Castillo, Guillermo Licea: Optimization of type-2 fuzzy systems based on the level of uncertainty, applied to response integration in modular neural networks with multimodal biometry. IJCNN 2010: 1-6

Denisse Hidalgo, Patricia Melin, Oscar Castillo: Type-2 Fuzzy Inference System Optimization Based on the Uncertainty of Membership Functions Applied to Benchmark Problems. MICA (2) 2010: 454-464

Denisse Hidalgo, Patricia Melin, Guillermo Licea, Oscar Castillo: Optimization of Type-2 Fuzzy Integration in Modular Neural Networks Using an Evolutionary Method with Applications in Multimodal Biometry. MICA 2009: 454-465

Denisse Hidalgo, Patricia Melin, Oscar Castillo, Guillermo Licea: Optimization of Modular Neural Networks with Type-2 Fuzzy Integration using General Evolutionary Method with Application in Multimodal Biometry. Mexico Intelligent Engineering Systems Through Artificial Neural Networks. Volume 19. *ANNIE 2009* Conference, St. Louis, Missouri, USA. 2 - 4 November 2009. ISBN 978-0-918-0295-3: 83-90

Denisse Hidalgo, Oscar Castillo, Patricia Melin: Optimization with genetic algorithms of modular neural networks using interval type-2 fuzzy logic for response integration: The case of multimodal biometry. *IJCNN 2008*: 738-745

2. MARCO TEÓRICO

2.1. Biometría Multimodal

Recientemente, los métodos tradicionales de identificación y verificación se han sustituido por información concreta conocida por un individuo, como un número de identificación personal (PIN) o contraseña. La biométrica aporta una nueva dimensión –la autenticación de la identidad física– a partir de una huella digital, lectura de iris o perfil facial. La demanda de soluciones biométricas y otras soluciones de identificación electrónica crece rápidamente; el nivel de efectividad y seguridad de las diferentes tecnologías biométricas varía, al igual que los riesgos inherentes que conllevan. Los niveles de efectividad difieren para los diferentes grupos de personas, debido que las soluciones se basan en un único elemento biométrico –lo que se denomina modalidad única–, lo cual limita el potencial de esta tecnología.

Una modalidad única puede resultar insuficiente para identificar a un individuo en una base de datos que recoja a 500 millones de personas. Una respuesta a este problema es la autenticación multimodal, que significa que un sistema soporta varios métodos de identificación biométrica. La idea es que la biometría multimodal adopte dos formas. En primer lugar, un sistema que utilice dos medidas biométricas, por ejemplo la huella y la identificación facial. El segundo sistema sugerido toma diferentes lecturas de la misma biométrica, por ejemplo una huella que se captura más de una vez.

Estos sistemas persiguen objetivos comunes: mejorar el detalle, fiabilidad y seguridad, integridad y control ofrecido por una solución biométrica que funciona correctamente. Ha habido multitud de datos y debates que sugieren firmemente que la biometría multimodal puede conducir a un establecimiento de la identidad más seguro ya que incorpora más de un “indicador” de identidad, lo cual dificulta las falsificaciones y disminuye la probabilidad de falsos positivos.

Es importante reconocer que la biometría multimodal es un método más estricto de establecer y confirmar la identidad. Es por ello que en este desarrollo de tesis manejamos una red neuronal multimodal como tema de estudio para nuestro sistema híbrido de optimización [25].

2.2. Redes Neuronales Artificiales

Muchos de los desarrollos del hombre se deben a su capacidad para explicar y emular funciones que son realizadas por seres vivos. Aunque el hombre ha sido capaz de emular funciones de los animales, para él siempre ha sido un sueño poder conocer e imitar, la llamada por muchos la máquina perfecta: el cerebro humano.

Cuando la neurociencia pudo explicar de forma un poco convincente el funcionamiento de la unidad principal de procesamiento de información que posee el cerebro, la neurona, surge

casi de manera automática la idea de poder emular dicho funcionamiento en un elemento artificial "La neurona artificial." Kohonen (1998) define las redes neuronales como redes de elementos simples (usualmente adaptativos) masivamente interconectados en paralelo y con organización jerárquica, las cuales intentan interactuar con los objetos del mundo real del mismo modo que lo hace el sistema nervioso biológico.

En síntesis se puede considerar que una Red Neuronal Artificial es un sistema de procesamiento de información que tiene ciertas características de comportamiento en común con las redes neuronales biológicas. Las redes neuronales artificiales han sido desarrolladas como generalizaciones de modelos matemáticos del conocimiento humano o de la biología neuronal, con base en lo siguiente:

1. El procesamiento de información se realiza en muchos elementos simples llamados neuronas.
2. Las señales son pasadas entre neuronas a través de enlaces de conexión
3. Cada enlace de conexión tiene un peso asociado, el cual, en una red neuronal típica, multiplica la señal transmitida.
4. Cada neurona aplica una función de activación (usualmente no lineal) a las entradas de la red (suma de las señales de entrada pesadas) para determinar su señal de salida.

La distribución de neuronas dentro de una red se realiza formando niveles o capas de un número de neuronas determinado, donde se conoce como capa o nivel a un conjunto de neuronas cuyas entradas provienen de la misma fuente (que puede ser otra capa de neuronas) y cuyas salidas se dirigen al mismo destino (que puede ser otra capa de neuronas). Se pueden distinguir tres tipos de capas:

Capa de Entrada.- Es la capa que recibe directamente la información proveniente de las fuentes externas de la red.

Capa Oculta.- Son internas a la red y no tiene contacto directo con el exterior. El número de niveles ocultos puede estar entre cero y un número elevado. Las neuronas de la capa oculta pueden estar interconectadas de diferentes maneras, lo que determina, junto con su número, las

distintas tipologías de redes neuronales.

Capa de Salida.- Transfieren información de la red hacia el exterior.

Las RNA's han sido aplicadas en un gran número de problemas reales de complejidad considerable. Su más importante ventaja es la de resolver problemas que son muy complejos para tecnologías convencionales, problemas que no tienen una solución determinística o para los cuales una solución determinística es muy complicado encontrarla. En general, por ser una abstracción del cerebro biológico, las RNA son buenas para resolver aquellos problemas que las personas resuelven adecuadamente, pero que los computadores no. Estos problemas, entre otros, incluyen reconocimiento de patrones y problemas de pronóstico (los cuales requieren el reconocimiento de una tendencia en unos datos).

Con Redes Neuronales se ha dado solución a problemas con altos niveles de incertidumbre que con métodos tradicionales jamás se habría obtenido. Soluciones tan novedosas e interesantes como identificación de usuarios en cajeros automáticos desde la imagen del iris de los ojos, reconocimiento de emisores en comunicaciones, identificación de huella dactilar, identificación de rostros, reconocimiento de objetos tridimensionales y reconocimiento de texto manuscrito, entre muchas otras cosas [17].

2.3. Redes Neuronales Modulares (RNM)

Como es habitual en muchas disciplinas científicas, previo a la búsqueda de soluciones al problema que se plantea en cada momento, es razonable y preferible pararse un instante y realizar un análisis del problema. El fruto de este análisis será una visión de las distintas partes que forman el todo, habiéndose transformado la tarea inicial, probablemente compleja, en un conjunto de subtareas más elementales, susceptibles de ser abordadas de manera más sencilla y eficiente. Una vez hecho esto el problema se transforma en el opuesto: integrar los resultados parciales obtenidos de cada una de esas subtareas y generar la solución al problema completo.

El primer paso es *dividir* la tarea problema en subtareas, y posteriormente crear y organizar adecuadamente los subsistemas construidos para permitir la comunicación entre ellas y así *integrarse* como un todo que proporcione la solución buscada. La idea de modularidad, al igual que ocurrió en los orígenes de la computación conexionista, puede haber surgido bajo la inspiración de los modelos biológicos. Un examen de las estructuras fisiológicas del sistema nervioso en los animales vertebrados revela la existencia de una representación y procesamiento modular jerárquica de la información.

Tomando como base los indicios biológicos, una primera aproximación modular de sistemas complejos podría ser la descrita por Jacobs y Jordan, que implicaría dos tipos bien diferenciados de aprendizaje:

- Aprendizaje supervisado, durante el cual un maestro externo suministra para cada estímulo de entrada la salida correcta. Sin embargo, este maestro no especifica qué módulo es el que debe aprender el correspondiente par [estímulo de entrada, salida deseada].

- Aprendizaje no supervisado, que básicamente consiste en un aprendizaje competitivo, en el que los distintos módulos compiten por aprender el ejemplo presentado.

En general un sistema computacional se puede considerar como una estructura modular si se puede dividir en dos o más módulos (subsistemas), en los cuales cada módulo individualmente puede evaluar diferentes, o las mismas entradas sin comunicarse con los demás módulos. Es entonces que la comunicación entre los módulos se puede describir desde dos puntos de vista:

1. Cómo repartir la información durante la etapa de entrenamiento entre los distintos módulos.
2. Cómo integrar los distintos resultados ofrecidos por los diferentes módulos constitutivos del sistema para generar la salida final.

El problema de cómo repartir la información durante la etapa de entrenamiento entre los distintos módulos es equivalente a determinar qué módulo debe ajustarse para aprender un determinado ejemplo, y de qué magnitud debe ser ese ajuste. Pueden destacarse soluciones a este problema por un criterio de proximidad, que puede reducirse al caso “*el ganador se lo lleva todo*”, “mayoría gana” o bien puede haber varios ganadores. El mecanismo de “*el ganador se lo lleva todo*” sólo se puede plantear en aquellos sistemas en los que los expertos realizan tareas parecidas y ofrecen resultados homogéneos.

Es importante mencionar que el uso de las RNM para resolver un problema en particular, requiere de un conocimiento amplio del problema para poder hacer la subdivisión del mismo, y plantear la arquitectura modular adecuada para resolverlo, de tal manera que se pueden entrenar cada uno de los módulos independientemente, y posteriormente integrar el conocimiento aprendido por cada módulo, en la arquitectura global [21] [22].

2.4.Lógica Difusa

La lógica difusa es una metodología que proporciona una manera simple y elegante de obtener una conclusión a partir de información de entrada vaga, ambigua, imprecisa, con ruido o incompleta, en general la lógica difusa imita como una persona toma decisiones basada en información con las características mencionadas. Una de las ventajas de la lógica difusa es la posibilidad de implementar sistemas basados en ella tanto en hardware como en software o en combinación de ambos. La lógica difusa es una técnica de inteligencia computacional que permite trabajar información con alto grado de imprecisión, en esto se diferencia de la lógica convencional que trabaja con información bien definida y precisa [29] [30].

El concepto clave para entender cómo trabaja la lógica difusa es el de conjunto difuso, se puede definir un conjunto difuso de la siguiente manera. Un conjunto difuso es una generalización de un intervalo unidad [0,1]. Así, la *función de membresía* de un conjunto

difuso mapea cada elemento del universo de discurso a un rango del espacio el cual, en muchos casos, es el conjunto al intervalo de la unidad [31] [32].

Una de las más grandes diferencias entre los conjuntos duros y difusos es que el primero siempre tiene funciones de membresía únicas, mientras que todo conjunto difuso tiene un número infinito de funciones de membresía que pueden representarlo. Esto permite que los sistemas difusos puedan ser ajustados a su rendimiento máximo en una situación dada. En un sentido amplio, como apuntó Lotfi Zadeh cualquier campo puede ser fuzzificado y generalizado reemplazando el concepto de conjunto duro en un campo fuente por el concepto de un conjunto difuso [1].

La lógica difusa está basada en el hecho de que la gente es capaz de manejar problemas complejos en la vida diaria sin tener un conocimiento exacto matemático del sistema. Expresiones como esta son imprecisas o llamadas *difusas*. A pesar de lo difuso, los humanos utilizamos palabras como: poco, mucho, fuerte, suave,..., frecuentemente en el transcurso de la vida estas palabras pueden ser útiles, a pesar de su falta de precisión matemática. Al leer la expresión antes mencionada acerca del clima nadie saldría de su casa en camiseta, bermudas y lentes oscuros. Así que para un ser humano la expresión es lo suficientemente precisa para la selección apropiada de ropa, aun que la expresión contenga datos precisos como temperatura exacta e intensidad de la lluvia por área y tiempo el resultado de la selección no sería muy diferente [17] [33].

Los Sistema de Lógica Difusa (FLS) Tipo-1 no pueden manejar directamente reglas con incertidumbre porque utilizan conjuntos difusos tipo-1 que son precisos. Los FLS Tipo-2, nos permiten modelar y minimizar los efectos de la incertidumbre en sistemas de lógica difusa basados en reglas; por otra parte, son muy útiles en circunstancias en las cuales es difícil determinar una función de membresía exacta para un conjunto difuso; por lo tanto, pueden ser utilizados para manejar reglas inciertas e incluso medidas inciertas [1]. Los conjuntos difusos tipo-2 nos permiten modelar y minimizar los efectos de la incertidumbre en

sistemas de lógica difusa basados en reglas. Los FLS tipo-2 mueven al mundo de los FLS en una fundamentalmente nueva e importante dirección [2][24].

En esta tesis nos estamos enfocando en la lógica difusa tipo-2 ya que lo que nos interesa es el manejo de la incertidumbre de las funciones de membresía de un sistema difuso. Por lo que explicaremos un poco lo que es la lógica difusa tipo-2 más a detalle a continuación.

La lógica difusa tipo-2, puede manejar incertidumbre porque puede modelarla y reducir al mínimo sus efectos. Y, si desaparecen todas las incertidumbres, la lógica difusa tipo-2 reduce a lógica difusa tipo-1, de la misma manera que, si desaparece la aleatoriedad, la probabilidad se reduce al determinismo [18].

Los sistemas inteligentes basados en lógica difusa constituyen herramientas fundamentales para modelar sistemas complejos no lineales. Los conjuntos difusos y la lógica difusa, son el fundamento de los sistemas difusos, han sido desarrolladas buscando modelar la forma como el cerebro manipula información inexacta. Los conjuntos difusos tipo-2, se usan para modelar incertidumbre e imprecisión. Los conjuntos difusos tipo-2 fueron originalmente propuestos por Zadeh en 1975 y son esencialmente conjuntos “difusos-difusos” en los que los grados de pertenencia son conjuntos difusos tipo-1[1][6].

2.5.Sistema De Inferencia Difusa Tipo-2 (FLS)

Un sistema de inferencia difuso es un sistema basado en reglas que usa lógica difusa, en vez de lógica Booleana, para analizar datos. Su estructura básica incluye cuatro componentes principales [1] [24]:

- *Fuzzificador*. Traduce entradas (valores reales) a valores difusos.

- *Sistema de Inferencia*. Aplica un mecanismo de razonamiento difuso para obtener una salida difusa tipo-1 o tipo-2.
- *Defuzificador/Reductor de tipo*. El defuzificador traduce una salida a valores precisos; el reductor de tipo transforma un conjunto difuso de tipo-2 a tipo-1; y
- *Base de conocimientos*. Contiene un conjunto de reglas difusas, conocidas como base de reglas, y un conjunto de funciones de membresía conocidas como la base de datos.

En la figura 2.1 podemos ver la estructura básica de un Sistema de Inferencia Difusa tipo-2.

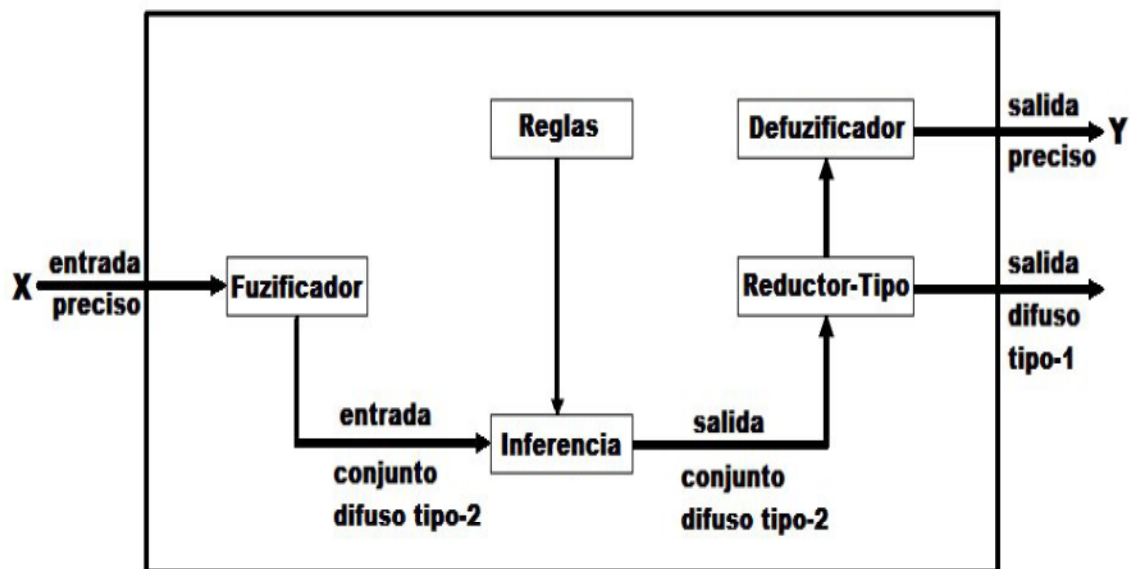


Figura 2.1. Estructura básica de un sistema de inferencia difusa tipo-2

La incertidumbre, es "la imperfección en el conocimiento sobre el estado o los procesos de la naturaleza". La incertidumbre estadística es "la aleatoriedad o el error proveniente de varias fuentes como las descritas al usar la metodología estadística"[23].

2.6.Fuentes De Incertidumbre De Lógica Difusa Tipo-2

La incertidumbre viene en muchos aspectos y es independiente del tipo de Lógica Difusa (FL), o cualquier tipo de metodología. Cuando tratamos con problemas del mundo real, raras veces (poco probable) podemos evitar la incertidumbre. En el nivel empírico, la incertidumbre es un compañero inseparable de casi cualquier medida, siendo resultado de una combinación de errores de medida inevitables y los límites de resolución de instrumentos de medición [19].

En el nivel cognoscitivo, surge de la imprecisión y la ambigüedad inherente en la lengua natural. En el nivel social, la incertidumbre tiene empleos aún estratégicos y a menudo es creada y mantenida por la gente para objetivos diferentes (la intimidad, el secreto, la propiedad) [26].

Una característica de la lógica difusa, que es de particular importancia para la gestión de la incertidumbre, es que proporciona un marco sistemático para hacer frente a los cuantificadores difusos, por ejemplo, la mayoría, muchos, pocos, no muchos, casi todos, con poca frecuencia, aproximadamente 0,8 , etc.; de esta manera, la lógica difusa subsume tanto la lógica de predicados y la teoría de la probabilidad, y hace que sea posible para hacer frente a diferentes tipos de incertidumbre dentro de un marco conceptual [27].

En cuanto *a las causas de incertidumbre*, se encuentran:

La incertidumbre involucrada en cualquier situación de resolución de problemas es el resultado de alguna deficiencia de información. La Información puede estar incompleta, fragmentada, no totalmente confiable, vaga, contradictoria, o deficiente. En general, estas carencias de información pueden causar diferentes tipos de incertidumbre.

En cuanto *a la naturaleza de la incertidumbre*:

Tres tipos de incertidumbre son reconocidos *la falta de claridad ...* (o la vaguedad), que es resultado de los límites imprecisos de conjuntos difusos; *la no especificidad* (o la

imprecisión), la cual está conectada con tamaños (las cardinalidades) de los conjuntos relevantes de las alternativas; y *la lucha* (o la discordia), que expresa conflictos entre varios conjuntos de alternativas. La palabra *imprecisión* es frecuentemente usada tanto para la falta de claridad como para la no especificidad [26].

Hay varias fuentes de incertidumbre en el cálculo y evaluación. Los cinco tipos de incertidumbre, que emergen de un conocimiento impreciso del estado de la naturaleza son:

- Incertidumbre en la medición, es el error en las cantidades observadas.
- Incertidumbre en el proceso, es la aleatoriedad subyacente en la dinámica.
- Incertidumbre en el modelo, es la especificación errónea de la estructura del modelo;
- Incertidumbre en la estimación, es la que puede resultar de cualquiera, o de una combinación, de las incertidumbres descritas anteriormente y es la inexactitud e imprecisión.
- Incertidumbre en la implementación, es la consecuencia de la variabilidad que resulta de una política de ordenación, i.e. incapacidad para alcanzar exactamente el objetivo de una estrategia [1] [6].

La lógica difusa, es una tecnología basada en reglas que tolera imprecisiones e incluso las aprovecha para resolver problemas que antes no tenían solución [5].

2.7.Funciones De Membresía Tipo-2 e Incertidumbre

Las funciones de membresía caracterizan a los conjuntos difusos, sean éstos tipo-1 ó tipo-2. Karnik y Mendel en [23], muestran que cuando nosotros no podemos determinar la membresía de un elemento en un conjunto como 0 ó 1, usamos conjuntos difusos de tipo-1. Similarmente, cuando las circunstancias son muy difusas, tanto que tenemos problemas para determinar el grado de membresía, incluso como un número entre [0 1], usamos conjuntos difusos tipo-2, concepto que fue introducido por Zadeh en 1975. Esto no significa que

necesitamos tener circunstancias extremadamente difusas para utilizar conjuntos difusos tipo-2. Podemos ver la situación desde una perspectiva diferente. Cuando algo es incierto (ej., una medida), tenemos problemas para determinar su valor exacto, y en su caso usar conjuntos difusos tipo-1 tiene más sentido que usar conjuntos clásicos. Pero entonces, aun en los conjuntos difusos tipo-1, especificamos la función de membresía exactamente. Pero si no podemos determinar el valor exacto de la cantidad de incertidumbre utilizamos conjuntos difusos tipo-2 [23].

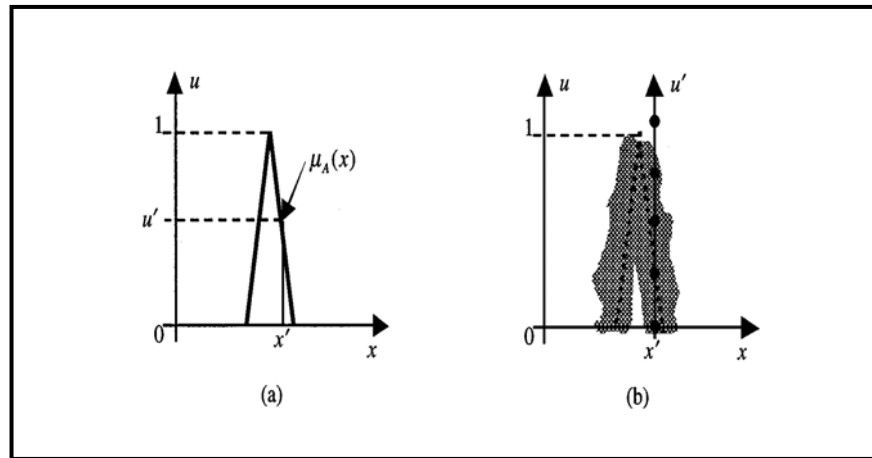


Figura 2.2. Funciones de Membresía. (a) Función de Membresía Tipo-1, (b) Función de Membresía Tipo-1 con Incertidumbre

2.8. Conjuntos Difusos Tipo-2 Por Intervalos

Si $f_x(u) = 1, \forall u \in [J_x^u, \bar{J}_x^u] \subseteq [0, 1]$, la función de membresía tipo-2 $\mu_{\tilde{A}}(x, u)$ se expresa por una función de membresía inferior, $J_x^u \equiv \underline{\mu}_A(x)$ y superior, $\bar{J}_x^u \equiv \bar{\mu}_A(x)$ de tipo-1, entonces es llamado un conjunto difuso tipo-2 por intervalos denotado por;

$$\tilde{A} = \left\{ (x, u, 1) \mid \forall x \in X, \forall u \in [\underline{\mu}_A(x), \bar{\mu}_A(x)] \subseteq [0, 1] \right\} \quad (2.1)$$

o bien

$$\tilde{A} = \left\{ \int_{x \in X} \left[\int_{u \in [J_x^u, \bar{J}_x^u] \subseteq [0, 1]} 1/u \right] / x \right\} = \left\{ \int_{x \in X} \left[\int_{u \in [\underline{\mu}_A(x), \bar{\mu}_A(x)] \subseteq [0, 1]} 1/u \right] / x \right\} \quad (2.2)$$

La incertidumbre en la membresía primaria de un conjunto difuso tipo-2, \tilde{A} , consiste en una región delimitada que llamamos Huella de Incertidumbre (FOU, por sus siglas en ingles). Esta es la unión de todas las membresías primarias [23]:

$$FOU(\tilde{A}) = \cup_{x \in X} J_x \quad (2.3)$$

El término FOU es muy útil, ya que no solamente enfoca nuestra atención en las incertidumbres inherentes en una función de membresía tipo-2 específica, cuya forma es consecuencia directa de la naturaleza de estas incertidumbres, pero también provee de una descripción verbal del dominio entero de soporte para todos los grados secundarios de una función de membresía tipo-2 [23].

2.9. Funciones De Membresía Upper Y Lower

La FOU puede ser descrita en términos de las funciones de membresía upper y lower [23].

Una función de membresía upper y una función de membresía lower son dos funciones de membresía tipo-1 las cuales son los límites de la FOU de un conjunto difuso tipo-2 \tilde{A} . La función de membresía upper está asociada con el límite superior de $FOU(\tilde{A})$, y esta denotada \forall por $\mu_{\tilde{A}}(x)$,

$x \in X$. La función de membresía lower está asociada con el límite inferior de $FOU(\tilde{A})$, y esta denotada $\underline{\mu}_{\tilde{A}}(x), \forall x \in X$ [23].

$$\mu_{\tilde{A}}(x) \equiv FOU(\tilde{A}) \forall x \in X \quad (2.4)$$

y

$$\underline{\mu}_{\tilde{A}}(x) \equiv \underline{F}\underline{U}(\tilde{A}) \quad x \in X \quad (2.5)$$

2.10. Algoritmos Genéticos

En la naturaleza, los individuos compiten entre sí por recursos tales como comida, agua refugio. Adicionalmente, los animales de la misma especie normalmente antagonizan para obtener una pareja. Esta es la teoría de la evolución, especies naturales que van evolucionando para adaptarse al medio que las rodea y aquellos individuos que tenga más éxito en tal adaptación tendrán mejor probabilidad de sobrevivir hasta la edad adulta y probablemente un número mayor de descendientes, por lo tanto, mayores probabilidades de que sus genes sean propagados a los largo de sucesivas generaciones. La combinación de características de los padres bien adaptados, en un descendiente, puede producir muchas veces un nuevo individuo mucho mejor adaptado que cualquiera de sus padres a las características de su medio ambiente [20].

Este proceso no debe verse en ningún momento como un proceso determinista, sino como un proceso con la fuerte componente estocástica. Es decir, si un individuo se adapta al entorno, lo más que se puede afirmar es que ese individuo tendrá mayor probabilidad de conservar sus genes en la siguiente generación que sus congéneres. Pero solo es una probabilidad, no es un hecho absolutamente seguro. Siempre existirá la posibilidad de que a pesar de estar muy dotado por alguna razón no consiga reproducirse. Pero en cuanto a la especie como un conjunto o población, si puede afirmarse que ir adaptándose al medio.

La idea surgió en la universidad de Michigan, Estados Unidos donde el profesor J. H. Holland quien, consciente de la importancia de la selección natural introdujo la idea de los Algoritmos Genéticos en los años sesenta y al final de esta década desarrollo una técnica que permitió incorporarla en un programa de computadora. Su principal objetivo era lograr que las computadoras aprendieran por sí mismas. A la técnica inventada por Holland se le llamó Algoritmos Genéticos (AG).

2.11. Elementos de un AG

Como los Algoritmos Genéticos se encuentran basados en los procesos de evolución de los seres vivos, casi todos sus conceptos se basan en conceptos de biología y genética que son fáciles de comprender.

Individuo.- Un individuo es un ser que caracteriza su propia especie. El individuo es un cromosoma y es el código de información sobre el cual opera el algoritmo. Cada solución parcial del problema a optimizar está codificada en forma de cadena en un alfabeto determinado, que puede ser binario o real. Una cadena representa a un cromosoma, por lo tanto también a un individuo y cada posición de la cadena representa a un gen. Esto significa que el algoritmo trabaja con una codificación de los parámetros y no con los parámetros en sí mismos.

El genotipo, es el conjunto de genes ordenados y representa las características del individuo. Cada individuo tiene una medida de su adecuación como solución al problema.

Población.- A un conjunto de individuos (Cromosomas) se le denomina población. El método de AGs consiste en ir obteniendo de forma sucesiva distintas poblaciones. Por otra parte un Algoritmo Genético trabaja con un conjunto de puntos representativos de diferentes zonas del espacio de búsqueda y no con un solo punto.

Función Fitness.- La única restricción para usar un algoritmo genético es que exista una función llamada fitness, que le informe de cuan bueno es un individuo dado en la solución de un problema. Esta función fitness o de evaluación es el principal enlace entre el Algoritmo Genético a un problema real, es la efectividad y eficiencia de la función fitness que se tome, por lo tanto debe procurarse que la función fitness sea similar, si no igual a la función objetivo que se quiere optimizar. Esta medida se utiliza como parámetro de los operadores y guía la obtención de nuevas poblaciones.

Operadores Genéticos.- Son los diferentes métodos u operaciones que se pueden ejercer sobre una población y que nos permite obtener poblaciones nuevas. Una vez que se ha evaluado cada individuo sobre una función fitness, se aplican los operadores genéticos. En Algoritmos Genéticos se destacan los siguientes operadores:

-*Operador de Selección.* El paso siguiente a la evaluación es escoger los miembros de la población que serán utilizados para la reproducción. Su meta es dar más oportunidades de selección a los miembros más aptos de la población. Así funciona: se calcula el cociente entre el valor fitness de un individuo y la suma total de los valores fitness de todos los individuos de la población.

-*Operador de Cruce.*- Consiste en unir en alguna forma los cromosomas de los padres que han sido previamente seleccionados de la generación anterior para formar dos descendientes como se puede ver en la figura 3. Existen diversas variaciones, dependiendo del número de puntos de división a emplear y la forma de ver el cromosoma. El objetivo del operador de cruce es recombinar subcadenas de forma eficiente; esta gestión recibe el nombre de construcción de bloques.




Figura 2.3. Operador de cruce

Operador de Mutación.- El operador de mutación consiste en la alteración aleatoria de cada uno de los genes del individuo con una probabilidad de mutación. El objetivo de la mutación es producir diversidad en la población. Si al generar aleatoriamente la población inicial o después de varias generaciones, en la misma

posición de todos los cromosomas sólo aparece un único elemento utilizado, esto supondrá que con los operadores de reproducción y cruce, nunca cambiara dicho elemento, por lo que puede ocurrir que jamás se alcance la solución más óptima a nuestro problema. La probabilidad de aparición del operador de mutación no debe ser grande para no perjudicar la correcta construcción de bloques. El operador de mutación origina variaciones elementales en la población y garantiza que cualquier punto del espacio de búsqueda pueda ser alcanzado.




Figura 2.4. Operador de mutación

2.12. Definición y Representación del Cromosoma

Se debe utilizar la estructura de datos más apropiada para el problema en cuestión. Si se está optimizando un problema en que las variables sean reales entonces el cromosoma debe estar formado por componentes reales. Si una solución al problema puede representarse con algunos números imaginarios y algún entero entonces es necesario definir un cromosoma con estas características.

Definir una representación apropiada es parte del arte de usar algoritmos genéticos. Se debe usar una representación mínima que sea completamente expresiva de forma tal que sea capaz de representar cualquier solución al problema, pero además que no admita soluciones no factibles. En caso de que el diseño de los cromosomas permita representar soluciones no

factibles entonces corresponde diseñar la función objetivo de forma tal que esta solo de crédito parcial a las mismas.

La representación no debe contener información innecesaria para dar la solución al problema. Aunque puede haber mérito usando una representación que contiene material genético extra, esto tiende a aumentar el tamaño del espacio de la búsqueda y disminuir así la eficiencia del Algoritmo Genético durante la búsqueda.

2.13. Criterios De Parada, Mecanismos De Reemplazo Y Población

Los criterios de parada del algoritmo genético están muy relacionados con la naturaleza del problema en cuestión. No obstante podemos citar algunos de los criterios de parada más generales:

- Hasta número de generaciones determinado.
- Hasta que el mejor individuo de una población, alcance un valor predeterminado de la función objetivo.
- Hasta que determinada cantidad de individuos de una población sobrepase un valor de umbral predeterminado.
- Hasta que la mayoría de los individuos de una población se encuentren en la vecindad de un punto. O sea que la mayoría de los individuos haya convergido a un punto.

Los mecanismos de reemplazo por su parte están muy relacionados con el tipo de algoritmo genético que se implemente siendo los más populares:

- Simple, este algoritmo no realiza reemplazo y tiene elitismo opcional.
- 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.
- Con poblaciones de tamaño fijo, 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.

- Incremental en el que en cada generación solo uno o dos descendientes sobreviven.
- Algoritmo genético con migraciones: este algoritmo permite la evolución de varias poblaciones de forma paralela, donde cada una de ellas evoluciona siguiendo un modelo de algoritmo genético con tamaño fijo. En cada generación el algoritmo establece una política de emigración entre las diferentes poblaciones [20].

3. DESARROLLO

En el presente trabajo de tesis se planteó un nuevo método de Optimización de las Funciones de Membresía en Sistemas Difusos Tipo-2 en Base al Nivel de Incertidumbre aplicados a la Integración de Respuesta en Redes Neuronales Modulares para Biometría Multimodal. Se llevaron a cabo diversas etapas:

- La optimización del integrador difuso tipo-2 en base al nivel de incertidumbre de sus funciones de membresía.
- La optimización de la arquitectura de la red neuronal modular en capas y neuronas, donde se prueban los integradores difusos tipo-2 obtenidos.

La visión primordial del proyecto de tesis es la elaboración de un método para optimizar las funciones de membresía de sistemas difusos tipo-2 en base al nivel de incertidumbre aplicados a la integración de respuesta en Redes Neuronales Modulares para biometría

multimodal, además se busca la optimización de capas y neuronas de la arquitectura de la red neuronal modular; la finalidad de obtener la arquitectura óptima es la de tener mejores niveles de reconocimiento y mejorar la eficiencia del sistema híbrido de reconocimiento de patrones.

Se adquirieron entonces los datos que serian utilizados como datos de entrada para la RNM, dichos datos fueron tomados de [16], ya que el objetivo de este proyecto de tesis fue implementar como integradores los sistemas difusos tipo-2, optimizados en base a la incertidumbre de sus funciones de membresía con algoritmos genéticos. Una vez obtenidos dichos datos, se inició con la etapa de entrenamiento de RNM optimizada de los cuales elegimos algunas de las pruebas para probar la integración con los sistemas difusos tipo-2 optimizados con AGs en base a su incertidumbre en donde implementamos la estrategia que se propone en esta tesis y que posteriormente se describe.

A continuación se presenta esquemáticamente el proyecto de tesis elaborado, en la figura 3.1.

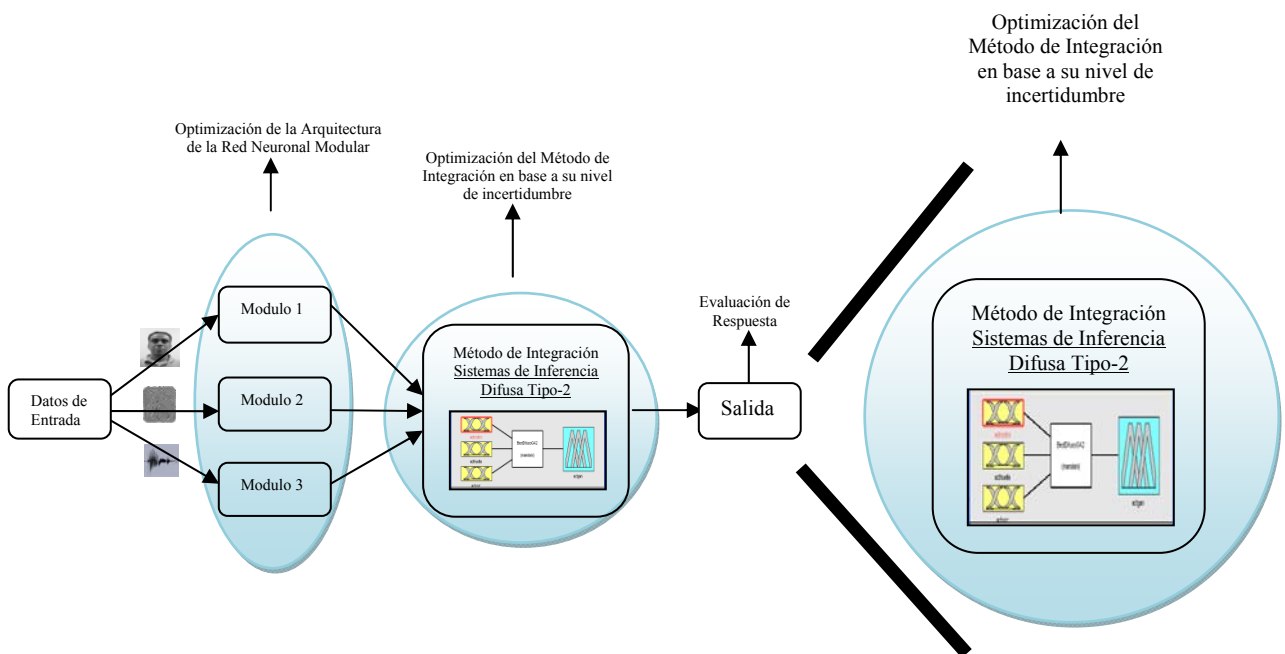


Figura 3.1. Esquema general de optimización

En el esquema anterior se puede observar en primera instancia la representación general de la red neuronal modular para biometría multimodal, que como datos de entrada se reciben datos de rostro, huella y voz para sus respectivos módulos; en este punto se hace la optimización de la arquitectura de la red neuronal modular donde optimizamos capas y neuronas para el entrenamiento de la red, después con los datos obtenidos como resultado de cada módulo hacemos la integración de resultados con sistemas de inferencia difusa tipo-2, cabe resaltar que es aquí donde se crea la optimización de dichos sistemas de inferencia difusa tipo-2 en base a la incertidumbre de sus funciones de membresía para así obtener una respuesta satisfactoria de porcentaje de reconocimiento de personas de la red.

3.1. Definición del Nuevo Método de Optimización de Funciones de Membresía de Sistemas Difusos Tipo-2

A continuación explicaremos detalladamente el nuevo método de optimización de las funciones de membresía en sistemas difusos Tipo-2 en base al nivel de incertidumbre como métodos de integración; utilizando algoritmos genéticos para dicha optimización. Es importante mencionar que para ésta tesis propusimos una estrategia que a continuación se describirá:

1. El primer paso es obtener el sistema de inferencia difusa tipo-1, que nos permitirá encontrar la incertidumbre de sus funciones de membresía. En este caso hemos utilizado ϵ (épsilon) para referirnos a la incertidumbre.
2. Para el siguiente paso, que es encontrar la incertidumbre, se manejan 3 casos principales para manipular ϵ y en base a ello hacer uso de algoritmos genéticos para todas las situaciones, que se describen a continuación:
 - Para el primer caso (que llamaremos Caso 1) se utiliza igual valor de incertidumbre para todas las funciones de membresía para cada

entrada que contenga el sistema difuso, como lo podemos ver en la figura 3.2.

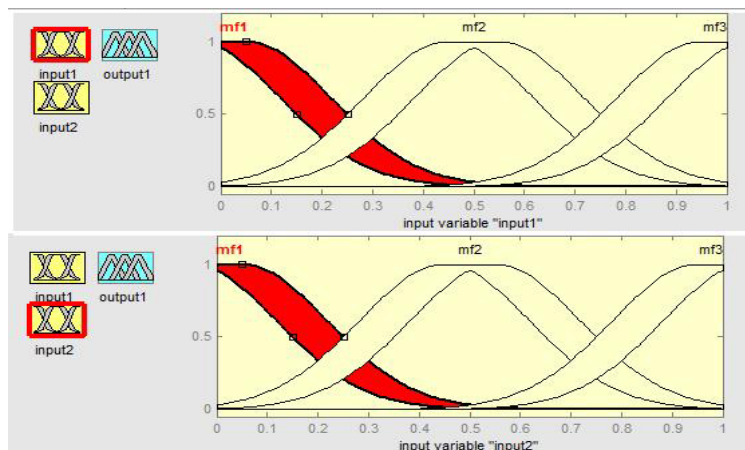


Figura 3.2. Ejemplificación de las funciones de membresía para el caso 1

- Para el segundo caso (Caso 2) se utiliza diferente valor de incertidumbre de las funciones de membresía para cada entrada., como lo podemos ver en la figura 3.3.

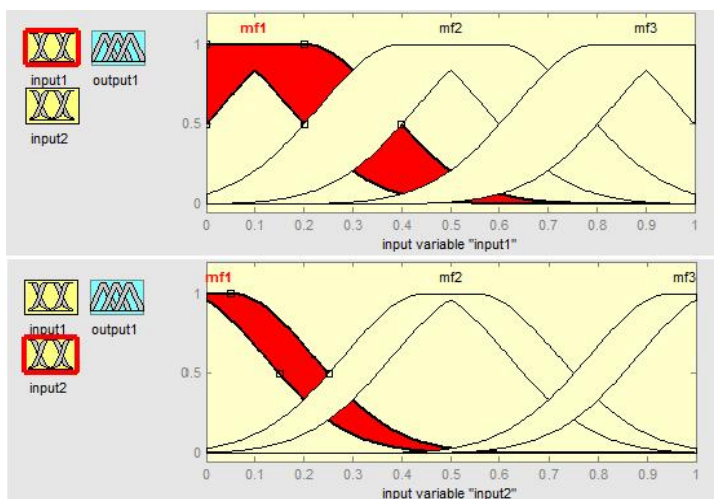


Figura 3.3. Ejemplificación de las funciones de membresía para el caso 2

- Para el tercer caso (Caso 3) se utiliza diferente valor de incertidumbre para cada función de membresía de cada entrada, tal como lo podemos ver en la figura 3.4.

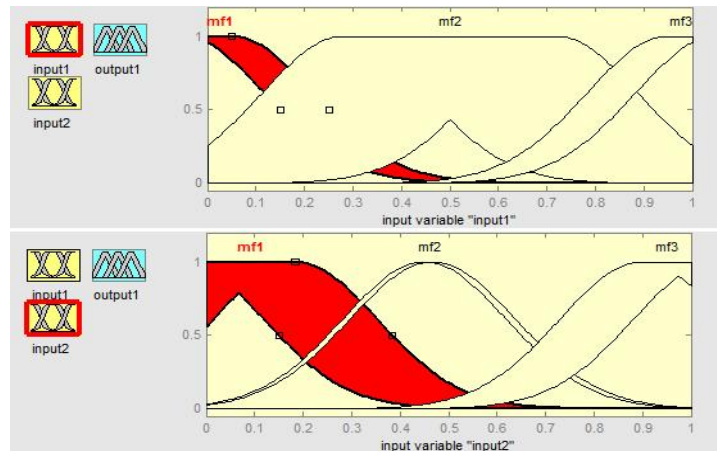


Figura 3.4. Ejemplificación de las funciones de membresía para el caso 3

Además se ha propuesto un índice para evaluar la aptitud de los sistemas difusos la cual es:

$$Index = \frac{N}{1+n \varepsilon} \quad \text{Ec. (3.1)}$$

Donde, N es el número de datos dentro del intervalo de salida entre el total de datos, n = número de incremento y ε = Valor de ampliación de las FM's.

3. Una vez que encontramos la incertidumbre de las funciones de membresía del sistema difuso tipo-2 nos dirigimos a hacer la comparación entre los resultados obtenidos para seleccionar el mejor, dándonos así el sistema de inferencia difusa tipo-2 optimo.

En la figura 3.5 podemos observar el esquema general que representa la estrategia propuesta explicada anteriormente, donde cabe resaltar el uso de algoritmos genéticos para su optimización.

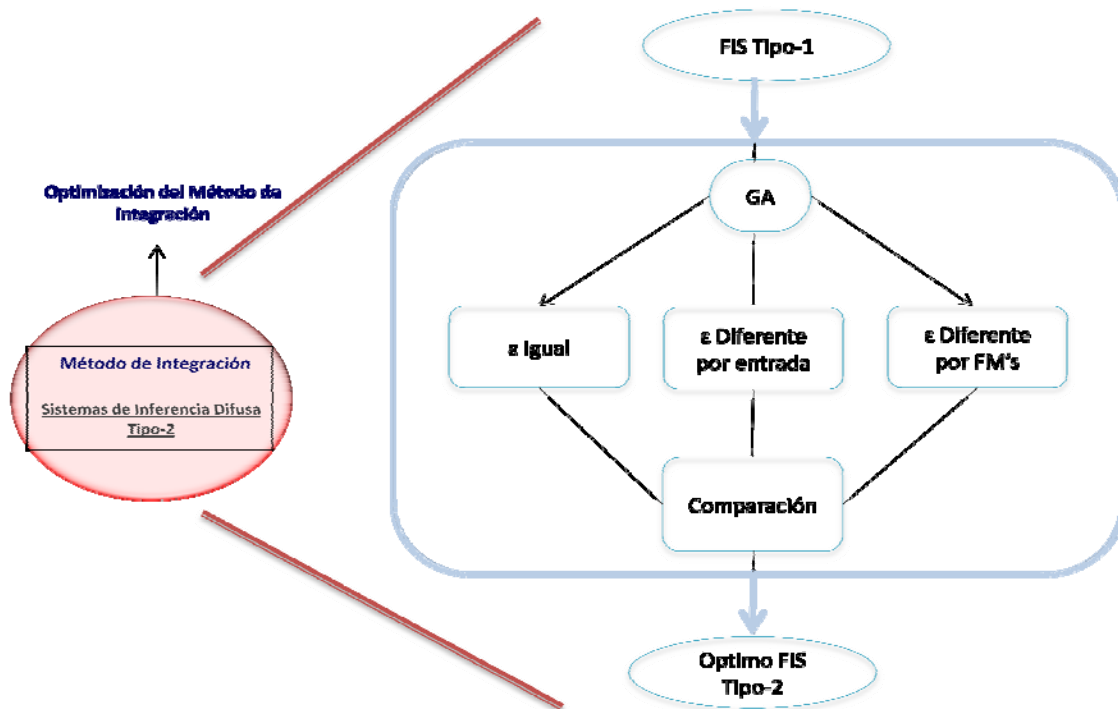


Figura 3.5. Esquema general de la estrategia propuesta para optimización de sistemas de inferencia difusa tipo-2 basado en el nivel de incertidumbre

Cabe mencionar que para éste desarrollo de tesis, inicialmente se hicieron pruebas para la estrategia propuesta de optimización con experimentos en los que se ejecutaban perturbaciones del valor épsilon manualmente y así estudiar los resultados que obteníamos con los diferentes casos benchmark utilizados y que se describen más adelante.

3.2. Estructura del Algoritmo Genético Propuesto

Para la optimización de la red neuronal como se mencionó anteriormente, se utilizaron algoritmos genéticos; en este caso jerárquico, para el cual se diseñó un cromosoma real con 18 bits de los cuales los tres primeros determinan las capas que tendrá cada módulo, y los 15 sobrantes determinarán las neuronas para cada capa. En la figura 3.6 podemos observar la estructura que muestra dicho cromosoma.

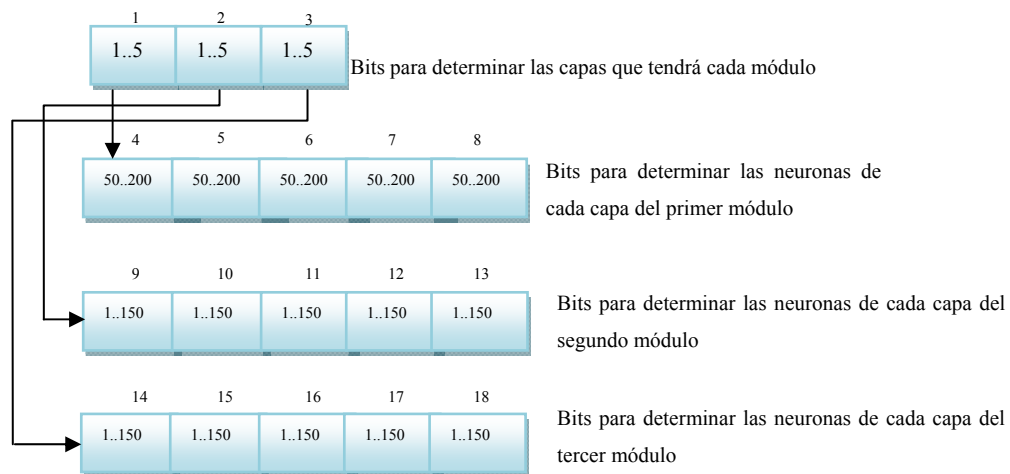


Figura 3.6. Representación del cromosoma para optimización de la arquitectura de la red

El desarrollo de nuestro proyecto de tesis se enfoca precisamente en la optimización de las funciones de membresía del método de integración basado en su incertidumbre. En la figura 3.7 podemos observar el cromosoma utilizado en el algoritmo genético.




Figura 3.7. Representación del cromosoma para optimización de integrador difuso

Dicho cromosoma, es un cromosoma real simple que está compuesto por 108 bits, de los cuales los primeros 36 bits determinarán los parámetros de las funciones de membresía generando así su incertidumbre para el caso 1; del bit 37 al 72 determinarán los parámetros de las funciones de membresía generando su incertidumbre para el caso 2, y por último del bit 73 al 108 determinarán los parámetros de las funciones de membresía generando su incertidumbre para el caso 3.

3.3. Casos Benchmark

A continuación se describen los casos benchmark utilizados en este proyecto de tesis, los cuales son: Predicción de MPG (Millas por Galón) de automóviles, Sistema de Identificación No-Lineal Box-Jenkins Gas Furnace (BJ) y Cancelación de Ruido Adaptativo (ANC).

3.3.1. Predicción de MPG (Millas por Galón) de automóviles:

El problema de Predicción de MPG (Millas por Galón) de automóviles es un problema de regresión no lineal, en el cual son usados varios atributos (variables de entrada) como el número de cilindros, desplazamiento, caballos de fuerza, peso, aceleración, Año del modelo; para predecir otro atributo (variable de salida) en este caso MPG. La base de datos original contiene 392 datos, se utilizaron los primeros 196 datos para entrenamiento y los otros 196 para prueba.

Jang J.-S.R. *et.al.* en [17] aborda la cuestión de selección de entradas; para encontrar las variables de entradas más importantes para ANFIS y reducir la dimensión de los datos para el entrenamiento, se encontró el mejor sistema de inferencia difuso con las variables Peso y Año del Modelo como variables de entrada, obteniendo el mínimo error cuadrático medio de prueba. De dichos resultados nos basamos para obtener el sistema de inferencia difusa tipo-2 como base para perturbar el valor ϵ en las funciones de membresía con las dos variables más significativas y reduciendo los datos de entrada para el entrenamiento en primera instancia.

3.3.2. Sistema de Identificación No-Lineal Box-Jenkins Gas Furnace (BJ)

Se utilizaron los datos del horno de gas conocido como Box-Jenkins. Esta es una serie de tiempo de datos para un proceso de horno de gas con un ritmo de flujo de gas $u(t)$ como entrada al horno y concentración CO_2 $y(t)$ como salida del horno. Se busca predecir $y(t)$. Se tienen 10 entradas candidatas para ANFIS: $y(t-1)$, $y(t-2)$, $y(t-$

3), $y(t-4)$, $u(t-1)$, $u(t-2)$, $u(t-3)$, $u(t-4)$, $u(t-5)$, $u(t-6)$. La base de datos original contiene 290 $[u(t), y(t)]$ pares de datos. Se utilizaron los primeros 145 datos para entrenamiento y los otros 145 para prueba.

Jang J.-S.R. *et.al.* en [17] aborda este problema y encuentra que con las variables de entrada $y(t-1)$ y $u(t-3)$ para ANFIS se encuentra el mejor sistema difuso obteniendo el mínimo error cuadrático medio de prueba. De dichos resultados nos basamos para obtener el sistema de inferencia difusa tipo-2 como base para perturbar el valor ϵ en las funciones de membresía con las dos variables más significativas y reduciendo los datos de entrada para el entrenamiento.

3.3.3. Cancelación de Ruido Adaptivo (ANC)

El objetivo de la cancelación de ruido adaptivo es filtrar la salida como componente de interferencia identificado en un modelo lineal entre el ruido medido de origen y la interferencia no medida.

La cancelación del ruido adaptivo usando filtros lineales ha sido usado exitosamente en aplicaciones del mundo real tal como la cancelación de la interferencia en los electrocardiogramas [17].

3.4. Red Neuronal Modular para Biometría Multimodal

La red neuronal modular utilizada para este proyecto, es entrenada para realizar el reconocimiento de personas a través las 3 medidas biométricas más importantes utilizadas actualmente en el campo del reconocimiento de patrones, rostro, huella y voz. En la Fig. 3.8 se puede apreciar gráficamente la estructura de nuestra red.

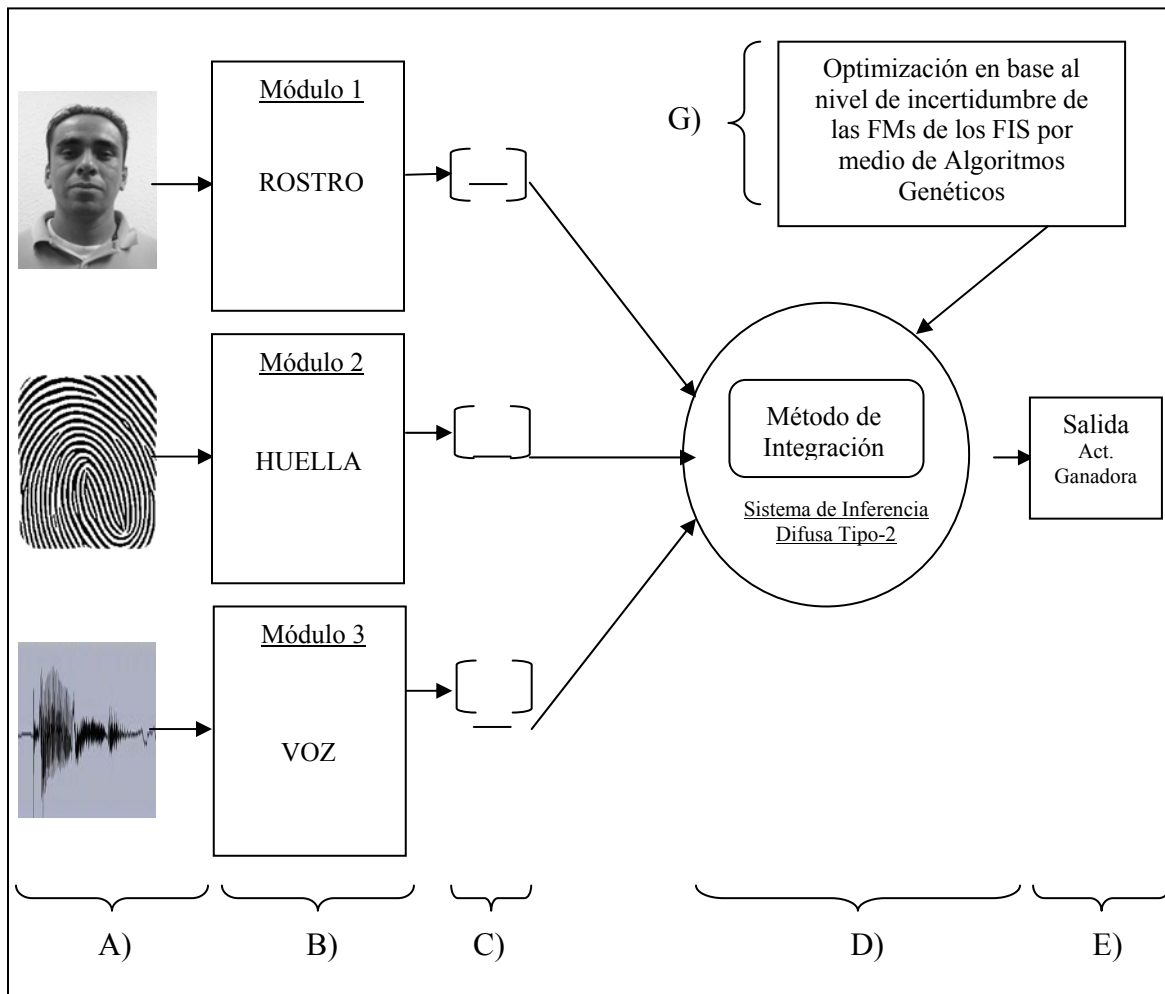


Fig.3.8. Esquema de la red neuronal modular para biometría multimodal

A continuación se presenta una breve explicación de cada uno de los puntos que se marcan en la figura anterior.

3.4.1. A) Datos De Entrada

En este punto se visualizan los datos que fueron utilizados para llevar a cabo el entrenamiento de la red neuronal modular. Dichos datos de entrada son los siguientes:

Rostro: Se utilizaron imágenes del rostro de 30 personas diferentes, para realizar el entrenamiento sin ruido, además de utilizar 30 imágenes del rostro de estas mismas personas

pero con diferente gesto, para utilizarlas en el entrenamiento con ruido [16]. Dichas imágenes se muestran en la Fig. 3.9.



Fig.3.9. Base de Datos utilizada para el entrenamiento de rostros

Huella: Se utilizaron imágenes de la huella dactilar de 30 personas diferentes, para realizar el entrenamiento sin ruido, y se les agregó a estas mismas, ruido aleatorio para utilizarlas en el entrenamiento con ruido [16]. Estas imágenes se muestran en la Fig. 3.10.




Fig.3.10. Base de Datos utilizada para el entrenamiento de huellas

Voz: Para el entrenamiento del módulo de voz se utilizó una palabra por persona, al igual que en el entrenamiento para rostros, en el entrenamiento para voz se tomaron muestras de voces de 30 personas diferentes. Las palabras utilizadas para los entrenamientos fueron: Accesar, Hola y Presentación donde algunas personas dijeron la palabra Accesar, otras Hola y algunas otras la palabra Presentación, cabe mencionar que a estas mismas se les agregó ruido aleatorio para llevar a cabo el entrenamiento con ruido [16].

3.4.2. B) Módulos De La RNM Para Los Entrenamientos

La red neuronal modular que se entrenó para este proyecto cuenta con tres módulos, uno para rostro, otro para huella y por último el utilizado para voz, cada uno de los tres módulos cuenta con tres submódulos, es decir la arquitectura de los módulos se podría visualizar en la Fig 3.11.

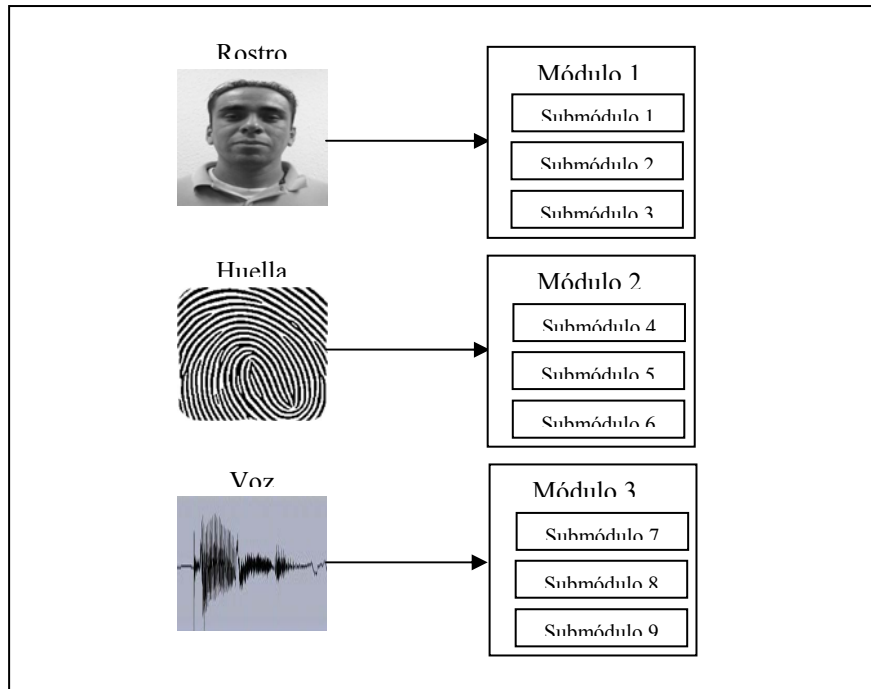


Fig.3.11. Arquitectura de la Red Neuronal para Entrenamiento

Cabe mencionar que para cada módulo entrenado y cada submódulo, se utilizó diferente arquitectura, es decir, diferente número de neuronas, capas, etc., para los diversos entrenamientos.

3.4.3. C) Salida De La Red Neuronal Modular (RNM)

La salida de la RNM es un vector que está conformado por 30 activaciones (en este caso porque la red ha sido entrenada con 30 personas diferentes) las cuales son calculadas después de haber simulado la Red una vez que esta ha sido entrenada.

3.4.4. D) Integración De La RNM (Sistemas de Inferencia Difusa Tipo-2)

En esta parte, una vez obtenidas las activaciones ganadoras para cada módulo, se ingresan al sistema de inferencia difuso, en el cual se evalúan dichas activaciones y

dependiendo de las características del sistema difuso, se obtuvo un resultado de salida final, el cual nos dirá cual es el módulo ganador.

3.4.5. E) Optimización De Los Sistemas Difusos en base a la Incertidumbre de sus Funciones de Membresía por Medio de Algoritmos Genéticos

La optimización de los sistemas difusos consiste en, como su nombre lo indica, optimizar las funciones de membresía de los sistemas difusos de tipo-2 en base a su nivel de incertidumbre con algoritmos genéticos.

3.4.6. F) Salida Final (Activación Ganadora)

El resultado del sistema difuso nos dirá a que módulo pertenece, una vez obtenida esta información se podrá saber que persona ha sido reconocida.

4. RESULTADOS

Inicialmente es importante exponer que se realizaron diversas pruebas en integración difusa tipo-1 y tipo-2 para redes neuronales modulares para biometría multimodal donde se comprobó la eficacia de tipo-2 para este tipo de problemas; es por eso que trabajamos con integración difusa tipo-2 [9][11]. Por dichos trabajos realizados nos interesamos en particular, por la optimización de sistemas difusos tipo-2 en base a su nivel de incertidumbre como integradores de respuesta de la red neuronal modular [7] [8].

4.1. Optimización de Sistemas Difusos Tipo-2 basados en el Nivel de Incertidumbre

Primeramente se trabajó con diferentes casos benchmark para obtener resultados preliminares, en donde, se hicieron pruebas perturbando ϵ manualmente, dichos resultados se muestran a continuación. Cabe mencionar que para realizar este trabajo de tesis se utilizó la toolbox de lógica tipo-2 por intervalos [3] [4].

4.1.1. Resultados con Benchmark MPG perturbando incertidumbre manualmente

Los experimentos los iniciamos con el benchmark de predicción de MPG de automóviles descrito anteriormente [10][12]; para el Caso 1 de la estrategia propuesta donde el valor de ϵ es igual para todas las funciones de membresía de todas las entradas, se obtuvieron 20 sistemas difusos como integradores; empezamos con un sistema base y fuimos incrementando el valor de ϵ en un 10% y evaluarlos, ya que perturbando el valor de ϵ vamos aumentando la incertidumbre de sus funciones de membresía y así hasta obtener el tipo-2 óptimo; en la Tabla 1 se pueden observar los resultados obtenidos.

Para el Caso 2, donde el incremento de ϵ lo hacemos por cada entrada se perturbó con un incremento de 30% para las funciones de membresía de la primera entrada y un 10% para las funciones de membresía de la segunda entrada, los resultados obtenidos se muestran en la Tabla 2.

Para el Caso 3, donde el incremento de ϵ lo hacemos para cada una de las funciones de membresía en cada entrada, se perturbó dicha ϵ en un 15%, 5%, 10% y 20% respectivamente en cada función de membresía y los resultados los podemos visualizar en la Tabla 3.

Hemos propuesto un índice para evaluar el fitness de los sistemas difusos (ver Ec. 3.1) donde:

N = Datos dentro del intervalo de salida entre el total de datos de salida; n = número de sistemas difusos y ϵ = Valor de incremento de incertidumbre de las funciones de membresía.

Tabla 4.1. Resultados obtenidos para Caso 1 donde es igual valor de incertidumbre en un 10% (MPG).

No.	N	n	Epsilon (ϵ)	Index	Datos dentro del Intervalo de salida
Base	0.3418	20	0	0.11	67/192
1	0.602	20	0.1	0.2	118/192
2	0.7296	20	0.2	0.24	143/192
3	0.7857	20	0.3	0.26	154/192
4	0.7908	20	0.4	0.26	155/192
5	0.8061	20	0.5	0.27	158/192
6	0.8265	20	0.6	0.28	162/192
7	0.8469	20	0.7	0.28	166/192
8	0.8571	20	0.8	0.29	168/192
9	0.8571	20	0.9	0.29	168/192
10	0.8622	20	1.0	0.29	169/192
11	0.8622	20	1.1	0.29	169/192
12	0.8622	20	1.2	0.29	169/192
13	0.8622	20	1.3	0.29	169/192
14	0.8622	20	1.4	0.29	169/192
15	0.8622	20	1.5	0.29	169/192
16	0.8622	20	1.6	0.29	169/192
17	0.8622	20	1.7	0.29	169/192
18	0.8622	20	1.8	0.29	169/192
19	0.8673	20	1.9	0.29	170/192
20	0.8673	20	2.0	0.29	170/192

Tabla 4.2. Resultados obtenidos para Caso 2 donde es diferente valor de incertidumbre por entrada en un 30% en la primer entrada y un 10% en la segunda entrada (MPG).

No.	N	n	Epsilon (ϵ)	Index	Datos dentro del Intervalo de salida
Base	0.3418	20	0	0.07	67/192
1	0.6531	20	0.2	0.13	128/192
2	0.7602	20	0.4	0.15	149/192
3	0.8214	20	0.6	0.16	161/192
4	0.852	20	0.8	0.17	167/192
5	0.8571	20	1.0	0.17	168/192
6	0.8622	20	1.2	0.17	169/192
7	0.8622	20	1.4	0.17	169/192
8	0.8622	20	1.6	0.17	169/192
9	0.8622	20	1.8	0.17	169/192
10	0.8673	20	2.0	0.17	170/192
11	0.8827	20	2.2	0.18	173/192
12	0.8929	20	2.4	0.18	175/192
13	0.8827	20	2.6	0.18	173/192
14	0.8622	20	2.8	0.17	169/192
15	0.8469	20	3.0	0.17	166/192
16	0.8469	20	3.2	0.17	166/192
17	0.8469	20	3.4	0.17	166/192
18	0.8469	20	3.6	0.17	166/192
19	0.8469	20	3.8	0.17	166/192
20	0.8469	20	4.0	0.17	166/192

Tabla 4.3. Resultados obtenidos para Caso 3 donde es diferente valor de incertidumbre por función de membresía en un 15% y 5% respectivamente en la primer entrada y un 10% y 20% respectivamente en la segunda entrada (MPG).

No.	N	n	Epsilon (ϵ)	Index	Datos dentro del Intervalo de salida
Base	0.3418	20	0	0.1	67/192
1	0.6582	20	0.125	0.19	129/192
2	0.7602	20	0.25	0.22	149/192
3	0.7959	20	0.375	0.23	156/192
4	0.8112	20	0.5	0.23	159/192
5	0.8418	20	0.625	0.24	165/192
6	0.852	20	0.75	0.24	167/192
7	0.8571	20	0.875	0.24	168/192
8	0.8571	20	1	0.24	168/192
9	0.8571	20	1.125	0.24	168/192
10	0.8622	20	1.25	0.25	169/192
11	0.8622	20	1.375	0.25	169/192
12	0.8622	20	1.5	0.25	169/192
13	0.8622	20	1.625	0.25	169/192
14	0.8724	20	1.75	0.25	171/192
15	0.8724	20	1.875	0.25	171/192
16	0.8878	20	2	0.25	174/192
17	0.8673	20	2.125	0.25	170/192
18	0.8571	20	2.25	0.24	168/192
19	0.8469	20	2.375	0.24	166/192
20	0.8469	20	0.125	0.24	166/192

En los tres casos el objetivo es encontrar el mayor número de datos dentro del intervalo de salida pero con el menor índice, es decir, menor incertidumbre. Por lo que en la tabla 1 podemos resaltar el FIS 20 con el mayor número de puntos dentro del intervalo con un menor índice. En la tabla 2 podemos resaltar el FIS 12 con el mayor número de puntos dentro del intervalo con un menor índice. Y en la tabla 3 podemos resaltar el FIS 16 con el mayor número de puntos dentro del intervalo con un menor índice. A continuación, en la figura 4.1, se presenta la gráfica donde se plasman los resultados mostrados en las tablas 1, 2 y 3.

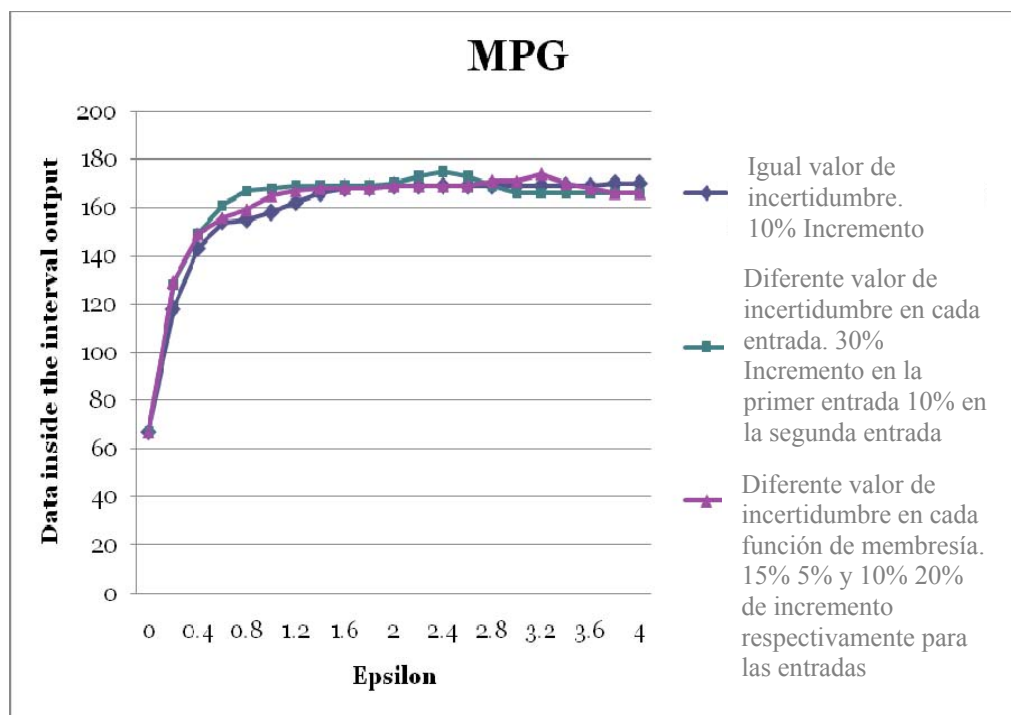


Figura 4.1. Resultados obtenidos para predicción de MPG con perturbación manual de ϵ

En la figura anterior, podemos observar que en el caso 2 se obtuvo el mayor número de datos dentro del intervalo de salida; sin embargo lo que nos interesa en encontrar el mayor número de datos dentro del intervalo pero con el menor ϵ , penalizando entonces con la incertidumbre si no es tan significativa la diferencia entre el valor de los datos dentro del intervalo de salida. Por lo que para estos experimentos podemos decir que el caso 3, donde la incertidumbre de las funciones de membresía es diferente para cada una de ellas, es nuestro mejor resultado; ya que se obtuvieron 174 datos dentro del intervalo de salida con ϵ de 2; y podemos determinar que manejando una huella de incertidumbre distinta para cada función de membresía obtenemos mejores resultados.

En las siguientes figuras (4.2, 4.3 y 4.4) se muestran como quedaron las funciones de membresía de los mejores sistemas difusos obtenidos para cada caso en MPG.

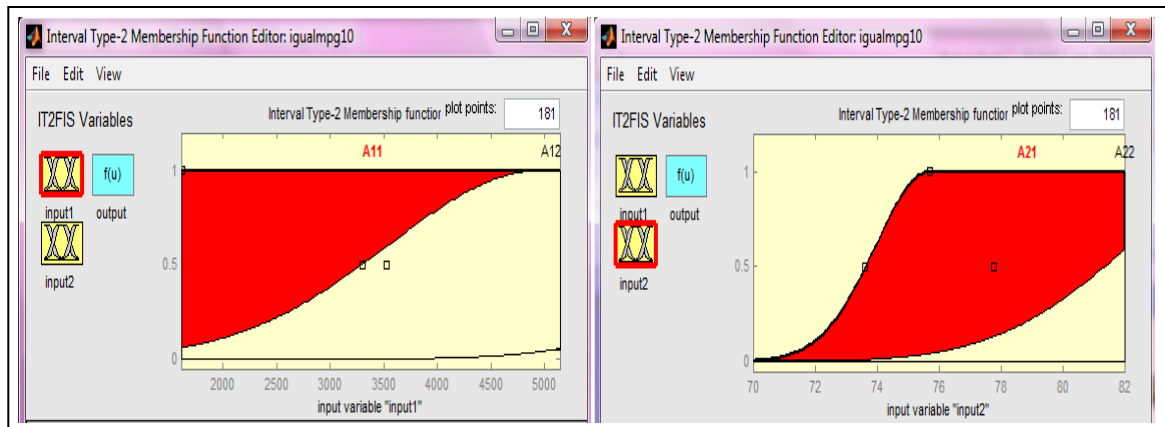


Figura 4.2. Huella de incertidumbre para las funciones de membresía del mejor sistema difuso para el caso1 de MPG.

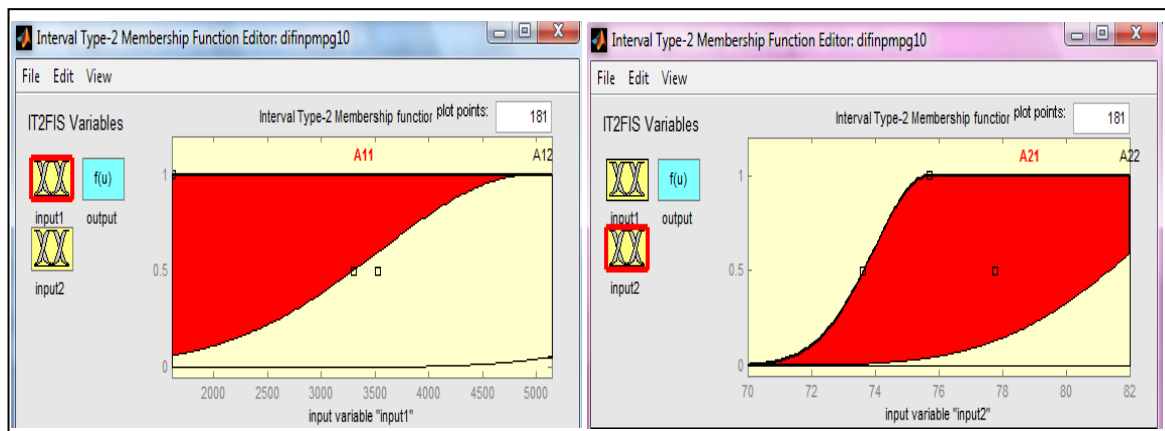


Figura 4.3. Huella de incertidumbre para las funciones de membresía del mejor sistema difuso para el caso2 de MPG.

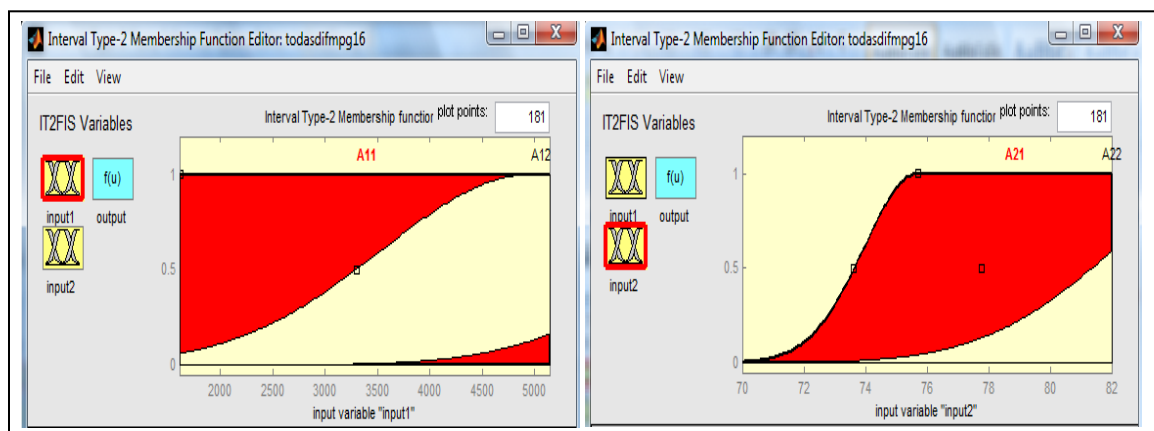


Figura 4.4. Huella de incertidumbre para las funciones de membresía del mejor sistema difuso para el caso3 de MPG.

4.1.2. Resultados con Benchmark BJ perturbando incertidumbre manualmente

Después de haber trabajado con el benchmark de predicción de MPG de automóviles; se continuó con el de Sistema de Identificación No-Lineal donde se utilizan los datos del horno de gas conocido como Box-Jenkins Gas Furnace (BJ) [14].

Para el Caso 1 de la estrategia propuesta, al igual que en MPG, se obtuvieron 20 sistemas difusos como integradores; empezamos con un sistema base y fuimos incrementando el valor de ϵ en un 0.5% y evaluarlos; en la Tabla 4 se pueden observar los resultados obtenidos.

Para el Caso 2, donde el incremento de ϵ lo hacemos por cada entrada se perturbó con un incremento de 0.1% para las funciones de membresía de la primera entrada y un 0.3% para las funciones de membresía de la segunda entrada, los resultados obtenidos se muestran en la Tabla 5.

Para el Caso 3, donde el incremento de ϵ lo hacemos para cada una de las funciones de membresía en cada entrada, se perturbó dicha ϵ en un 0.2%, 0.5%, 0.3% y 0.1% respectivamente en cada función de membresía y los resultados los podemos visualizar en la Tabla 6.

Tabla 4.4. Resultados obtenidos para Caso 1 donde es igual valor de incertidumbre en un 0.5% (BJ).

	N	n	Epsilon	Index	Datos dentro del Intervalo de salida
Base	0.3724	20	0.005	0.34	54/145
1	0.9517	20	0.01	0.87	138/145
2	0.9655	20	0.015	0.88	140/145
3	0.9655	20	0.02	0.88	140/145
4	0.9724	20	0.025	0.88	141/145

5	0.9931	20	0.03	0.90	144/145
6	0.9931	20	0.035	0.90	144/145
7	1.0000	20	0.04	0.91	145/145
8	1.0000	20	0.045	0.91	145/145
9	1.0000	20	0.05	0.91	145/145
10	1.0000	20	0.055	0.91	145/145
11	1.0000	20	0.06	0.91	145/145
12	1.0000	20	0.065	0.91	145/145
13	1.0000	20	0.07	0.91	145/145
14	1.0000	20	0.075	0.91	145/145
15	1.0000	20	0.08	0.91	145/145
16	1.0000	20	0.085	0.91	145/145
17	1.0000	20	0.09	0.91	145/145
18	1.0000	20	0.095	0.91	145/145
19	1.0000	20	0.1	0.91	145/145
20	1.0000	20	0.105	0.91	145/145

Tabla 4.5. Resultados obtenidos para Caso 2 donde es diferente valor de incertidumbre por entrada en un 0.1% en la primer entrada y un 0.3% en la segunda entrada (BJ).

	N	n	Epsilon	Index	Datos dentro del Intervalo de salida
Base	0.3724	20	0.002	0.36	54/145
1	0.9724	20	0.004	0.94	141/145
2	0.9931	20	0.006	0.95	144/145
3	1	20	0.008	0.96	145/145
4	1	20	0.01	0.96	145/145
5	1	20	0.012	0.96	145/145
6	1	20	0.014	0.96	145/145
7	1	20	0.016	0.96	145/145

8	1	20	0.018	0.96	145/145
9	1	20	0.02	0.96	145/145
10	1	20	0.022	0.96	145/145
11	1	20	0.024	0.96	145/145
12	1	20	0.026	0.96	145/145
13	1	20	0.028	0.96	145/145
14	1	20	0.03	0.96	145/145
15	1	20	0.032	0.96	145/145
16	1	20	0.034	0.96	145/145
17	1	20	0.036	0.96	145/145
18	1	20	0.038	0.96	145/145
19	1	20	0.04	0.96	145/145
20	1	20	0.042	0.96	145/145

Tabla 4.6. Resultados obtenidos para Caso 3 donde es diferente valor de incertidumbre por función de membresía en un 0.2% y 0.5% respectivamente en la primer entrada y un 0.3% y 0.1% respectivamente en la segunda entrada.

	N	n	Epsilon	Index	Datos dentro del Intervalo de salida
Base	0.3724	20	0.00275	0.35	54/145
1	0.9517	20	0.0055	0.9	138/145
2	0.9655	20	0.00825	0.92	140/145
3	0.9655	20	0.011	0.92	140/145
4	0.9655	20	0.01375	0.92	140/145
5	0.9724	20	0.0165	0.92	141/145
6	0.9862	20	0.01925	0.93	143/145
7	0.9931	20	0.022	0.94	144/145
8	0.9931	20	0.02475	0.94	144/145

9	0.9931	20	0.0275	0.94	144/145
10	1	20	0.03025	0.95	145/145
11	1	20	0.033	0.95	145/145
12	1	20	0.03575	0.95	145/145
13	1	20	0.0385	0.95	145/145
14	1	20	0.04125	0.95	145/145
15	1	20	0.044	0.95	145/145
16	1	20	0.04675	0.95	145/145
17	1	20	0.0495	0.95	145/145
18	1	20	0.05225	0.95	145/145
19	1	20	0.055	0.95	145/145
20	1	20	0.05775	0.95	145/145

En este caso pudimos observar que el problema en sí es sencillo, por lo que no se justificaría utilizar sistemas difusos tipo-2; sin embargo, nos dimos cuenta que en el caso 2; donde las funciones de membresía son iguales por entrada, éste se comportó mejor.

A continuación se presenta en la figura 4.5, la gráfica donde observamos los resultados mostrados en las tablas 4, 5 y 6.

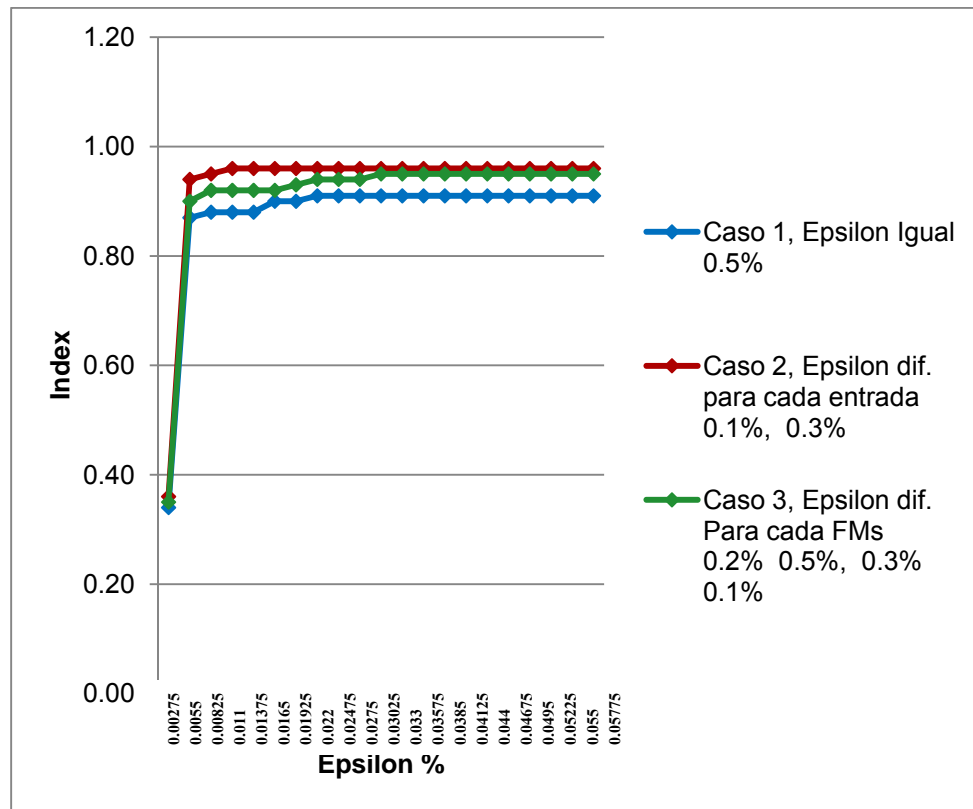


Figura 4.5. Resultados obtenidos para Box-Jenkins con perturbación manual de ϵ

En las siguientes figuras (4.6, 4.7 y 4.8) se muestran las funciones de membresía de los mejores sistemas difusos obtenidos para el caso 1, caso 2 y caso 3 de BJ.

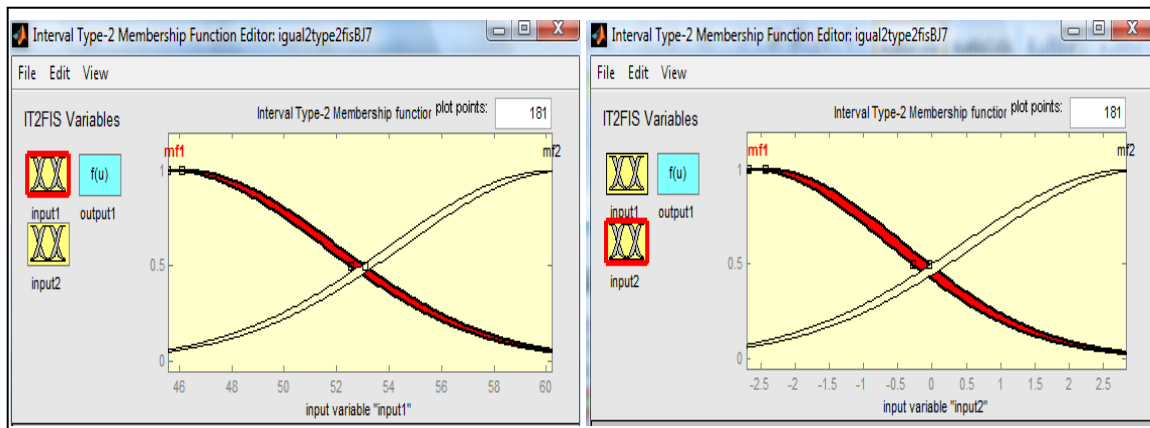


Figura 4.6. Huella de incertidumbre para las funciones de membresía del mejor sistema difuso para el caso1 de BJ.

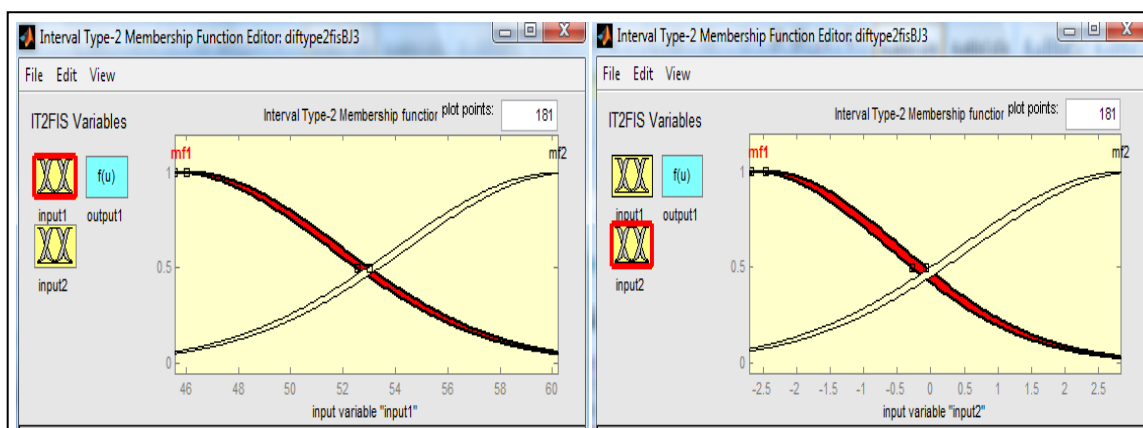


Figura 4.7. Huella de incertidumbre para las funciones de membresía del mejor sistema difuso para el Caso2 de BJ.

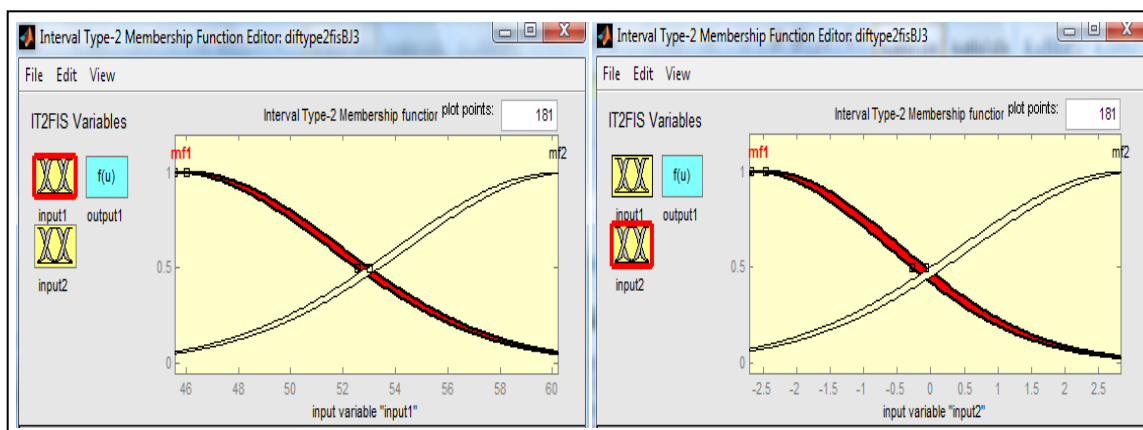


Figura 4.8. Huella de incertidumbre para las funciones de membresía del mejor sistema difuso para el Caso3 de BJ.

Se puede notar en las figuras anteriores que para éste caso benchmark en particular, no ocupamos tener mucha incertidumbre en nuestras funciones de membresía, es decir, podemos hacerle frente a nuestro problema con sistemas difusos tipo-1.

4.1.3. Resultados con Benchmark ANC perturbando incertidumbre manualmente

Luego de trabajar con MPG y BJ, y observar sus resultados; se continuó con otro benchmark llamado Cancelación de Ruido Adaptivo (ANC) [13]. El objetivo de la cancelación de ruido adaptivo es filtrar la salida como componente de interferencia identificado en un modelo lineal entre el ruido medido de origen y la interferencia no medida.

La cancelación del ruido adaptivo usando filtros lineales ha sido usada exitosamente en aplicaciones del mundo real tal como la cancelación de la interferencia en los electrocardiogramas.

Para trabajar en con este benchmark, se obtuvieron 20 sistemas difusos como integradores; para el caso 1 iniciamos con un sistema base y fuimos incrementando el valor de ϵ en un 10% y evaluarlos; en la Tabla 7 se pueden observar los resultados obtenidos.

Para el Caso 2, donde el incremento de ϵ lo hacemos por cada entrada se perturbó con un incremento de 40% para las funciones de membresía de la primera entrada y un 20% para las funciones de membresía de la segunda entrada, los resultados obtenidos se muestran en la Tabla 8.

Para el Caso 3, donde el incremento de ϵ lo hacemos para cada una de las funciones de membresía en cada entrada, se perturbó dicha ϵ en un 15%, 30% , 20% y 5% respectivamente en cada función de membresía y los resultados los podemos visualizar en la Tabla 9.

Tabla 4.7. Resultados obtenidos para Caso 1 donde es igual valor de incertidumbre en un 10% (ANC).

	N	n	Epsilon	Index	Datos dentro del Intervalo de salida
Base	0.3794	20	0	0.13	228/601
1	0.5441	20	0.1	0.18	327/601
2	0.7388	20	0.2	0.25	444/601
3	0.8170	20	0.3	0.27	491/601
4	0.8353	20	0.4	0.28	502/601
5	0.8386	20	0.5	0.28	504/601
6	0.8469	20	0.6	0.28	509/601
7	0.8552	20	0.7	0.29	514/601
8	0.8686	20	0.8	0.29	522/601
9	0.8752	20	0.9	0.29	526/601
10	0.9085	20	1.0	0.30	546/601
11	0.9168	20	1.1	0.31	551/601
12	0.9218	20	1.2	0.31	554/601
13	0.9251	20	1.3	0.31	556/601
14	0.9251	20	1.4	0.31	556/601
15	0.9268	20	1.5	0.31	557/601
16	0.9285	20	1.6	0.31	558/601
17	0.9285	20	1.7	0.31	558/601
18	0.9285	20	1.8	0.31	558/601
19	0.9285	20	1.9	0.31	558/601
20	0.9285	20	2.0	0.31	558/601

Tabla 4.8. Resultados obtenidos para Caso 2 donde es diferente valor de incertidumbre por entrada en un 40% en la primer entrada y un 20% en la segunda entrada (ANC).

	N	n	Epsilon	Index	Datos dentro del Intervalo de salida
Base	0.3794	20	0	0.05	228/601
1	0.8236	20	0.3	0.12	495/601
2	0.8453	20	0.6	0.12	508/601
3	0.9185	20	0.9	0.13	552/601
4	0.9251	20	1.2	0.13	556/601
5	0.9285	20	1.5	0.13	558/601
6	0.9285	20	1.8	0.13	558/601
7	0.9285	20	2.1	0.13	558/601
8	0.9285	20	2.4	0.13	558/601
9	0.9285	20	2.7	0.13	558/601
10	0.9285	20	3	0.13	558/601
11	0.9285	20	3.3	0.13	558/601
12	0.9285	20	3.6	0.13	558/601
13	0.9285	20	3.9	0.13	558/601
14	0.9285	20	4.2	0.13	558/601
15	0.9285	20	4.5	0.13	558/601
16	0.9285	20	4.8	0.13	558/601
17	0.9285	20	5.1	0.13	558/601
18	0.9285	20	5.4	0.13	558/601
19	0.9285	20	5.7	0.13	558/601
20	0.9285	20	6.0	0.13	558/601

Tabla 4.9. Resultados obtenidos para Caso 3 donde es diferente valor de incertidumbre por función de membresía en un 15% y 30% respectivamente en la primer entrada y un 20% y 5% respectivamente en la segunda entrada.

No.	N	n	Epsilon	Index	Datos dentro
					del Intervalo
					de salida
Base	0.3794	20	0	0.05	228/601
1	0.7238	20	0.35	0.09	435/601
2	0.8186	20	0.7	0.10	492/601
3	0.8303	20	1.05	0.10	499/601
4	0.8436	20	1.4	0.11	507/601
5	0.8619	20	1.75	0.11	518/601
6	0.8852	20	2.1	0.11	532/601
7	0.9085	20	2.45	0.11	546/601
8	0.9218	20	2.8	0.12	554/601
9	0.9268	20	3.15	0.12	557/601
10	0.9285	20	3.5	0.12	558/601
11	0.9285	20	3.85	0.12	558/601
12	0.9285	20	4.2	0.12	558/601
13	0.9285	20	4.55	0.12	558/601
14	0.9285	20	4.9	0.12	558/601
15	0.9285	20	5.25	0.12	558/601
16	0.9285	20	5.6	0.12	558/601
17	0.9285	20	5.95	0.12	558/601
18	0.9285	20	6.3	0.12	558/601
19	0.9285	20	6.65	0.12	558/601
20	0.9285	20	7	0.12	558/601

En este problema podemos observar que se obtienen buenos resultados en los tres casos ya que se logra obtener 558 datos dentro del intervalo de salida de un total de 601 para este caso; sin embargo, lo que estamos buscando es obtener el mejor resultado con un menor ϵ , es decir, obtener el mejor resultado con la menor huella de incertidumbre. En este caso lo podemos observar en el caso 3, donde obtenemos 558 datos pero con un ϵ de 0.12.

En la figura 4.9, se muestra la gráfica donde observamos los resultados mostrados en las tablas 7, 8 y 9.

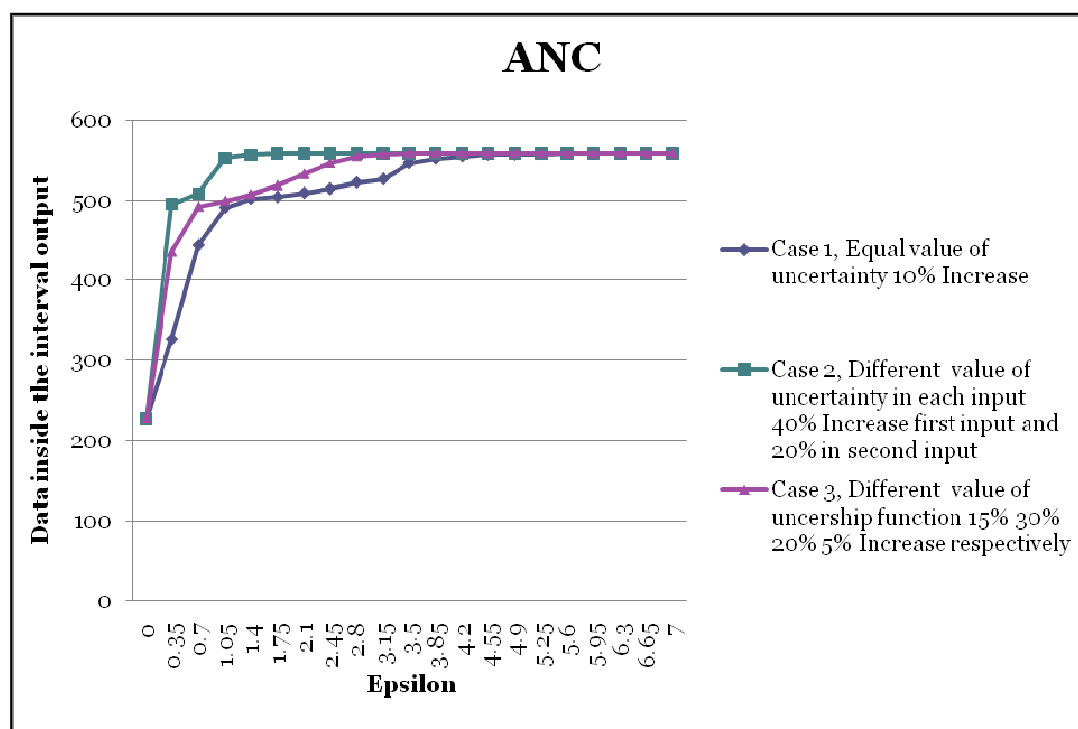


Figura 4.9. Resultados obtenidos para Cancelación de Ruido Adaptativo (ANC) con perturbación manual de ϵ

A continuación, en las figuras 4.10, 4.11 y 4.12 se muestran las funciones de membresía de los mejores sistemas difusos obtenidos para el caso 1, caso 2 y caso 3 de ANC.

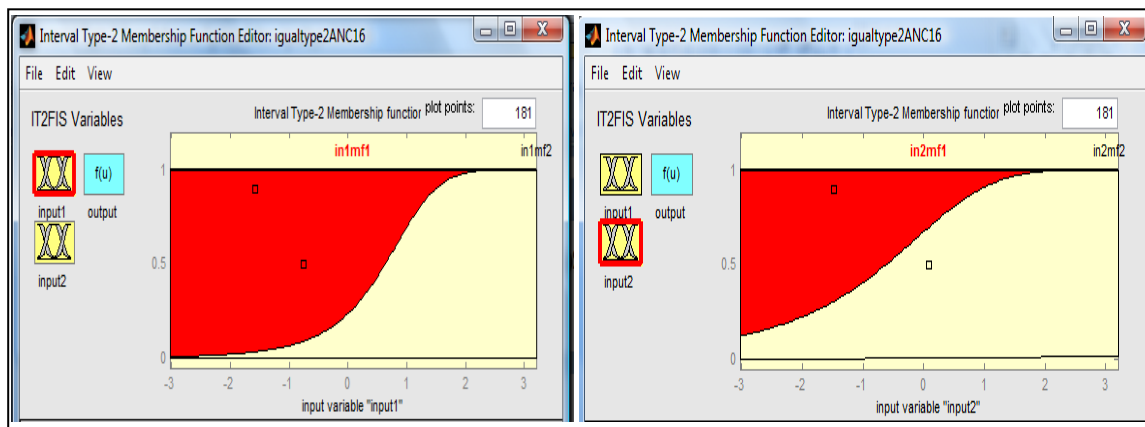


Figura 4.10. Huella de incertidumbre para las funciones de membresía del mejor sistema difuso para el Caso1 de ANC.

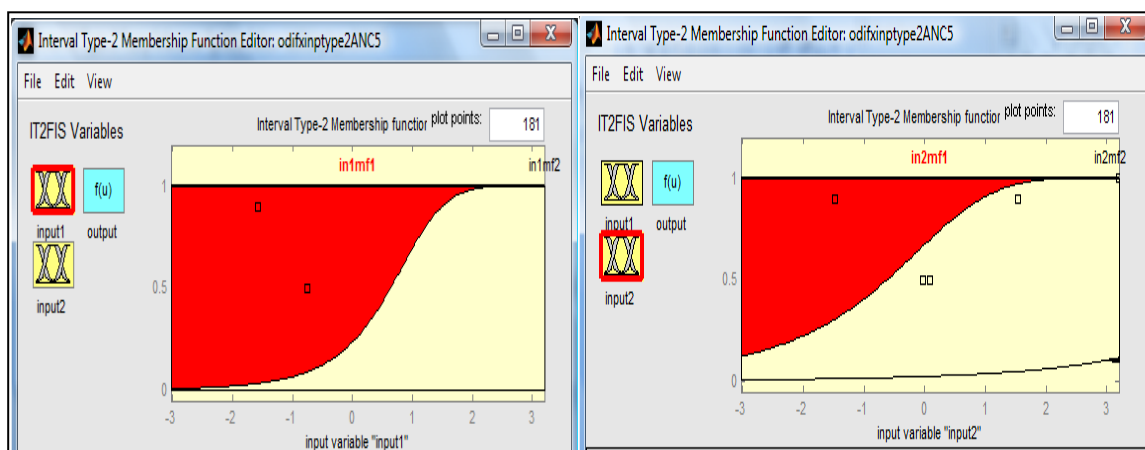


Figura 4.11. Huella de incertidumbre para las funciones de membresía del mejor sistema difuso para el Caso2 de ANC.

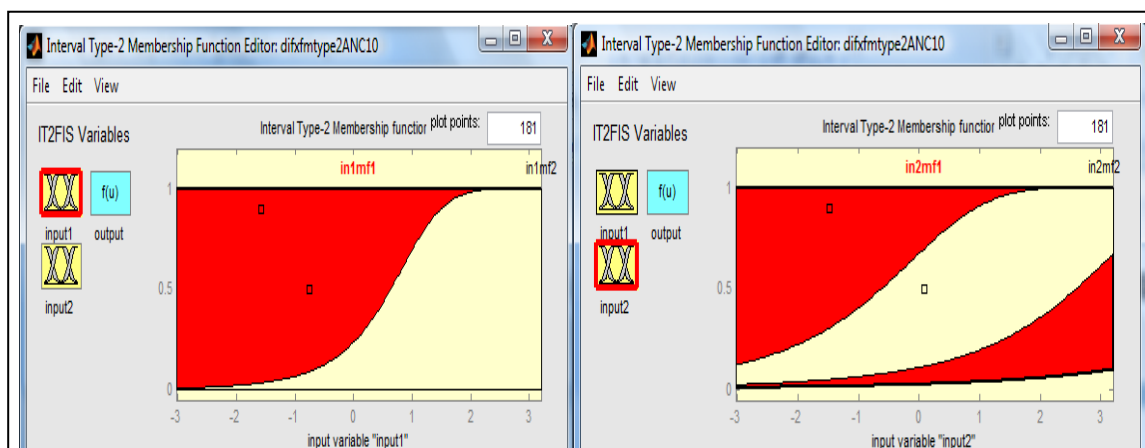


Figura 4.12. Huella de incertidumbre para las funciones de membresía del mejor sistema difuso para el Caso3 de ANC.

En las figuras anteriores podemos observar que este problema es un poco complejo, por lo que se ocupa mayor huella de incertidumbre que el problema BJ.

Visto lo anterior, se procedió a utilizar algoritmos genéticos utilizando el problema de cancelación de ruido (ANC) ya que es un problema complejidad avanzada.

4.1.4. Pruebas iniciales de optimización basada en incertidumbre utilizando benchmark ANC

Para la optimización de los sistemas difusos basados en su incertidumbre; a diferencia con la estructura propuesta mostrada en la figura 3.6 donde se busca que un solo algoritmo genético sea utilizado para esto, iniciamos primeramente con la estructura mostrada en la figura 4.13, donde se puede observar que tenemos tres algoritmos genéticos por separado para cada uno de los tres casos de incertidumbre propuestos.

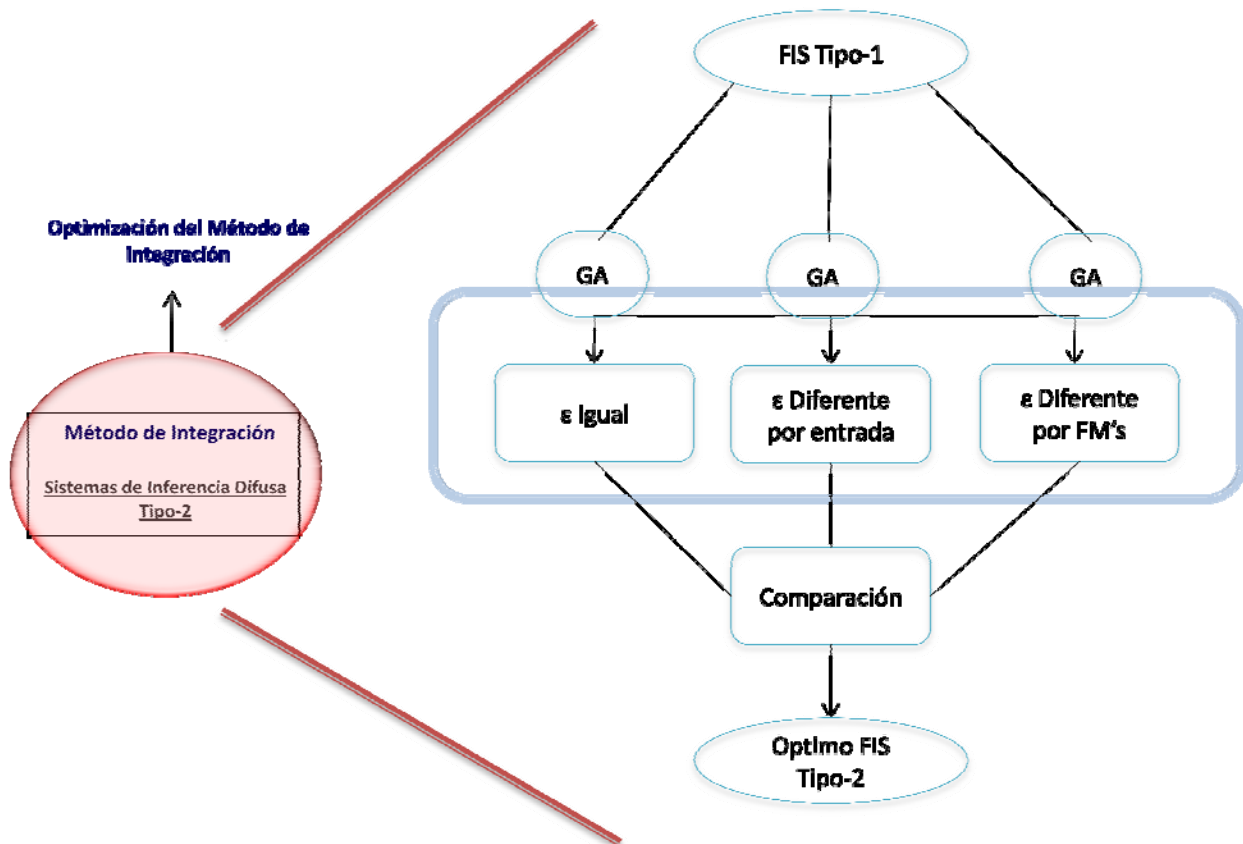


Figura 4.13. Estructura inicial para pruebas de optimización basada en incertidumbre

Como se mencionó anteriormente; con el algoritmo genético se inició probando por separado un AG para cada caso dentro de su estructura con el benchmark ANC, y se obtuvieron los resultados que a continuación se describen.

En la tabla 10 se muestran los resultados obtenidos para el caso 1 donde el valor de incertidumbre (épsilon) es igual para todas las funciones de membresía de cada entrada; la tabla 11 muestra los resultados obtenidos para el caso 1 donde el valor de la incertidumbre es igual por entrada; y por último, en la tabla 12 se pueden observar los resultados del caso 3 donde el valor de épsilon varía para cada función de incertidumbre de cada entrada. Las tablas anteriormente mencionadas se muestran a continuación.

Tabla 4.10. Resultados obtenidos para Caso 1 donde es igual valor de incertidumbre (Épsilon).

No.	Individuos	Generación	Mutación	Cruce	Tiempo de Ejecución	Epsilon	Datos dentro el intervalo de Salida
1	80	100	0.1	0.4	1:50:28	1.00183	524/601
2	150	200	0.3	0.7	6:36:42	1	525/601
3	100	100	0.001	0.5	2:13:45	1.02672	526/601
4	40	50	0.8	0.9	0:55:31	1	529/601
5	30	30	0.5	0.6	0:12:26	1.00441	530/601
6	50	50	1	1	0:33:36	1.00355	530/601
7	60	30	0.4	0.85	0:46:34	1	538/601
8	35	30	0.95	1	0:26:21	1	552/601
9	25	30	0.8	1	0:19:02	1	556/601
10	15	100	1	1	0:20:36	1	564/601
11	10	100	0.9	1	0:13:20	1	565/601
12	10	30	0.6	0.8	0:08:18	1.502	579/601
13	5	30	0.7	0.9	0:04:04	2	597/601
14	20	30	0.5	0.7	0:16:09	2	600/601
15	15	30	0.35	0.85	0:12:11	3.4934	601/601

Como podemos observar en la tabla anterior, obtuvimos el mejor resultado con todos los datos dentro del intervalo de salida con una estructura del AG de 15 individuos, 30 generaciones, 0.35 de mutación, 0.85 de cruce una inertidumbre de 3.4934 y en un tiempo de 12 min y 11 segundos.

Tabla 4.11. Resultados obtenidos para Caso 2 donde el valor de incertidumbre (Épsilon) es diferente por entrada.

No.	Individuos	Generación	Mutación	Cruce	Tiempo de Ejecución	Epsilon 1er Entrada	Epsilon Segunda Entrada	Datos dentro el intervalo de Salida
1	80	100	0.1	0.4	0:50:58	1.500	1.500	584/601
2	150	200	0.3	0.7	3:09:31	2.000	1.663	597/601
3	100	100	0.001	0.5	1:08:40	1.505	1.501	580/601
4	40	50	0.8	0.9	0:25:55	1.300	2.693	572/601
5	30	30	0.5	0.6	0:11:48	2.000	1.000	598/601
6	50	50	1	1	0:33:17	2.064	1.061	599/601
7	60	30	0.4	0.85	0:15:25	2.000	3.459	597/601
8	35	30	0.95	1	0:13:28	2.000	2.000	597/601
9	25	30	0.8	1	0:09:44	1.500	2.500	597/601
10	15	100	1	1	0:10:09	2.000	1.167	599/601
11	10	100	0.9	1	0:06:37	1.500	1.520	588/601
12	10	30	0.6	0.8	0:04:07	1.000	1.000	593/601
13	5	30	0.7	0.9	0:01:57	1.001	1.000	582/601
14	20	30	0.5	0.7	0:07:56	2.000	1.534	601/601
15	15	30	0.35	0.85	0:05:45	1.000	1.500	567/601

En la tabla 11, podemos observar en que el mejor resultado lo obtuvimos con una estructura del AG de 20 individuos, 30 generaciones, 0.5 de mutación, 0.7 de cruce, una incertidumbre de 1.767 y en un tiempo de 7 min y 56 segundos.

Tabla 4.12. Resultados obtenidos para Caso 3 donde el valor de incertidumbre (Épsilon) es diferente para cada función de membresía de cada entrada.

No	Ind.	Gen.	Mut.	Cruce	Tiempo de Ejecución	Epsilon 1th MF 1th Entrada	Epsilon 2th MF 1th Entrada	Epsilon 1th MF 2th Entrada	Epsilon 2th MF 2th Entrada	Datos dentro el intervalo de Salida
1	80	100	0.1	0.4	2:01:39	2.000	1.001	1.000	1.000	592/601
2	150	150	0.3	0.7	5:34:46	1.500	2.000	3.981	3.713	597/601
3	100	100	0.001	0.5	2:16:09	1.510	2.048	3.906	3.571	593/601
4	40	50	0.8	0.9	0:24:59	2.000	1.588	3.237	2.332	598/601
5	30	30	0.5	0.6	0:11:23	1.500	2.000	3.747	3.500	601/601
6	50	50	1	1	0:33:06	2.000	1.000	1.009	1.000	595/601
7	60	30	0.4	0.85	0:23:07	2.000	1.000	1.012	1.047	592/601
8	35	30	0.95	1	0:14:47	4.000	3.860	3.519	4.000	601/601
9	25	30	0.8	1	0:09:40	2.003	3.625	4.000	2.600	601/601
10	15	100	1	1	0:20:56	1.000	1.000	1.025	1.000	560/601
11	10	100	0.9	1	0:13:15	2.031	2.000	3.465	1.830	576/601
12	10	30	0.6	0.8	0:04:00	1.006	2.000	3.252	2.725	601/601
13	5	30	0.7	0.9	0:01:56	1.047	1.698	1.640	1.523	600/601
14	20	30	0.5	0.7	23:07:16	3.963	4.000	1.979	1.981	601/601
15	15	30	0.35	0.85	0:05:58	1.000	2.943	3.997	3.594	601/601

La tabla 12 nos muestra el mejor resultado con una estructura del AG de 20 individuos, 30 generaciones, 0.5 de mutación, 0.7 de cruce, una incertidumbre de 2.981 y en un tiempo de 23 min y 07 segundos.

Al trabajar con AG podemos observar que obtenemos mejores resultados [15]. Para este benchmark en particular, y trabajando inicialmente con un AG para cada caso, pudimos observar que el caso 2, donde obtenemos diferente ϵ por entrada, arrojó el mejor resultado ya que se obtuvo el total de datos con menor ϵ en cuanto a los otros dos casos (ver Tabla 13).

Tabla 4.13. Tabla de resultados con AG

No. Caso	Individuos	Generación	Mutación	Cruce	Tiempo de Ejecución	Epsilon	Datos dentro el intervalo de Salida
1	15	30	0.35	0.85	0:12:11	3.4934	601/601
2	20	30	0.5	0.7	0:07:56	1.767	601/601
3	20	30	0.5	0.7	0:23:07	2.980	601/601

4.1.5. Pruebas de optimización basada en incertidumbre utilizando benchmark MPG

Luego de realizar los diferentes experimentos, continuamos con la realización del AG con la estructura que se muestra en la figura 3.6; en la cual se tiene un solo AG que optimiza en base al nivel de incertidumbre tomando en cuenta los tres casos; realizando pequeñas pruebas con el benchmark MPG; en la figura 4.14 se muestran los resultados obtenidos.

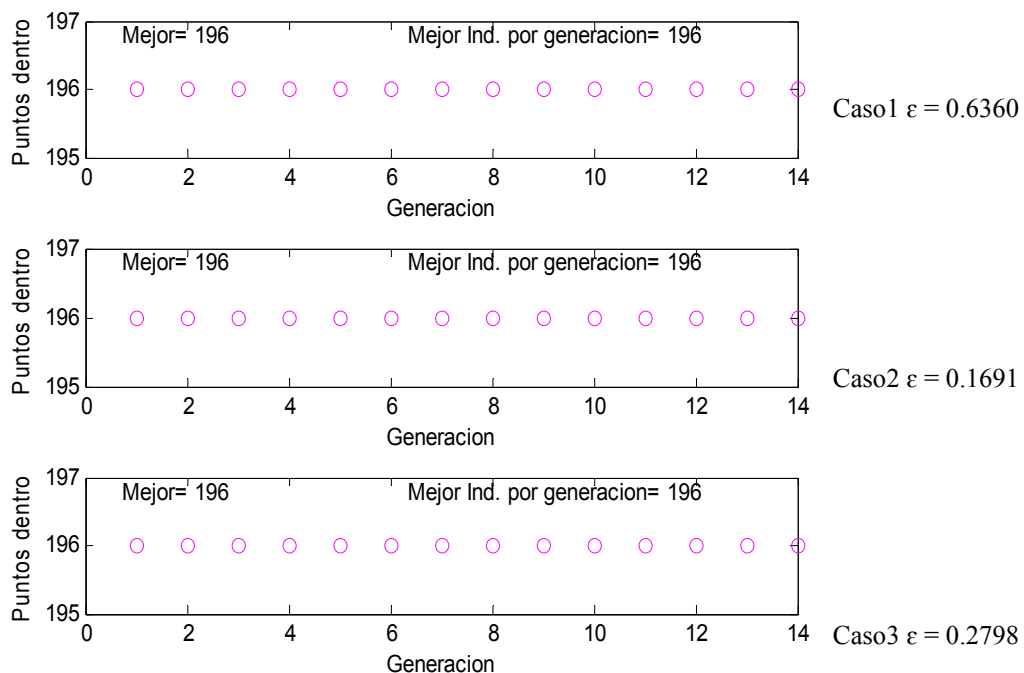


Figura 4.14. Resultado de optimización para el benchmark MPG

En este caso podemos observar que el caso 2 da el total de datos dentro del intervalo de salida con una menor ϵ . Hasta el momento probando con dos casos diferentes, hemos observado que en el caso en que la incertidumbre de las membresías es igual por entrada se ha comportado con mejores resultados, por lo que podemos deducir que no es conveniente tener igual incertidumbre en las diferentes funciones de membresía existentes en las entradas del sistema difuso. Las figuras 4.15, 4.16 y 4.17 muestran como quedaron las funciones de membresía en cada uno de los casos.




Figura 4.15. Huella de incertidumbre para las funciones de membresía del mejor sistema difuso para el Caso1 de MPG, usando la estrategia propuesta para optimización de sistemas de inferencia difusa tipo-2 basado en el nivel de incertidumbre.




Figura 4.16. Huella de incertidumbre para las funciones de membresía del mejor sistema difuso para el Caso2 de MPG, usando la estrategia propuesta para optimización de sistemas de inferencia difusa tipo-2 basado en el nivel de incertidumbre.

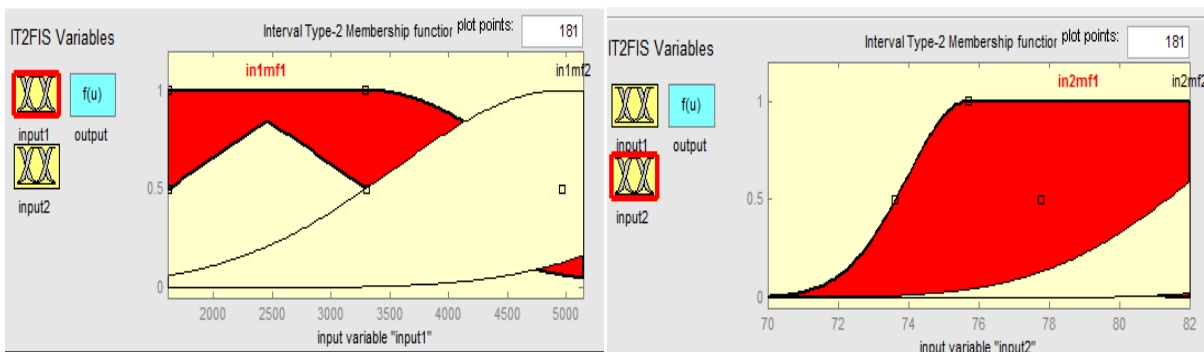


Figura 4.17. Huella de incertidumbre para las funciones de membresía del mejor sistema difuso para el Caso3 de MPG, usando la estrategia propuesta para optimización de sistemas de inferencia difusa tipo-2 basado en el nivel de incertidumbre.

4.1.6. Pruebas De Optimización De Funciones De Membresía Basada En Incertidumbre Como Integradores De Respuesta De Redes Neuronales Modulares

Una vez realizadas pruebas con los distintos casos benchmark; y para continuar, trabajamos sobre la optimización de los sistemas difusos basados en el nivel de incertidumbre de sus funciones de membresías, utilizados para integración de redes neuronales modulares con aplicación en biometría multimodal.

Dichos integradores de respuesta se probaron en la red neuronal modular para biometría multimodal con la estructura que se muestra a continuación en la tabla 14:

Tabla 4.14. Tabla de resultados para la red neuronal modular para biometría multimodal.

Numero de Capas por Submodulo	Neuronas por Capa	Funcion de Rendimiento	No. de Personas reconocidas por submodulo	Porcentaje de Reconocimiento en Redes monolíticas	Tiempo de Ejecución
R:Submodulo 1: 2	64, 32	MSE	7	23.33%	2:45:25
Submodulo 2: 2	64, 33	MSE	5	16.67%	
Submodulo 3: 2	64, 34	MSE	3	10%	
H:Submodulo 4: 2	120, 60	MSE	1	3.33%	
Submodulo 5: 2	120, 61	MSE	2	6.67%	
Submodulo 6: 2	120, 62	MSE	1	3.33%	
V:Submodulo 7: 2	80, 40	MSE	26	86.67%	
Submodulo 8: 2	80, 41	MSE	20	66.67%	
Submodulo 9: 2	80, 42	MSE	24	80%	

Utilizando la estructura anterior de la red neuronal modular se utilizaron los algoritmos genéticos para la optimización basada en el nivel de incertidumbre de las funciones de membresía de los sistemas difusos tipo-2 como integradores para la red neuronal modular, obteniendo los resultados que se muestran a continuación (ver tabla 15):

Tabla 4.15. Tabla de resultados con AG para optimización de sistemas difusos tipo-2 como integradores de respuesta de redes neuronales modulares para biometría multimodal

Ind	Max Gen	Mutación	Tipo Mut	Cruce	Tipo Cruce	GGAP	Duración del GA	Error Alcanzado	% de Epsilon	Mejor Caso	% Reconocimiento	Personas Reconocidas
100	150	0.0001	mutbga	0.1	xovmp	0.85	1:14:28	1.0522E-09	14.1143	Caso 1	76.66	23/30
90	100	0.0001	mutbga	0.2	xovmp	0.85	0:43:46	9.2360E-11	16.3738	Caso 2	76.66	23/30
80	100	0.0001	mutbga	0.3	xovmp	0.85	0:39:04	3.3177E-09	19.4004	Caso 2	76.66	23/30
70	100	0.0001	mutbga	0.5	xovmp	0.85	0:33:50	6.6579E-09	27.6966	Caso 2	90	27/30
60	100	0.0001	mutbga	0.45	xovmp	0.85	0:29:21	2.9281E-10	17.9984	Caso 2	76.66	23/30
50	100	0.001	mutbga	0.65	xovmp	0.85	0:24:23	8.3362E-10	17.5228	Caso 3	76.66	23/30
40	100	0.001	mutbga	0.7	xovsp	0.85	0:18:55	3.9711E-10	12.3861	Caso 3	100	30/30
30	100	0.01	mutbga	0.6	xovmp	0.85	0:13:37	1.1475E-10	22.7655	Caso 2	76.66	23/30
20	100	0.01	mutbga	0.8	xovsp	0.85	0:09:04	6.7780E-10	14.0247	Caso 3	76.66	23/30
10	100	0.1	mutbga	0.9	xovsp	0.85	0:04:52	7.9326E-10	36.3460	Caso2	76.66	23/30
5	100	0.1	mutbga	1	xovsp	0.85	0:02:32	8.8196E-09	33.9990	Caso 1	76.66	23/30
15	100	0.1	mutbga	0.95	xovsp	0.85	0:07:04	5.7787E-10	35.3040	Caso 3	76.66	23/30
25	100	0.01	mutbga	0.85	xovsp	0.85	0:11:26	3.3008E-11	14.7913	Caso 3	76.66	23/30
35	100	0.01	mutbga	0.65	xovmp	0.85	0:15:52	2.3658E-10	38.6421	Caso 1	76.66	23/30
45	100	0.001	mutbga	0.75	xovsp	0.85	0:21:37	4.3981E-11	16.0841	Caso 3	76.66	23/30
55	100	0.001	mutbga	0.6	xovsp	0.85	0:26:24	3.7871E-10	12.7013	Caso 3	76.66	23/30
65	100	0.001	mutbga	0.4	xovsp	0.85	0:33:13	6.2238E-11	9.3798	Caso 3	76.66	23/30
75	100	0.0001	mutbga	0.35	xovsp	0.85	0:35:01	1.0669E-10	18.1557	Caso 3	76.66	23/30

Se realizaron diversas pruebas de optimización de sistemas difusos como integradores de respuesta de redes neuronales modulares. Obteniendo los resultados mostrados anteriormente en la tabla 15, donde podemos observar, que en la mayoría de las pruebas mostradas, el caso 3 da mejores resultados.

Nuestro mejor resultado lo obtuvimos precisamente con el Caso 3, alcanzando un error cuadrático medio de la red neuronal modular de $3.9711e-10$, 12.3861 en porcentaje de épsilon, con una estructura de AG de 40 individuos, 100 generaciones, 0.001 de mutación mutbga, 0.7 de cruce de un punto, 0.85 de generación GAP, en un tiempo de 18 minutos 55 segundos con un reconocimiento del 100%.

Luego de los resultados anteriores, se observó que no se ocupaba de muchos individuos ni generaciones en el GA para buenos resultados, por lo que se hicieron algunas pruebas de

optimización con el algoritmo genético utilizando una estructura del cromosoma de 55 individuos, 50 generaciones, 0.001 de mutación mutbga, 0.6 de cruce de un punto, 0.85 de generación GAP y se obtuvieron los resultados mostrados en la tabla 16.

Tabla 4.16. Tabla de resultados con AG para optimización de sistemas difusos tipo-2 como integradores de respuesta de redes neuronales modulares para biometría multimodal con una estructura del AG de 55 individuos 50 generaciones 0.001 de mutación 0.6 de cruce y 0.85 de GGAP

No. de Entrenamiento	Duración del GA	Error Alcanzado	% de Epsilon	Mejor Caso	% Reconocimiento	Personas Reconocidas
1	00:12:37	3.324E-09	19.87	Caso 3	76.66%	23/30
2	00:13:00	2.7513E-09	19.32	Caso 3	80%	24/30
3	00:13:07	3.5516E-09	40.8592	Caso 1	100%	30/30
4	00:13:02	1.3927E-08	31.2823	Caso 1	100%	30/30
5	00:12:30	6.6596E-08	14.0873	Caso 3	76.66%	23/30
6	00:12:32	1.1661E-07	27.5176	Caso 2	93.33%	28/30
7	00:12:29	1.7439E-08	24.9288	Caso 2	100%	30/30
8	00:12:27	4.3604E-09	13.9198	Caso 3	100%	30/30
9	00:12:31	1.1925E-08	19.8027	Caso 1	76.66%	23/30
10	00:12:26	8.2119E-09	6.0431	Caso 2	76.66%	23/30
11	00:12:54	1.0182E-09	18.0333	Caso 3	100%	30/30
12	00:12:36	4.2397E-10	30.53	Caso 2	76.66%	23/30
13	00:12:37	8.0948E-09	29.5688	Caso 1	76.66%	23/30
14	00:12:45	1.1718E-09	32.7755	Caso 1	76.66%	23/30
15	00:13:05	1.1987E-09	33.5067	Caso 2	76.66%	23/30
16	00:13:02	3.6451E-08	8.6526	Caso 2	80%	24/30
17	00:12:46	1.1061E-08	40.4736	Caso 1	83.33%	25/30
18	00:13:05	1.453E-08	10.8561	Caso 2	83.33%	25/30
19	00:13:08	2.861E-10	25.4811	Caso 1	93.33%	28/30
20	00:12:50	1.2819E-08	22.7639	Caso 3	96.66%	29/30

En los resultados anteriores pudimos observar que se encontraron 4 buenos resultados donde obtenemos un 100% de reconocimiento de personas con el Caso 1, Caso 2, y con Caso 3, pero el porcentaje de reconocimiento de 100% con el caso 3 se logra con un menor porcentaje de ϵ , 13.9198, y obteniendo un error cuadrático medio de la red neuronal modular de $4.3604e-09$, con una estructura de AG de 55 individuos, 50 generaciones, 0.001 de mutación mutbga, 0.6 de cruce de un punto, 0.85 de generación GAP, en un tiempo de 12 minutos 27 segundos con un reconocimiento del 100%.

Se obtuvieron resultados satisfactorios, dejándonos apreciar que en sistemas difusos tipo-2 se obtienen mejores resultados, teniendo diferente incertidumbre en sus funciones de membresía. Cabe resaltar que lo anteriormente dicho, es en cuento a problemas de reconocimiento de patrones.

5. CONCLUSIONES

En el presente proyecto de tesis doctoral se presentó la realización de un nuevo método de optimización de las funciones de membresía en sistemas difusos tipo-2 en base al nivel de incertidumbre; dichos sistemas difusos aplicados a la integración de respuesta en redes neuronales modulares para biometría multimodal. Los Sistemas Difusos Tipo-2 usados como métodos de integración fueron optimizados usando algoritmos genéticos.

La optimización de dichos métodos de integración fue hecha con los algoritmos genéticos y probados con resultados de simulación para reconocimiento de patrones; en los cuales se muestra que nuestro método de optimización da mejores resultados, ya que podemos observar que con los sistemas difusos tipo-2 como integradores de respuesta optimizados en base a su nivel de incertidumbre muestra en la mayoría de las pruebas un alto porcentaje de reconocimiento.

Además se presentaron cada uno de los puntos más relevantes que conformaron éste proyecto, como son, la explicación detallada del nuevo método de optimización, la realización de resultados de los Algoritmos Genéticos obteniendo con ellos los Sistemas Difusos tipo-2 a utilizar como Métodos de Integración, esto con el fin de tener un amplio panorama del proyecto en general. Se presentó también, un conjunto de información adicional (Anexos) que permiten al lector una mejor comprensión de cada uno de los resultados obtenidos, así como también las imágenes que permiten observar la evolución de cada prueba del algoritmo genético.

El uso de las Redes Neuronales Modulares nos permite obtener mejores resultados ya que al dividirse el problema en varios módulos da la pauta a la obtención de buenos resultados; en este caso el problema fue dividido en tres módulos en donde cada uno fue para entrenar diferentes medidas biométricas las cuales fueron Rostro, Huella y Voz. Esto nos llevó a tener el entrenamiento requerido para realizar pruebas de los métodos de integración y llevar a cabo el objetivo de este Proyecto de Tesis, como lo fue la optimización de la integración de respuesta con lógica difusa tipo-2 basada en la incertidumbre de sus funciones de membresía de la red neuronal optimizada a través de algoritmos genéticos.

Al utilizar Lógica Difusa como Método de Integración de Respuestas pudimos observar las ventajas que obtenemos al utilizarla. De igual manera el trabajar con Algoritmos Genéticos es de gran ayuda para obtener resultados óptimos ya que esta técnica nos permite optimizar el problema, y encontrar mejores resultados; en este caso en particular nos benefició al descubrir el nivel de incertidumbre necesario de las Funciones de Membresía de los Sistemas Difusos tipo-2 y que dichos Sistemas Difusos lograran buenos resultados de integración para la Red Neuronal Modular y por lo tanto obtener mayor porcentaje de Reconocimiento de Patrones.

En resumen se concluye, que la Integración Difusa para Redes Neuronales Modulares aplicadas a Biometría, otorga buenos resultados; en especial con la utilización de éstos Sistemas Difusos manejando Lógica Difusa Tipo-2 y con el nivel incertidumbre adecuado. Con esto se apreció en este caso que se obtienen mejores resultados, ya que en las pruebas realizadas de los algoritmos genéticos se obtuvo un buen porcentaje de reconocimiento con el caso 3 de nuestra propuesta, ya que demuestra que no se ocupan tener simétricas nuestras funciones de membresía

ni con el mismo nivel de incertidumbre, sino que eso lo determinará la complejidad del problema.

Como trabajos futuros se puede proponer, el realizar la optimización de la arquitectura de la red neuronal, ya que en esta ocasión no se alcanzó a realizar pruebas de ello. También queda como propuesta pasar nuestra optimización a ser multiobjetivo, ya que se puede observar en los resultados de optimización que tenemos como mejor resultado el menor porcentaje de ϵ , y como multiobjetivo, se podrían tomar las diferentes variables de importancia como el menor porcentaje de ϵ , menor error cuadrático medio de la red neuronal modular, y el mayor porcentaje de reconocimiento.

6. REFERENCIAS

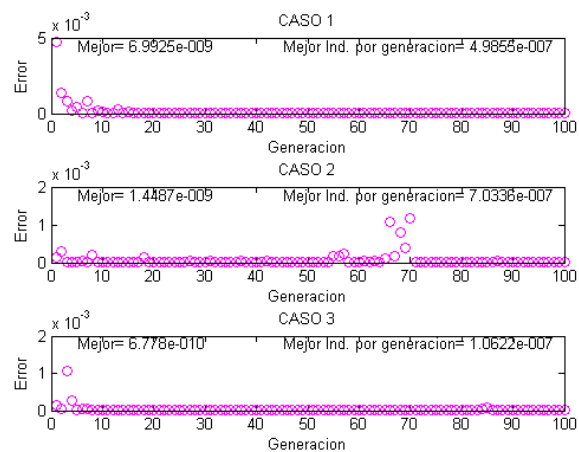

- [1] Castillo Oscar, Melin Patricia.: Type-2 Fuzzy Logic: Theory and Applications. Studies in Fuzziness and Soft Computing. ISSN: 1434-9922. e-ISBN: 978-3-540-76284-3. ISBN: 978-3-540-76283-6. Springer Berlin Heidelberg New York, 2008.
- [2] Castillo Oscar, Melin Patricia: Intelligent Systems with Interval Type-2 Fuzzy Logic. International Journal of Innovative Computing, Information and Control (ICIC) International. ISSN: 1349-4198. Vol. 4, No. 4: 771—783. Abril 2008
- [3] Castro Juan R., Castillo Oscar, Melin Patricia: An Interval Type-2 Fuzzy Logic Toolbox for Control Applications. FUZZ-IEEE 2007: 1-6
- [4] Castro Juan R., Castillo Oscar, Martínez Luis G.: Interval Type-2 Fuzzy Logic Toolbox. Engineering Letters 15(1): 89-98 (2007)
- [5] Castro Juan R., Castillo Oscar, Melin Patricia, Martínez Luis G., Escobar S., Camacho I.: Building Fuzzy Inference Systems with the Interval Type-2 Fuzzy Logic Toolbox. Analysis and Design of Intelligent Systems using Soft Computing Techniques 2007: 53-62
- [6] Castro Juan R., Castillo Oscar, Melin Patricia, Rodríguez Díaz Antonio: Building Fuzzy Inference Systems with a New Interval Type-2 Fuzzy Logic Toolbox. Transactions on Computational Science 1: 104-114 (2008)


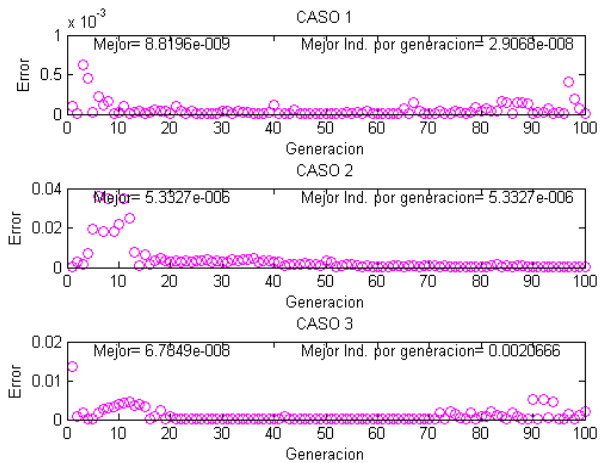


-
- [7] Hidalgo Denisse, Castillo Oscar, Melin Patricia: Optimization with genetic algorithms of modular neural networks using interval type-2 fuzzy logic for response integration: The case of multimodal biometry. *IJCNN 2008*: 738-745
 - [8] Hidalgo Denisse, Castillo Oscar, Melin Patricia: Type-1 and Type-2 Fuzzy Inference Systems as Integration Methods in Modular Neural Networks for Multimodal Biometry and Its Optimization with Genetic Algorithms. *Soft Computing for Hybrid Intelligent Systems 2008*: 89-114
 - [9] Hidalgo Denisse, Melin Patricia, Licea Guillermo, Castillo Oscar: Optimization of Type-2 Fuzzy Integration in Modular Neural Networks Using an Evolutionary Method with Applications in Multimodal Biometry. *MICAI 2009*: 454-465
 - [10] Hidalgo Denisse, Melin Patricia, Licea Guillermo: Optimization of Modular Neural Networks with Interval Type-2 Fuzzy Logic Integration Using an Evolutionary Method with Application to Multimodal Biometry. *Bio-inspired Hybrid Intelligent Systems for Image Analysis and Pattern Recognition 2009*: 111-121
 - [11] Hidalgo Denisse, Castillo Oscar, Melin Patricia: Type-1 and type-2 fuzzy inference systems as integration methods in modular neural networks for multimodal biometry and its optimization with genetic algorithms. *Inf. Sci.* 179(13): 2123-2145 (2009)
 - [12] Hidalgo Denisse, Melin Patricia, Mendoza Olivia: Evolutionary optimization of type-2 fuzzy systems based on the level of uncertainty. *FUZZ-IEEE 2010*: 1-6
 - [13] Hidalgo Denisse, Melin Patricia, Castillo Oscar: Optimal Design of Type-2 Fuzzy Membership Functions Using Genetic Algorithms in a Partitioned Search Space. *GrC 2010*: 212-216
 - [14] Hidalgo Denisse, Melin Patricia, Castillo Oscar, Licea Guillermo: Optimization of type-2 fuzzy systems based on the level of uncertainty, applied to response integration in modular neural networks with multimodal biometry. *IJCNN 2010*: 1-6
 - [15] Hidalgo Denisse, Melin Patricia, Castillo Oscar: Type-2 Fuzzy Inference System Optimization Based on the Uncertainty of Membership Functions Applied to Benchmark Problems. *MICAI (2) 2010*: 454-464
 - [16] Hidalgo Denisse, Castillo Oscar, Melin Patricia: Sistemas de Inferencia Difusa Tipo-1 y Tipo-2 como Métodos de Integración en Redes Neuronales Modulares para Biometría Multimodal y su Optimización por medio de Algoritmos Genéticos. Febrero 2008.
 - [17] Jang Jyh-Shing Roger, Sun Chuen-Tsai, Mizutani Eiji.: *Neuro-Fuzzy and Soft Computing: A Computational Approach to Learning and Machine Intelligence*. Prentice Hall; 1 edition. ISBN-10: 0132610663. ISBN-13: 978-0132610667 September 26, 1997.
 - [18] Karnik, N.N.; Mendel, Jerry M.: *Type-2 fuzzy logic systems: type-reduction*. Systems, Man, and Cybernetics, 1998. 1998 IEEE International Conference. vol.2. San Diego, CA, USA.: 2046 – 2051. ISBN: 0-7803-4778-1. 11-14 Oct 1998.
 - [19] Karnik, N.N., Mendel, Jerry .M, Qilian Liang: *Type-2 fuzzy logic systems*. Fuzzy Systems, IEEE Transactions Volume: 7: 643 – 658. ISSN: 1063-6706. Dec 1999







- [20] Man Kim Fung, Tang Kit-Sang and Kwong Sam: Genetic Algorithms, Concepts and Designs (Advanced Textbooks in Control and Signal Processing). Springer; ISBN-10: 1852330724, ISBN-13: 978-1852330729. March 30, 1999.
- [21] Melin Patricia, Castillo Oscar.: Hybrid Intelligent Systems for Pattern Recognition Using Soft Computing: An Evolutionary Approach for Neural Networks and Fuzzy Systems. Studies in Fuzziness and Soft Computing. ISSN print edition: Pp. 1434-9922. ISSN electronic edition: 1860-0808. ISBN: 3-540-24121-3. Springer Berlin Heidelberg New York, 2005.
- [22] Melin Patricia, Castillo Oscar, Gómez, E., Kacprzyk, J., Pedrycz, W. : Analysis and Design of Intelligent Systems Using Soft Computing Techniques. Advances in Soft Computing 41. Springer, 2007.
- [23] Mendel Jerry M.: “UNCERTAIN Rule-Based Fuzzy Logic Systems, Introduction and New Directions”, Prentice Hall. Pp.576. ISBN-10: 0-13-040969-3, ISBN-13: 978-0-13-040969-0, Dec 22.
- [24] Qilian Liang, Mendel J.M.: Interval type-2 fuzzy logic systems: theory and design. Fuzzy Systems, IEEE Transactions, Volume: 8 Issue: 5. Pp.: 535 – 550. ISSN: 1063-6706. Oct 2000.
- [25] Tapiador Mateos Merino, Sigüenza Juan A.: Tecnologías biométricas aplicadas a la seguridad. Librería Rama y Editorial Microinformática. 1ª ed., 1ª imp. ISBN: 8478976361, ISBN-13: 9788478976362. December 2004.
- [26] Wu Hongwei, Mendel Jerry M.: Uncertainty bounds and their use in the design of interval type-2 fuzzy logic systems. Fuzzy Systems, IEEE Transactions. Vol.10. pp. 622 – 639. ISSN: 1063-6706. Oct 2002.
- [27] Zadeh Lotfi A.: The role of fuzzy logic in the management of uncertainty in expert systems. Fuzzy Sets and Systems. Volume 11, Issues 1-3, Pages 197-198, 1983.
- [28] Zadeh Lotfi A.: Generalized theory of uncertainty (GTU)—principal concepts and ideas. The Fuzzy Approach to Statistical Analysis . Computational Statistics & Data Analysis. Volume 51, Issue 1, Pages 15-46, 1 November 2006.
- [29] Zadeh, L.A.: Fuzzy Sets, Information and Control, Vol. 8, pp. 338-353, 1965.
- [30] Zadeh, L.A.: Toward a theory of fuzzy information granulation and its centrality in human reasoning and fuzzy logic. Fuzzy Sets and Systems. Vol. 90. pp. 117-117. Elsevier, 1997.
- [31] Zadeh, L.A.: Fuzzy logic = computing with words. Fuzzy Systems, IEEE Transactions. Vol. 4. Pp.103 – 111. ISSN: 1063-6706. Mayo 1996
- [32] Zadeh, L.A.: Fuzzy logic, neural networks, and soft computing. Communications of the ACM. Vol. 37, Marzo 1994.
- [33] Zadeh, L.A.: Soft computing and fuzzy logic. Software, IEEE. Vol.11. Pp. 48 – 56. ISSN: 0740-7459. Nov 1994


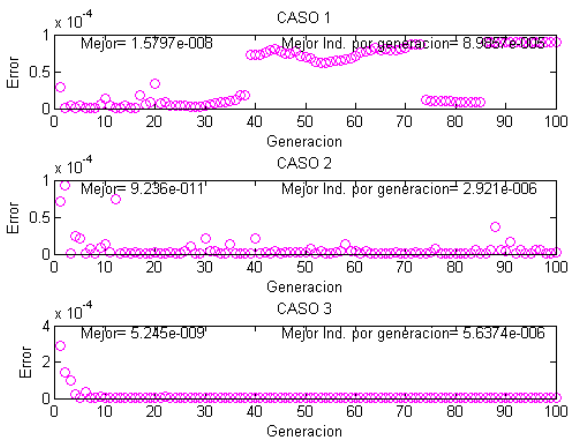




7. ANEXOS

7.1. Graficas de comportamiento del GA para la optimización de sistemas difusos tipo-2 como integradores de redes neuronales modulares con aplicación en biometría multimodal.

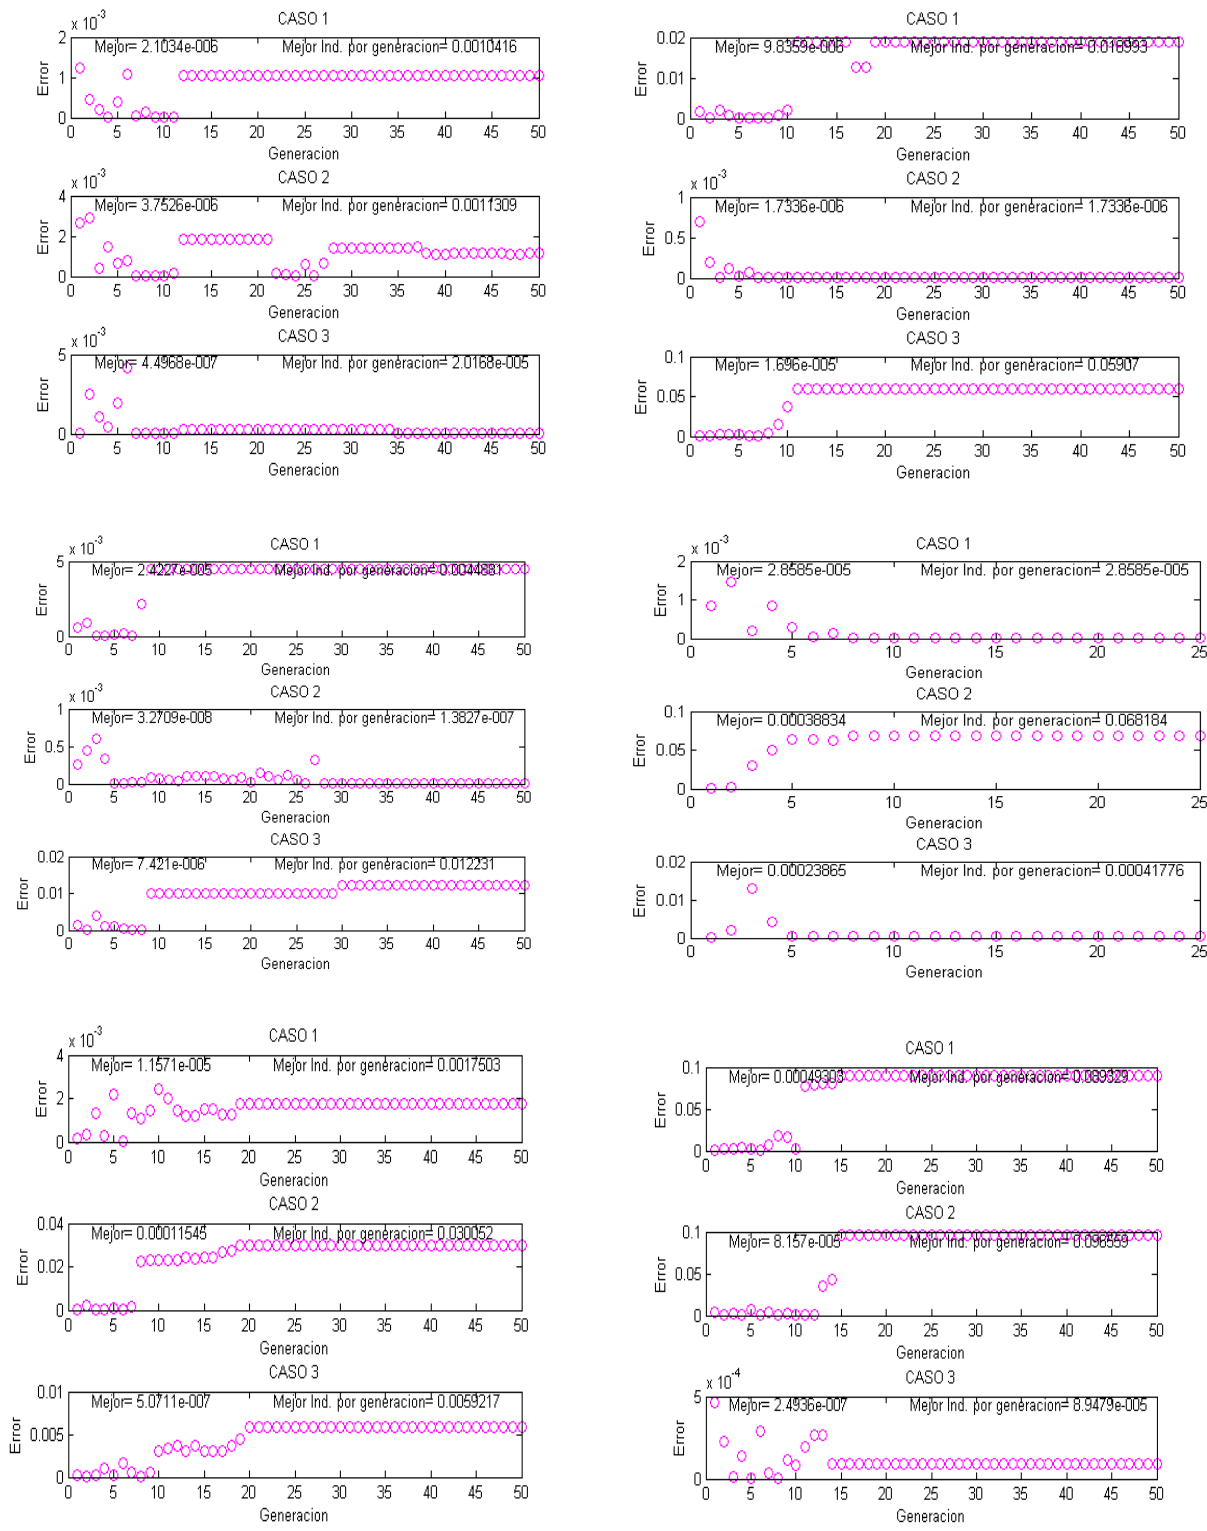


























25ind50gen





50ind50gen

