



UNIVERSIDAD AUTÓNOMA CHAPINGO
POSGRADO EN INGENIERÍA AGRÍCOLA Y USO
INTEGRAL DEL AGUA

MODELOS NEURO-DIFUSOS PARA TEMPERATURA Y
HUMEDAD DEL AIRE EN UN INVERNADERO

TESIS

QUE COMO REQUISITO PARCIAL
PARA OBTENER EL GRADO DE:
MAESTRO EN INGENIERÍA AGRÍCOLA
Y USO INTEGRAL DEL AGUA

PRESENTA:

LEOPOLDO HERNÁNDEZ LARRAGOITI

SEPTIEMBRE DE 2009

Chapingo, Estado de México

MODELOS NEURO-DIFUSOS PARA TEMPERATURA Y HUMEDAD DEL AIRE EN UN INVERNADERO


Tesis realizada por **Leopoldo Hernández Larragoiti** bajo la dirección del Comité
Asesor indicado, aprobada por el mismo y aceptada como requisito parcial para obtener
el grado de:

MAESTRO EN INGENIERÍA AGRÍCOLA Y USO INTEGRAL DEL AGUA ORIENTACIÓN BIOSISTEMAS

DIRECTOR:


Dr. Irineo Lorenzo López Cruz

ASESOR:


Dr. J. Armando Ramírez Arias

ASESOR:


Dr. Eugenio Romanchik Kriuchkova



AGRADECIMIENTOS

Al posgrado de Ingeniería Agrícola y Uso Integral del Agua de la Universidad Autónoma Chapingo por darme la oportunidad de realizar mis estudios de maestría.

Al CONACYT por el apoyo económico brindado durante mis estudios de maestría.

Al Consejo Mexiquense de Ciencia y Tecnología (COMECYT) que aportó un apoyo económico para la culminación de este trabajo de investigación a través de una Beca Tesis de Posgrado.

Al Dr. Irineo L. López Cruz, que con sus valiosas sugerencias y acertadas propuestas hizo posible la finalización de este trabajo.

Al Dr. J. Armando Ramírez Arias y al Dr. Eugenio Romanchik Kriuchkova , por el paciente trabajo de revisión y acertadas sugerencias para mejorar el mismo.

DEDICATORIA

Al que creó y dirige mi vida y que sin el nada de lo que he hecho hubiera sido posible: Jehová (Yavé) ¡Cuán grandes son sus señales y cuán potentes sus maravillas! El hace según su voluntad en el ejército del cielo y en los habitantes de la tierra; no hay quien detenga su mano y le diga: ¿Qué haces? Engrandezco y glorifico al Rey del cielo, porque todas sus obras son verdaderas y sus caminos justos; y él puede humillar a los que andan con soberbia. El origen de la sabiduría está en El.

A mi ayuda idónea y amada esposa **Adriana** y al fruto de nuestro amor **Jefté Leopoldo**, por su comprensión y su amor incondicional, amor que tiene su origen en Jesucristo. Gracias por estar conmigo en las buenas y en las malas.

A mis padres **Micaela** y **Demetrio**, por el apoyo que me han brindado siempre y por el amor que nos han mostrado, bendito el Señor Jesucristo por haberme otorgado la dicha de tenerles. Gracias por sus valiosos consejos.

A mis suegros **Isabel** y **José Merced**, por el regalo maravilloso (Adri) y por el apoyo que nos han brindado.

"Jehová con sabiduría fundó la tierra; afirmó los cielos con inteligencia" (Proverbios 3:19). "¿Dónde estabas tú cuando yo fundaba la tierra? Házmelo saber, si tienes inteligencia" (Job 38:4).

MODELOS NEURO-DIFUSOS PARA TEMPERATURA Y HUMEDAD DEL AIRE DE UN INVERNADERO

Leopoldo Hernández Larragoiti¹
Irineo L. López Cruz²

En la producción de cultivos hortícolas bajo condiciones de invernadero es importante optimizar y controlar el manejo del ambiente usando modelos dinámicos. El desarrollo y uso de modelos mecanicistas es costoso y requiere mucho tiempo. Los modelos de caja negra, basados en mediciones de entradas y salidas, son un enfoque prometedor para estudiar sistemas complejos y no-lineales. En la presente investigación se estudiaron y generaron modelos neuro-difusos, para predecir el comportamiento de la temperatura y la humedad relativa del aire en el interior de dos invernaderos. Las variables de entrada fueron: la temperatura, la humedad relativa, la radiación solar global y la velocidad y dirección del viento medidas fuera del invernadero. Las variables de salida fueron la temperatura y humedad del aire medidas dentro del invernadero. El tiempo de muestreo fue cada minuto. Se generaron varios modelos neuro-difusos para la temperatura y humedad, usando el modelo neuro-difuso ANFIS (Adaptive Neuro-Fuzzy training of Sugeno-type Fuzzy Inference System), disponible en el Fuzzy Logic Toolbox de Matlab. Se usaron los métodos partición de rejilla y agrupamiento sustractivo para generar el sistema de inferencia difuso. Se analizaron varias particiones empíricas de los datos, dos tipos de funciones de membresía (Gaussiana y Campana generalizada), así como las funciones de membresía de salida constante y lineal. Se probaron además varias épocas de entrenamiento. Se emplearon dos conjuntos de datos recolectados en dos invernaderos con ventilación natural, localizados en la Universidad Autónoma Chapingo y la Universidad Autónoma de Querétaro. Los resultados mostraron que los modelos neuro-difusos predicen de manera aceptable el comportamiento del clima dentro del invernadero, ya que fueron mejores que los correspondientes modelos de regresión lineal múltiple.

Palabras clave: modelos neuro-difusos, invernadero, ANFIS, control óptimo.

NEURO-FUZZY MODELS FOR AIR TEMPERATURE AND HUMIDITY OF A GREENHOUSE

Leopoldo Hernández Larragoiti¹
Irineo L. López Cruz²

In producing horticultural crops under greenhouse conditions, it is important optimize and control the management of the environment using dynamic models. The development and use of mechanistic models is expensive and requires too much time. Black-box models, based on measurements of inputs and outputs, are a promising approach to study complex and nonlinear systems. In the present research, neuro-fuzzy models were studied and generated in order to predict the behavior of air temperature and humidity inside two greenhouses. Input variables were: temperature, relative humidity, global solar radiation, and direction and speed of wind velocity measured outside the greenhouse. Output variables were air temperature and humidity measured inside the greenhouse. The sampling time was each minute. Several neuro-fuzzy models were generated using the neuro-fuzzy model ANFIS (Adaptive Neuro-Fuzzy training of Sugeno-type Fuzzy Inference System), available in the Matlab's Fuzzy Logic Toolbox. Grid and partitioning and subtractive clustering methods were used to generate the fuzzy inference system. Several empirical data partitions were analyzed, two membership functions (Gaussian and Generalized Bell), as well as the output membership functions constant and linear. In addition several training epochs were tested. Two sets of data collected from two greenhouses with natural ventilation located at University of Chapingo and University of Querétaro, were used. Results showed that neuro-fuzzy models predict in an acceptable way the behavior of greenhouse climate, since they performed always better than the corresponding multiple linear regression models.

Key words: neuro-fuzzy models, greenhouse, ANFIS, optimal control.

¹ Tesista

² Director

¹ MSc student

² Student's advisor

INDICE GENERAL

Resumen.....	v
Indice General.....	vi
Indice de Tablas.....	viii
Indice de Figuras.....	x
I. INTRODUCCION.....	1
II. OBJETIVOS.....	3
2.1 General.....	3
2.2 Particulares.....	3
III. REVISION BIBLIOGRAFICA.....	4
3.1 Modelado de sistemas	4
3.2 Sistemas difusos.....	5
3.2.1 Conceptos y operaciones básicas.....	5
3.2.2 Tipos de Funciones de Membresía.....	11
3.2.3 Sistemas de Inferencia Difuso.....	16
3.2.4 Métodos para formación de reglas difusas.....	21
3.3 Redes Neuronales.....	24
3.4 Modelado neuro-difuso	29
3.4.1 Sistema neuro-difuso ANFIS.....	29
3.4.2 Identificación del sistema.....	35
3.4.3 ANFIS en MATLAB.....	40
IV. MATERIALES Y METODOS.....	44
4.1 Características del invernadero y adquisición de datos.....	44
4.2 Modelado neuro-difuso de la temperatura y humedad relativa.....	46
4.3 Modelo de regresión lineal (mínimos cuadrados)	50
V. RESULTADOS Y DISCUSION.....	51

INDICE GENERAL – *Continuación*

5.1 Modelado de la temperatura del invernadero de Chapingo, México.....	51
5.2 Modelo de la Humedad Relativa del invernadero de Chapingo, México.....	63
5.3 Modelo de regresión lineal múltiple.....	72
5.4 Capacidad de generalización.....	76
VI. CONCLUSIONES.....	85
BIBLIOGRAFÍA.....	87
Apéndice A. Programa para hacer particiones empíricas de los datos para el modelado de temperatura y humedad relativa.....	90
Apéndice B. Programa para seleccionar el radio que produce el mínimo rmse con genfis2.....	91
Apéndice C. Programa para modelar la temperatura o la humedad relativa dentro del invernadero, con partición de rejilla y ANFIS para mejorar la respuesta.....	92
Apéndice D. Programa para modelar la temperatura o la humedad relativa dentro del invernadero, con agrupamiento sustractivo y ANFIS para mejorar la respuesta.....	100
Apéndice E. Selección de entradas, temperatura del invernadero de Chapingo, Mexico.....	105
Apéndice F. Selección de entradas, humedad relativa del invernadero de Chapingo, Mexico.....	109

INDICE DE TABLAS

Tabla	Página
3.1 Dos pasos en el proceso de aprendizaje híbrido para ANFIS.....	34
4.1 Descripción del área de estudio (invernadero de Chapingo, México)....	44
5.1 Opciones para generar el FIS inicial mediante genfis1 en Temperatura y Humedad Relativa de un invernadero con ventilación natural en Chapingo, México.....	51
5.2 Topología del modelo difuso de temperatura y humedad relativa mediante genfis1 para un invernadero con ventilación natural en Chapingo, México.....	52
5.3 Valores estadísticos como medidas del desempeño de los modelo de temperatura obtenidos con genfis1 y ANFIS para el invernadero de Chapingo, México.....	54
5.4 Topología del modelo difuso de temperatura mediante genfis2 para un invernadero con ventilación natural en Chapingo, México.....	58
5.5 Desempeño de los modelos de temperatura obtenidos mediante agrupamiento sustractivo y ANFIS para el invernadero de Chapingo, México.....	60
5.6 Resultados estadísticos para la humedad relativa con genfis1 y ANFIS.	64
5.7 Topología del modelo difuso de humedad relativa mediante agrupamiento sustractivo para un invernadero con ventilación natural en Chapingo, México.....	68
5.8 Valores estadísticos empleando genfis2 para el FIS inicial, humedad relativa del invernadero de Chapingo.....	69
5.9 Estadísticos de la temperatura usando genfis1 y ANFIS, invernadero de la UAQ (Universidad Autónoma de Querétaro).....	77

INDICE DE TABLAS - *Continuación*

Tabla	Página
5.10 Desempeño de los modelos de temperatura obtenidos mediante agrupamiento sustractivo y ANFIS para el invernadero de la UAQ.....	78
5.11 Estadísticos para el modelo de humedad relativa, ANFIS y partición de rejilla. Invernadero de la UAQ.....	80
5.12 Resultados estadísticos de los modelos de humedad relativa obtenidos mediante agrupamiento sustractivo y ANFIS para el invernadero de la UAQ.....	82
E.1 Resultados del Modelo de Temperatura obtenidos con partición de rejilla y ANFIS, haciendo selección de entradas. Para distintas particiones de datos. Invernadero de Chapingo.....	105
E.2 Resultados del Modelo de Temperatura obtenidos con partición mediante agrupamiento sustractivo y ANFIS, para distintas particiones de datos.....	108
F.1 Resultados del Modelo de Humedad Relativa mediante partición de rejilla y ANFIS, para distintas particiones de datos. Invernadero de Chapingo, México.....	109
F.2 Resultados del Modelo de Humedad Relativa obtenidos mediante agrupamiento sustantivo y ANFIS , para distintas particiones de datos. Invernadero de Chapingo, México.....	112

INDICE DE FIGURAS

Figura	Página
3.1 Funciones de Membresía típicas de valores lingüísticos “joven”, “adulto” y “viejo”.....	8
3.2 El concepto de $A \subseteq B$	9
3.3 Operaciones de conjuntos difusos: (a) dos conjuntos difusos A y B; (b) $\bar{A}$; (c) $A \cup B$; (d) $A \cap B$	10
3.4 Ejemplos de cuatro clases de MFs parametrizadas: (a) <i>triangulo</i> (x; 20, 60, 80); (b) <i>trapecio</i> (x; 10, 20, 60, 95); (c) <i>gauss</i> (x; 50, 20); (d) <i>campana</i> (x; 20, 4, 50).....	13
3.5 (a) Conjunto Base A; (b) su extensión cilíndrica $c(A)$	15
3.6 (a) Conjunto Difuso bidimensional R; (b) R_x (proyección de R sobre X); y (c) R_y (proyección de R sobre Y).....	16
3.7 Funciones de membresía típicos del conjunto de término $T(edad)$	17
3.8 Modelo de razonamiento difuso de Sugeno (Jang et al, 1997).....	21
3.9 Métodos de partición del espacio de entrada: (a) partición de rejilla, (b) partición de árbol y (c) partición dispersa.....	23
3.10 Perceptrón multicapa.....	27
3.11 Red neuronal tipo recurrente.....	28
3.12 Razonamiento difuso.....	30
3.13 Arquitectura ANFIS equivalente para inferencia Takagi-Sugeno.....	31
3.14 Diagrama de bloques para la identificación de parámetros (Jang et al., 1997).....	40

INDICE DE FIGURAS - *Continuación*

4.1	Variables meteorológicas del invernadero de Chapingo, México: radiación solar (R_o), humedad relativa (H_{Ro}), velocidad del viento (V_v), dirección del viento (D_v), temperatura exterior (T_o), temperatura interior (T_i) y la humedad relativa (H_{Ri}) en el interior del invernadero.....	45
5.1	Estructura del FIS inicial obtenido por <i>genfis1</i> para el modelo de temperatura y de la humedad relativa, constituido por dos funciones de membresía en cada entrada y con una función de membresía de salida ya sea constante o lineal.....	53
5.2	Curvas de error usadas para detectar sobreentrenamiento en los datos 80.17%-19.83%. Modelado de temperatura en el invernadero de Chapingo, México usando <i>genfis1</i> y ANFIS.....	55
5.3	Temperatura medida y simulada por el modelo neuro-difuso de un invernadero con ventilación natural, en Chapingo, México. Conjunto de datos 80.17-19.83 (usando <i>genfis1</i> y ANFIS).....	56
5.4	Gráfico de dispersión del modelo neuro-difuso. Conjunto de datos 80.17%-19.83%, para la temperatura de un invernadero con ventilación natural en Chapingo, México; usando <i>genfis1</i> y ANFIS...	57
5.5	Estructura del FIS inicial obtenido mediante agrupamiento sustractivo para la temperatura del invernadero de Chapingo, constituido por seis funciones de membresía por entrada y una función de membresía de salida constante o lineal.....	59
5.6	Curva de error del modelo de temperatura con datos 80.17-19.83 usando agrupamiento sustractivo y ANFIS.....	60
5.7	Temperatura medida y simulada por el modelo neuro-difuso para el invernadero de Chapingo, México. Conjunto de datos 80.17-19.83 y empleando <i>genfis2</i> y ANFIS.....	62

INDICE DE FIGURAS – *Continuación*

5.8	Gráfico de dispersión del conjuntos de datos 80.17-19.83 en el modelo de temperatura mediante genfis2 y ANFIS para el invernadero de Chapingo, México.....	63
5.9	Curvas de error del modelo neuro-difuso de humedad relativa, obtenido empleando genfis1 y ANFIS. Con datos 69.14-30.86 del invernadero de Chapingo.....	65
5.10	Modelo neuro-difuso de la humedad relativa del invernadero de Chapingo, usando datos 69.14-30.86 con ANFIS y genfis1.....	66
5.11	Gráficos de dispersión del conjunto 69.14-30.86 para la humedad relativa del invernadero de Chapingo. Se empleo genfis1 y se mejoro con ANFIS.....	67
5.12	Estructura del FIS inicial del modelo de humedad relativa, obtenido con genfis2 para el invernadero de Chapingo, constituido por cuatro funciones de membresía por entrada y una función de membresía de salida constante o lineal.....	69
5.13	Curvas de error usando el conjunto de datos 69.14-30.86 para la humedad relativa con agrupamiento sustractivo y ANFIS.....	70
5.14	Humedad relativa medida y simulada por el modelo neuro-difuso con datos 69.14-30.86 mediante ANFIS y genfis2 para el invernadero de Chapingo, México.....	71
5.15	Gráfico de dispersión para el conjunto 69.14-30.86. Modelo de humedad relativa usando agrupamiento sustractivo y ANFIS para el invernadero de Chapingo.....	72
5.16	Modelo de regresión lineal para la temperatura de un invernadero con ventilación natural, en Chapingo, México (datos 80.17%-19.83%).....	73
5.17	Gráfico de dispersión de los conjuntos de datos en el modelo de regresión lineal para la temperatura de un invernadero con ventilación natural, en Chapingo, México.....	74

INDICE DE FIGURAS – *Continuación*

5.18	Modelo de regresión lineal para la humedad relativa de un invernadero con ventilación natural, en Chapingo, México.....	75
5.19	Gráfico de dispersión de los conjuntos de datos en el modelo de regresión lineal para la humedad de un invernadero con ventilación natural, en Chapingo, México.....	76
5.20	Temperatura medida y simulada por el modelo neuro-difuso de un invernadero en Querétaro, Qro empleando genfis1 y ANFIS.....	77
5.21	Gráfico de dispersión de los conjuntos de datos para el modelo de temperatura de un invernadero con ventilación natural, en Querétaro, Qro.....	78
5.22	Temperatura medida y simulada por el modelo neuro-difuso, invernadero de Querétaro, Qro. La técnica de partición del espacio de entrada fue agrupamiento sustractivo y se mejoro con ANFIS.....	79
5.23	Gráfico de dispersión para los conjuntos de entrenamiento y prueba de la partición 80-20, se empleo genfis2 y ANFIS. Invernadero de la UAQ.....	80
5.24	Modelo para la humedad relativa con datos del invernadero de Querétaro. Empleando partición de rejilla y ANFIS.....	81
5.25	Dispersión de los conjuntos de datos para la Humedad Relativa con datos del invernadero de Querétaro.....	82
5.26	Modelo para la humedad relativa con datos del invernadero de Querétaro. Empleando agrupamiento sustractivo y ANFIS.....	83
5.27	Dispersión de los conjuntos de datos para el modelo de la humedad relativa del invernadero de la UAQ mediante agrupamiento sustractivo y ANFIS.....	84

I. INTRODUCCION

En la producción de cultivos hortícolas, un objetivo importante para la operación del invernadero es crear el ambiente más adecuado para los cultivos, de manera que se puedan obtener los mejores ingresos económicos. Cambiando las condiciones interiores en el invernadero se puede mejorar la calidad y la cantidad del producto. Para alcanzar esta mejora, además de la experiencia del productor, es indispensable la operación controlada por computadora del ambiente del invernadero.

Recientemente, se ha estudiado el control óptimo del clima del invernadero. Sin embargo, la aplicación de este se basa fuertemente en la disponibilidad de los modelos matemáticos que describen la dinámica del clima del interior y el crecimiento de la planta como una función de las variables de control, y el clima externo. El procedimiento para establecer modelos mecanicistas por lo general lleva mucho tiempo y es costoso. En situaciones donde los datos experimentales están disponibles, un modelado articulando el entorno a base de datos o un modelado de caja negra, por ejemplo, el modelado de redes neuronales y el difuso, pueden ser una alternativa atractiva al modelado mecanicista (Tien, 1997).

Las redes neuronales son caracterizadas por llevar a cabo mapeos no lineales del espacio de variables independientes al espacio de variables dependientes mediante arquitecturas paralelas que consisten en tratamientos de elementos simples que se comunican por conexiones ponderadas. Son capaces de aproximar funciones o de solucionar ciertos problemas de control por aprendizaje de ejemplos vía optimización de parámetros. Por otra parte, el modelado difuso puede ser considerado como modelado de caja gris, el cual es capaz de procesar el conocimiento experto disponible o la experiencia en forma de reglas difusas lingüísticas IF/THEN y funciones de membresía.

Aunque las redes neuronales y sistemas borrosos tienen orígenes diferentes, comparten la misma propiedad de procesamiento en paralelo, y ambos pueden utilizarse como aproximadores universales para realizar un mapeo no lineal de un sistema. El reconocimiento de la equivalencia funcional de ambos paradigmas como aproximadores universales, ha incitado una nueva línea de investigación para inyectar nuevas fuerzas motrices del campo de redes neuronales en la disciplina “difusa”, y viceversa. Es decir, una tentativa de combinar la representación transparente del sistema difuso y la capacidad de aprendizaje de las redes neuronales en un marco unificado, dando lugar así a un modelo integrado neuro-difuso o difuso-neuro (Gómez, 2005).

En la predicción del clima dentro del invernadero se han empleado distintos enfoques, como los modelos ARX o modelos de autoregresión con variables exógenas (López *et al.*, 2007) en el cual se obtuvo un ajuste mayor al 70% sobre los datos de estimación y validación de la temperatura. Salazar, *et al.* (2007) se reporta una alternativa para predecir el comportamiento del clima dentro de un invernadero empleando redes neuronales, obtuvieron un 97 % de ajuste del modelo empleando cuatro variables de entrada. Los modelos neurodifusos han sido empleados en distintos campos como en la predicción del comportamiento del clima en una región (Gamboa *et al.*, 2005; Lin, 2007), control de inyección de combustible y simulación del desempeño de motores (Haijun, 2008) y también en el modelado de series de tiempo hidrológicas (Nayak, 2004), etc.

En el presente trabajo se estudia y utiliza un sistema neuro-difuso para la generación de un modelo matemático del ambiente invernadero.

II. OBJETIVOS

2.1 General

Desarrollar la metodología para generar un modelo neuro-difuso de un sistema, mediante la modelación de la temperatura y la humedad relativa del ambiente de un invernadero en el centro de México.

2.2 Particulares

- Generar un modelo neuro-difuso para predecir el comportamiento de la temperatura de un invernadero.
- Generar un modelo neuro-difuso para predecir el comportamiento de la humedad relativa de un invernadero.
- Desarrollar la metodología para generar un modelo neuro-difuso de un sistema, empleando el Fuzzy Logic Toolbox de Matlab.

III. REVISION BIBLIOGRAFICA

3.1 Modelado de sistemas

Un modelo es una abstracción de la realidad, una descripción formal de los elementos más esenciales de un problema. La descripción puede ser física, matemática o verbal (Grant *et al.*, 2001). Ogata (Ogata, 2003) dice que un sistema es una combinación de componentes que actúan juntamente y realizan un determinado objetivo.

Un sistema es cualquier colección de objetos interrelacionados. Un objeto es cualquier unidad elemental en la cual se pueden hacer observaciones, pero cuya estructura interna o no existe o es ignorada. Una descripción es una señal que puede ser descifrada o interpretada por humanos (Haefner, 2005). Los modelos matemáticos se pueden clasificar de varias formas, por ejemplo (Grant *et al.*, 2001; Haefner, 2005):

- **Físicos contra abstractos.** Los modelos físicos generalmente son réplicas físicas a menor escala del objeto en estudio. Los modelos abstractos usan símbolos en lugar de réplicas a menor escala para representar el sistema estudiado.
- **Dinámicos contra estáticos.** Un modelo estático describe una relación, o conjunto de relaciones, que no cambia en el tiempo. Por el contrario, un modelo dinámico describe una relación que varía con el tiempo.
- **Correlacionales (empíricos) contra explicativos (mecanicistas).** Los modelos empíricos se desarrollan principalmente para describir y resumir un conjunto de relaciones, sin representar explícitamente los procesos o mecanismos que operan en el sistema real. Los modelos mecanicistas se desarrollan para representar la dinámica interna del sistema de interés.

- **Modelos determinísticos contra estocásticos.** Un modelo es determinístico si no contiene variables aleatorias. Las predicciones obtenidas empleando modelos en el marco de un conjunto específico de condiciones serán siempre idénticas. Un modelo es estocástico, si contiene una o más variables aleatorias. Los modelos determinísticos generalmente son más fáciles de desarrollar, porque sólo es necesario estimar las constantes, mientras que en los modelos estocásticos se debe especificar la distribución completa de cada una de las variables aleatorias.
- **Modelos de simulación contra analíticos.** Los modelos analíticos son aquellos que se pueden resolver matemáticamente en forma cerrada. Los modelos de simulación son aquellos para los cuales es posible encontrar una solución analítica y deben resolverse numéricamente.

3.2 Sistemas difusos

En general, un sistema difuso es cualquier sistema cuyas variables (o al menos alguna de ellas) contienen condiciones de estado que son conjuntos difusos. Para cada variable, los conjuntos difusos son definidos en algún conjunto universal relevante, el cual es a menudo un intervalo de números reales. En este especial pero importante caso, los conjuntos difusos son números difusos y las variables asociadas son variables lingüísticas. Una manera de discretizar las variables es representando las variables de estado por conjuntos difusos (Klir y Yuan, 1995).

3.2.1 Conceptos y operaciones básicas

Un conjunto clásico es un conjunto con límites claramente definidos o precisos. Por ejemplo, un conjunto A de números reales más grandes que 1.7 se puede expresar como:

$$A = \{x \mid x > 1.7\} \dots\dots\dots(3.1)$$

Donde hay un claro límite 1.7, tal que si x es más grande que este número, x pertenece al conjunto A ; de lo contrario no pertenece. Aunque los conjuntos clásicos sirven para diversas aplicaciones, no reflejan la naturaleza de conceptos y razonamientos humanos, los cuales tiende a ser abstractos e imprecisos. Por ejemplo, matemáticamente se puede expresar el conjunto de personas altas como una colección de personas cuyas alturas son de más de 1.70 m; si $A = \text{"persona alta"}$ y $x = \text{"altura"}$. Aún ésta es una forma antinatural e inadecuada de representar el concepto usual de "persona alta". En primer lugar, la naturaleza dicotómica del conjunto clásico clasificaría a una persona 1.7001 m como una persona alta, pero no una persona 1.6999 m. Esta distinción es intuitivamente poco razonable. El fallo viene de la transición definida entre la inclusión y exclusión en un conjunto.

Un **conjunto difuso**, es un conjunto sin límite bien definido. Esto es, la transición entre “pertenece a un conjunto” y “no pertenece a un conjunto” es gradual, y esta transición suave es caracterizada por funciones de membresía que dan a los conjuntos difusos flexibilidad para modelar expresiones lingüísticas empleadas cotidianamente, tales como “el agua esta caliente” o “la temperatura es alta”. De acuerdo con Zadeh (1965) los conjuntos o clases definidos de manera imprecisa “desempeñan un papel importante en el pensamiento humano, particularmente en los dominios del reconocimiento de patrones, de la comunicación de la información y de la abstracción”. Lo difuso no viene de la aleatoriedad de los miembros constituyentes de los conjuntos, sino de la imprecisa e incierta naturaleza de pensamientos y conceptos abstractos.

A diferencia de los conjuntos convencionales anteriormente mencionados, un conjunto difuso expresa el grado para el cual un elemento pertenece a un conjunto. Por lo tanto la función característica de un conjunto difuso admite tener valores entre 0 y 1, lo cual denota el grado de membresía de un elemento en un conjunto dado.

Si X es una colección de objetos denotados genéricamente por x , entonces un **conjunto difuso** A en X , es definido como un conjunto de pares ordenados:

$$A = \{(x, \mu_A(x)) \mid x \in X\} \dots\dots\dots (3.2)$$

Donde $\mu_A(x)$ es conocida como la **función de membresía (MF)** para el conjunto difuso A . La MF transforma cada elemento de X hacia un grado de membresía (o valor de membresía) entre 0 y 1. La definición de un conjunto difuso es una simple extensión de la definición de un conjunto clásico, en el cual se permite que la función característica tome cualquier valor entre 0 y 1. Si los valores de la función de membresía $\mu_A(x)$ son restringidos a 0 o 1, entonces A es reducido a un conjunto clásico y $\mu_A(x)$ es la función característica de A .

Generalmente X es llamado el **universo de discurso**, o simplemente **universo**, el cual puede consistir de objetos discretos (ordenados o no ordenados) o ser un espacio continuo. La construcción de un conjunto difuso depende de dos cosas: la identificación de un universo de discurso adecuado y la especificación de una función de membresía apropiada.

La especificación de funciones de membresía es *subjetiva*, lo cual quiere decir que las funciones de membresía especificadas para el mismo concepto (dice, “número ideal de hijos en una familia”) por diferentes personas puede variar considerablemente. Esta subjetividad viene de diferencias individuales en percibir o expresar conceptos abstractos y tiene poco que ver con aleatoriedad. Por lo tanto, la subjetividad y la no aleatoriedad de conjuntos difusos es la diferencia primaria entre el estudio de conjuntos difusos y la teoría de probabilidades, la cual se encarga del tratamiento objetivo de fenómenos aleatorios.

Por simplicidad de notación, un conjunto difuso A puede denotarse como sigue:

$$A = \begin{cases} \sum_{x_i \in X} \mu_A(x_i) / x_i & \text{Si } X \text{ es una colección de objetos discretos.} \\ \int_X \mu_A(x) / x & \text{Si } X \text{ es un espacio continuo (normalmente la línea real } \mathbb{R} \text{).} \end{cases} \dots\dots\dots (3.3)$$

Los signos de sumatoria e integración en la ecuación 3.3, puestos para la unión de pares $(x, \mu_A(x))$; no indican sumatoria o integración. Similarmente, “/” es simplemente una marca y no implica división.

En la práctica, cuando el universo de discurso X es un espacio continuo (la línea real R o sus subconjuntos), generalmente X se divide en varios conjuntos difusos cuyas MFs cubren a X de una manera más o menos uniforme. Estos conjuntos se denominan valores lingüísticos o etiquetas lingüísticas y, normalmente, se les asignan nombres de adjetivos utilizados en el lenguaje común, tales como “grande”, “mediano” o “pequeño”. De esta manera, el universo de discurso X frecuentemente es llamado la variable lingüística.

Suponiendo que $X = \text{“edad”}$. Entonces se pueden definir conjuntos difusos “joven”, “adulto” y “viejo” que son caracterizados por MFs $\mu_{joven}(x)$, $\mu_{adulto}(x)$, y $\mu_{viejo}(x)$, respectivamente. Así como una variable puede asumir diversos valores, una variable lingüística “edad” puede asumir valores lingüísticos diferentes, tales como “joven”, “adulto” y “viejo” en este caso. Si “edad” asume el valor de “joven”, entonces tenemos la expresión “edad es joven” y así sucesivamente para los otros valores. Las MFs típicas para estos valores lingüísticos se muestran en la Figura 3.1, dónde el universo de discurso X está completamente cubierto de MFs y la transición de una MF a otra es suave y gradual.




Figura 3.1 Funciones de Membresía típicas de valores lingüísticos “joven”, “adulto” y “viejo”.

Unión, intersección, y complemento son las operaciones más básicas de conjuntos clásicos. Correspondiente a las operaciones de conjuntos ordinarios de unión, intersección y complemento, los conjuntos difusos tienen operaciones similares, las cuales fueron definidas por Zadeh (1965).

Un conjunto difuso A está **contenido** en un conjunto difuso B (o, equivalentemente, A es un **subconjunto** de B , o A es menor o igual que B) si y sólo si $\mu_A(x) \leq \mu_B(x)$ para toda x . Simbólicamente:

$$A \subseteq B \Leftrightarrow \mu_A(x) \leq \mu_B(x) \dots\dots\dots(3.4)$$

La figura 3.2 ilustra el concepto de $A \subseteq B$.




Figura 3.2 El concepto de $A \subseteq B$.

La **unión** de dos conjuntos difusos A y B es un conjunto difuso C , escrito como $C = A \cup B$ o $C = A \vee B$, cuya MF se relaciona con las de A y B por:

$$\mu_C(x) = \max(\mu_A(x), \mu_B(x)) = \mu_A(x) \vee \mu_B(x) \dots\dots\dots(3.5)$$

Zadeh (1965) señaló que una definición más intuitiva pero equivalente de unión es el “el más pequeño” conjunto difuso conteniendo A y B . Alternativamente, si D es cualquier

conjunto difuso que contiene A y B , luego también contiene $A \cup B$. La intersección de conjuntos difusos puede ser definida análogamente.

La **intersección** de dos conjuntos difusos A y B es un conjunto difuso C , escrito como $C = A \cap B$ o $C = A \text{ AND } B$, cuya MF se relaciona con las A y B por:

$$\mu_C(x) = \min(\mu_A(x), \mu_B(x)) = \mu_A(x) \wedge \mu_B(x) \dots\dots\dots(3.6)$$

Como en el caso de la unión, la intersección de A y B es el “más grande” conjunto difuso el cual esta contenido en A y B . Esto se reduce a la operación de intersección ordinaria si A y B son no difusos.

El **complemento** de un conjunto difuso A , denotado por $\bar{A}$ ($\neg A$, NOT A), se define como:

$$\mu_{\bar{A}}(x) = 1 - \mu_A(x) \dots\dots\dots(3.7)$$




Figura 3.3 Operaciones de conjuntos difusos: (a) dos conjuntos difusos A y B ; (b) $\bar{A}$; (c) $A \cup B$; (d) $A \cap B$.

Sean A y B conjuntos difusos en X y Y . El **producto cartesiano** de A y B , denotado por $A \times B$, es un conjunto difuso en el producto espacio $X \times Y$ con la función de membresía:

$$\mu_{A \times B}(x, y) = \min(\mu_A(x), \mu_B(y)) \dots\dots\dots(3.8)$$

Similarmente, el **co producto cartesiano** $A + B$ es un conjunto difuso con la función de membresía:

$$\mu_{A+B}(x, y) = \max(\mu_A(x), \mu_B(y)) \dots\dots\dots(3.9)$$

Ambos, $A \times B$ y $A + B$, son caracterizados por MFs bidimensionales.

3.2.2 Tipos de Funciones de Membresía

Funciones de membresía en una dimensión

Una **MF triangular** se especifica mediante tres parámetros $\{a, b, c\}$ de la siguiente manera:

$$triangulo(x; a, b, c) = \begin{cases} 0, & x \leq a \\ \frac{x-a}{b-a}, & a \leq x \leq b \\ \frac{c-x}{c-b}, & b \leq x \leq c \\ 0, & c \leq x \end{cases} \dots\dots\dots(3.10)$$

Usando operadores min y max, la expresión anterior se puede expresar de la siguiente manera:

$$triangulo(x; a, b, c) = \max\left(\min\left(\frac{x-a}{b-a}, \frac{c-x}{c-b}\right), 0\right) \dots\dots\dots(3.11)$$

Los parámetros $\{a, b, c\}$ (con $a < b < c$) determinan las coordenadas en x de los tres vértices de la MF triangular en cuestión. La figura 3.4(a) ilustra una MF triangular definida por el triángulo $(x; 20, 60, 80)$.

Una **MF trapezoidal** se especifica por cuatro parámetros $\{a, b, c, d\}$ de la siguiente manera:

$$trapezio(x; a, b, c, d) = \begin{cases} 0, & x \leq a \\ \frac{x-a}{b-a}, & a \leq x \leq b \\ 1, & b \leq x \leq c \\ \frac{d-x}{d-c}, & c \leq x \leq d \\ 0, & d \leq x \end{cases} \dots\dots\dots(3.12)$$

Esta MF se puede definir en una forma más concisa, empleando los operadores min y max:

$$trapezio(x; a, b, c, d) = \max\left(\min\left(\frac{x-a}{b-a}, 1, \frac{d-x}{d-c}\right), 0\right) \dots\dots\dots(3.13)$$

Los parámetros $\{a, b, c, d\}$ (con $a < b \leq c < d$) determinan las coordenadas en x de los cuatro vértices de la MF trapezoidal definida.

La figura 3.4(b) ilustra una MF trapezoidal definida por el trapezio $(x; 10, 20, 60, 95)$. Nótese que una MF trapezoidal con parámetros $\{a, b, c, d\}$ se reduce a una MF triangular cuando b es igual a c .

Debido a la sencillez de sus formulas y su eficiencia computacional, las MFs triangulares y trapezoidales han sido usadas ampliamente, especialmente en aplicaciones de tiempo real. Sin embargo, puesto que ambas funciones se componen de segmentos de líneas rectas, no son suaves en los puntos de los vértices especificados por los parámetros

Una **MF Gaussiana** se especifica con dos parámetros $\{c, \sigma\}$:

$$gauss(x; c, \sigma) = e^{-\frac{1}{2}\left(\frac{x-c}{\sigma}\right)^2} \dots\dots\dots(3.14)$$

Una MF Gaussiana se determina completamente por c y σ ; c representa el centro de la MF y σ determina su anchura. La figura 3.4(c) muestra una MF Gaussiana definida por $gauss(x; 50, 20)$.




Figura 3.4 Ejemplos de cuatro clases de MFs parametrizadas: (a) $triangulo(x; 20, 60, 80)$; (b) $trapecio(x; 10, 20, 60, 95)$; (c) $gauss(x; 50, 20)$; (d) $campana(x; 20, 4, 50)$.

Una **MF de tipo campana generalizada** (o **MF tipo campana**) se especifica mediante tres parámetros $\{a, b, c\}$:

$$campana(x; a, b, c) = \frac{1}{1 + \left| \frac{x - c}{a} \right|^{2b}} \dots\dots\dots(3.15)$$

Donde el parámetro b normalmente es positivo. (Si b es negativo la figura de esta MF llega a ser una campana invertida). Nótese que esta MF es una generalización directa de la función de distribución de Cauchy definida en la teoría de probabilidad, por ello también es referida como **MF de Cauchy**.

La figura 3.4(d) ilustra una MF de tipo campana generalizada, definida por la $campana(x; 20, 4, 50)$. Una generalización deseada de la MF de tipo campana se puede obtener por una selección adecuada del conjunto de parámetros $\{a, b, c\}$. Específicamente, se puede ajustar c y a al variar el centro y ancho de la MF, y después usar b para controlar las pendientes en los puntos de cruce.

A causa de su suavidad y notación concisa, las MF Gaussiana y tipo campana han llegado a ser cada vez más utilizadas para especificar conjuntos difusos. La MF tipo campana tiene un parámetro más que la Gaussiana, por lo cual tiene un grado más de libertad para ajustar sus pendientes en los puntos de cruce.

Una **MF Sigmoidal** esta definida por:

$$sig(x; a, c) = \frac{1}{1 + \exp[-a(x - c)]} \dots\dots\dots(3.16)$$

Donde a controla la pendiente en el punto de cruce $x = c$.

Dependiendo del signo del parámetro a , una MF sigmoideal es inherentemente abierta por la izquierda o por la derecha y de esta manera es apropiada para representar conceptos tales como “muy grande” o “muy negativo”. Las funciones sigmoideal de esta clase son empleadas ampliamente como la función de activación de redes neuronales artificiales.

Funciones de membresía bidimensionales

Una forma natural para ampliar MFs unidimensionales a MFs bidimensionales es vía extensión cilíndrica, definida a continuación.

Si A es un conjunto difuso en X , entonces su **extensión cilíndrica** en $X \times Y$ es un conjunto difuso $c(A)$ definido por:

$$c(A) = \int_{X \times Y} \mu_A(x)/(x, y) \dots\dots\dots(3.17)$$

Generalmente A es llamado **conjunto base**.

El concepto de extensión cilíndrica es ilustrado en la figura 3.5. La operación de proyección, por otra parte, disminuye la dimensión de una función de membresía (multidimensional) dada.




Figura 3.5 (a) Conjunto Base A ; (b) su extensión cilíndrica $c(A)$.

Las MFs de dos dimensiones caen en dos categorías: compuestas y no compuestas. Si una MF de dos dimensiones puede ser expresada como una expresión analítica de dos MFs de una dimensión, entonces esta es compuesta; de otra manera esta es no compuesta.




Figura 3.6 (a) Conjunto Difuso bidimensional R ; (b) R_X (proyección de R sobre X); y (c) R_Y (proyección de R sobre Y).

3.2.3 Sistemas de Inferencia Difuso

Variables lingüísticas

Una **variable lingüística** se caracteriza por un quintuplo $(x, T(x), X, G, M)$ en el cual x es el nombre de la variable; $T(x)$ es el **conjunto de términos** de x – que es, el conjunto de sus **valores lingüísticos** o **términos lingüísticos**; X es el universo de discurso; G es una **regla sintáctica** la cual genera los términos en $T(x)$; y M es una **regla semántica** la cual asocia con cada valor lingüístico A su significado $M(A)$, donde $M(A)$ denota un conjunto difuso en X .

Si *edad* es interpretada como una variable lingüística entonces su término conjunto $T(edad)$ podría ser:

$$T(edad) = \{joven, no joven, muy joven, no muy joven, ..., \\ adulto, no adulto, ..., \\ viejo, no viejo, muy viejo, más o menos viejo, no muy viejo, ..., \\ no muy joven y no muy viejo, ...\} \quad \dots\dots\dots(3.18)$$

Donde cada término en $T(edad)$ es caracterizado por un conjunto difuso de universo de discurso $X = [0, 100]$, como se muestra en la figura 3.7. Usualmente se usa “edad es joven” para denotar la asignación del valor lingüístico “joven” a la variable lingüística *edad*. Por comparación, cuando *edad* se interpreta como una variable numérica, se usa la expresión “edad = 20” para asignar el valor numérico “20” a la variable numérica *edad*. La regla sintáctica se refiere a la forma en que los valores lingüísticos en el término conjunto $T(edad)$ son generados. La regla semántica define la función de membresía de cada valor lingüístico del término conjunto; la figura 3.7 muestra algunas de las funciones de membresía típicas.




Figura 3.7 Funciones de membresía típicos del conjunto de término $T(edad)$.

Reglas difusas Si-Entonces

Una **regla difusa Si-Entonces** (también conocida como **regla difusa**, **implicación difusa** o **declaración condicional difusa**) asume la forma:

Si x es A **Entonces** y es B(3.19)

Donde A y B son valores lingüísticos definidos por conjuntos difusos en los universos de discurso X y Y , respectivamente. Frecuentemente a “ x es A ” se le llama el **antecedente** o **premisa**, mientras que a “ y es B ” se le llama el **consecuente** o **conclusión**. En el lenguaje cotidiano se emplean muy a menudo expresiones lingüísticas tales como:

- Si la presión es alta, entonces el volumen es pequeño.
- Si la carretera esta resbaladiza, entonces el manejo es peligroso.
- Si el jitomate es rojo, entonces está maduro.
- Si la velocidad es alta, entonces se aplican los frenos ligeramente.

Razonamiento difuso

El razonamiento difuso, también conocido como razonamiento aproximado, es un procedimiento de inferencia que deriva conclusiones a partir de un conjunto de reglas difusas *si-entonces* y hechos conocidos.

La regla de inferencia básica en lógica tradicional es el **modus ponens**, de acuerdo con el cual es posible inferir la veracidad de una proposición B a partir de la veracidad de A y la implicación $A \rightarrow B$. Por ejemplo, si A se identifica con el hecho “el jitomate es rojo”, y B con “el jitomate esta maduro”, entonces, si el hecho “el jitomate es rojo” es cierto, entonces el hecho “el jitomate esta maduro” también será cierto. Este concepto se ilustra de la siguiente manera:

premisa 1 (hecho):	x es A
premisa 2 (regla):	<u>si x es A entonces y es B</u>
consecuencia (conclusión):	y es B

Sin embargo, en mucho del razonamiento humano, el modus ponens es empleado en una manera aproximada. Por ejemplo, si se tiene la misma regla implicación “si el jitomate es rojo, entonces está maduro” y si se sabe además que “el jitomate es más o menos rojo”, entonces se puede inferir que “el jitomate esta más o menos maduro”. Esto se escribe como:

premisa 1 (hecho):	x es A'
premisa 2 (regla):	<u>si x es A entonces y es B</u>
consecuencia (conclusión):	y es B'

donde A' es cerrado a A y B' es cerrado a B . Cuando A , B , A' y B' son conjuntos difusos de universos adecuados, el procedimiento de inferencia anterior se llama **razonamiento aproximado** o **razonamiento difuso**; también es llamado **modus ponens generalizado** (abreviado **GMP**), dado que tiene al modus ponens como un caso especial.

Modelos difusos de Mamdani

El **sistema de inferencia difuso de Mamdani** (Jang et al, 1997) fue propuesto como un primer intento de controlar una maquina de vapor y la combinación de la caldera, mediante un conjunto de reglas de control lingüísticas obtenidas de operadores humanos experimentados. En la aplicación de Mamdani, se usaron dos sistemas de inferencia difusa como dos controladores para generar el calor entrante a la caldera y a la apertura de la válvula de admisión del cilindro del motor, para regular la presión del vapor en la caldera y la velocidad del motor, respectivamente,. Dado que la planta únicamente puede aceptar valores definidos como entradas, se tiene que emplear un defusificador para convertir un conjunto difuso en un valor definido o concreto.

Modelos difusos de Tsukamoto

En el **modelo difuso de Tsukamoto**, el consecuente de cada regla difusa si-entonces se representa por un conjunto difuso con una MF monotonica. Como resultado, la salida inferida por cada regla es definida como un valor inducido por la fuerza de activación de la regla. La salida global se toma como la media ponderada de cada salida de la regla. Dado que cada regla infiere una salida definida, el modelo difuso de Tsukamoto agrega cada salida de la regla por el método de media ponderada y así se elimina el consumo de tiempo del proceso de defusificación. Sin embargo, el modelo difuso de Tsukamoto no es muy usado por no ser tan transparente como los modelos difusos de Mamdani o de Sugeno.

Modelo difuso de Sugeno

El **modelo difuso de Sugeno** (también conocido como el modelo difuso de **TSK**) fue propuesto inicialmente por Takagi, Sugeno y Kang (Jang et al, 1997) en un esfuerzo por desarrollar un método (aproximación) sistemático para generar reglas difusas a partir de un conjunto dado de datos de entrada-salida. Una regla difusa típica en un modelo difuso tipo Sugeno tiene la forma:

$$\text{Si } x \text{ es } A \text{ y } y \text{ es } B \text{ entonces } z = f(x, y) \dots\dots\dots(3.20)$$

Donde A y B son conjuntos difusos en la parte de antecedentes y $z = f(x, y)$ es una función definida (concreta) en la parte de consecuentes. Usualmente $f(x, y)$ es un polinomio dependiente de las variables de entrada x y y , pero, en general, puede ser cualquier función que pueda describir apropiadamente la salida del modelo dentro de la región difusa especificada por el antecedente de la regla. Cuando $f(x, y)$ es un polinomio de primer orden, el sistema de inferencia difuso resultante es llamado un **modelo difuso de Sugeno de primer orden**. Cuando f es una constante, se tiene un **modelo difuso de Sugeno de orden cero**. Además, un modelo difuso de Sugeno de orden cero es funcionalmente equivalente a una red neuronal de función de base radial (RBFN: Radial Basis Function Network) bajo ciertas restricciones menores (Jang et al, 1997).

La salida de un modelo de Sugeno de orden cero es una función suave de sus variables de entrada, a condición de que las vecindades de sus MF en el antecedente tengan suficiente traslape. En otras palabras, el traslape de las MFs en el consecuente de un modelo de Mamdani no tiene un efecto decisivo en la suavización; este es el traslape de las MFs antecedentes que determina la suavidad del comportamiento de entrada-salida resultante.

La figura 4.8 muestra el procedimiento de razonamiento difuso para un modelo difuso de Sugeno de primer orden. Dado que cada regla tiene una salida definida, la salida global se obtiene mediante una **media ponderada**. En la práctica, el operador media

ponderada a veces es reemplazado con el operador **suma ponderada** (esto es, $z = w_1 z_1 + w_2 z_2$ en la figura 4.8), a fin de reducir los cálculos, especialmente en el entrenamiento de un sistema de inferencia difuso.




Figura 3.8 Modelo de razonamiento difuso de Sugeno (Jang et al, 1997).

Sin el consumo de tiempo y sin la operación de defuzificación que es matemáticamente intratable, el modelo difuso de Sugeno es por mucho el candidato más popular para modelado difuso basado en conjuntos de datos de muestreo.

3.2.4 Métodos para formación de reglas difusas

El antecedente de una regla difusa define una región difusa, mientras que el consecuente describe el comportamiento dentro de esa región mediante varios componentes. El consecuente componente puede ser un consecuente MF, un valor constante (modelo de Sugeno de orden cero) o una ecuación lineal (modelo de Sugeno de primer orden). Los diferentes consecuentes constituyentes resultan en sistemas de inferencia difuso diferentes, pero sus antecedentes son siempre los mismos. Por lo tanto, los siguientes

métodos de partición (Jang et al, 1997) de espacios de entrada para formar los antecedentes de reglas difusas son aplicables a los tipos de inferencia difusa.

- **Partición de rejilla.** Este método de partición se usa frecuentemente en el diseño de controladores difusos, que generalmente implican pocas variables de estado como las entradas al controlador. Esta estrategia de partición sólo requiere un pequeño número de MFs para cada entrada. Sin embargo, tiene algunos problemas cuando se tiene un número moderado o creciente de variables de entrada. Por ejemplo, un modelo difuso con 10 entradas y dos MFs por cada entrada, podría resultar en $2^{10} = 1024$ reglas si-entonces difusas, lo cual es prohibitivamente grande. Generalmente, se refiere a este problema como **la maldición de la dimensionalidad**, y puede ser resuelto por otras estrategias de partición. La figura 3.9(a) muestra este tipo de partición.
- **Partición de árbol.** En este caso cada región se puede especificar en forma única a través de un árbol de decisiones correspondiente (ver figura 3.9(b)). Esta partición resuelve el problema de un incremento exponencial del número de reglas. Sin embargo, se requieren más MFs en cada entrada para definir tales regiones difusas, y esas MFs generalmente no siempre tienen un claro significado lingüístico tal como “pequeño”, “grande”, etc. En otras palabras, la ortogonalidad se mantiene aproximadamente en $X \times Y$ pero no en X o Y solamente. Esta partición es usada por el algoritmo CART (árbol de clasificación y regresión).
- **Partición dispersa.** Cubre un subconjunto del espacio de entrada entero que caracteriza una región de posible ocurrencia de los vectores entrada, con esta partición se puede limitar el número de reglas a una cantidad razonable. Sin embargo, esta partición normalmente se define por los pares de datos de entrada-salida deseados, debido a esto no se mantiene ortogonalidad en X , Y o en $X \times Y$. Esto hace difícil estimar la función de transformación global directamente de los consecuentes de cada salida de las reglas. Véase la figura 3.9(c).




Figura 3.9 Métodos de partición del espacio de entrada: (a) partición de rejilla, (b) partición de árbol y (c) partición dispersa.

Procedimiento de Modelado Difuso

Conceptualmente, el modelado difuso puede dividirse en dos etapas que no son totalmente independientes. La primera etapa es la identificación de la **estructura de la superficie**, la cual incluye las siguientes tareas:

1. Seleccionar las variables de entrada y salida relevantes.
2. Escoger un tipo específico de sistemas de inferencia difuso.
3. Determinar el número de términos lingüísticos asociados con cada variable de entrada-salida. (Para un modelo de Sugeno, se debe determinar el orden de las ecuaciones del consecuente).
4. Diseñar un conjunto de reglas si-entonces.

Se puede notar que para cumplir con las tareas anteriores, se depende del conocimiento (sentido común, leyes físicas simples, etc) que se tiene del sistema objetivo, información proporcionada por humanos expertos quienes están familiarizados con el sistema objetivo (el cual podrían ser los mismos humanos expertos), o simplemente prueba y error.

Después de la primera etapa de modelado difuso, se obtiene una base de reglas que puede describir en forma aproximada el comportamiento del sistema objetivo por medio

de los términos lingüísticos. El significado de estos términos lingüísticos se determina en la segunda etapa, la identificación de **estructura profunda**, la cual determina las MFs de cada término lingüístico. Esta etapa incluye las siguientes tareas:

1. Escoger una familia apropiada de MFs parametrizadas.
2. Consultar expertos humanos familiarizados con el sistema objetivo para determinar los parámetros de las MFs usadas en la base de reglas.
3. Refinar los parámetros de las MFs usando técnicas de regresión y optimización.

Las tareas 1 y 2 suponen la disponibilidad de humanos expertos, mientras que la tarea 3 asume la disponibilidad de un conjunto de datos de entrada-salida deseado. Cuando un sistema de inferencia difuso se usa como un controlador para una planta dada, luego el objetivo en la tarea 3 debería cambiarse por la búsqueda de parámetros que generarán el mejor funcionamiento de la planta (Jang, *et al.*, 1997).

3.3 Redes Neuronales

Las redes neuronales constituyen una poderosa herramienta para modelar sistemas, especialmente no lineales, sean dinámicos o estáticos. El cerebro humano es un sistema muy complejo formado por muchas células llamadas neuronas. Las redes neuronales artificiales emulan la arquitectura y capacidades de sistemas neuronales biológicos (Villaseñor, 2003).

Las redes neuronales (Neural Networks, NNs) consisten normalmente de un número de elementos de procesamiento (PEs) o neuronas interconectadas. Las conexiones son arreglos entre neuronas y la naturaleza de éstas determina la estructura de la red. Como la fuerza de las conexiones es ajustada o entrenada para alcanzar un comportamiento deseado, la red es gobernada por sus algoritmos de aprendizaje. Las redes neuronales pueden ser clasificadas de acuerdo a sus estructuras o algoritmos de aprendizaje (Ferreya, 2005). En términos de su estructura, las NNs pueden ser divididas en dos

tipos: redes neuronales unidireccionales (Feedforward neural networks) y redes neuronales recurrentes (Recurrent Neural Networks).

Feedforward neural networks (FFNNs). En una FFNN, las neuronas son normalmente agrupadas en capas. Las señales fluyen desde la capa de entrada hasta la capa de salida vía conexiones unidireccionales, las neuronas son conectadas de una capa a la siguiente, pero no dentro de la misma capa. Ejemplos de FFNNs incluyen la perceptrón multicapa (MLP), la red de vector de cuantización de aprendizaje (LVQ), red de control de articulación del modelo cerebral (CMAC) y la red de manejo de datos con método de grupos (GMDH). La mayoría de FFNNs normalmente realizan un mapeo estático entre un espacio de entrada y un espacio de salida: la salida en un instante dado es una función sólo de la entrada en ese instante.

Recurrent neural networks (RNNs). En una RNN, las salidas de algunas neuronas son retroalimentadas a las mismas neuronas o a neuronas en capas precedentes. Así, las señales pueden fluir tanto en direcciones hacia adelante como hacia atrás. Ejemplos de RNNs incluyen a la Red de Hopfield, La red Elman y la red Jordan. Las RNNs tienen una memoria dinámica: sus salidas en un instante dado reflejan las entradas actuales, así como las entradas y salidas previas.

Clasificación según el algoritmo de aprendizaje.

Las RNs son entrenadas por dos tipos principales de algoritmos de aprendizaje (Ferreyra, 2005): algoritmos de aprendizaje supervisado y no supervisado. Además, existe un tercer tipo, aprendizaje con reforzamiento, que puede ser considerado como una forma especial del aprendizaje supervisado.

Aprendizaje supervisado: Un algoritmo de aprendizaje supervisado ajusta las fuerzas o pesos de las conexiones entre neuronas de acuerdo a la diferencia entre las salidas deseada y actual de la red correspondientes a una entrada dada. De esta manera, el aprendizaje supervisado requiere un maestro o supervisor para proporcionar las señales

de salida deseadas u objetivo. Ejemplos de algoritmos de aprendizaje supervisado incluyen la regla delta, la regla delta generalizada o algoritmo de retropropagación y el algoritmo LVQ.

Aprendizaje no supervisado: Los algoritmos de aprendizaje supervisado no requieren que la salida deseada se conozca. Durante el entrenamiento, sólo los patrones de entrada son presentados a la NN que automáticamente adapta los pesos de sus conexiones para agrupar los patrones de entrada dentro de grupos con características similares. Ejemplos de algoritmos de aprendizaje no supervisado incluyen: el algoritmo de Kohonen, la teoría de resonancia adaptiva de Carpenter y Grossberg, y los algoritmos de aprendizaje competitivo.

Aprendizaje con reforzamiento: Como se mencionó anteriormente, el aprendizaje reforzado es un caso especial del aprendizaje supervisado. En lugar de utilizar un maestro para proporcionar las salidas deseadas, un algoritmo de aprendizaje reforzado emplea un crítico sólo para evaluar la calidad de la salida de la NN correspondiente a una entrada dada. Un ejemplo de un algoritmo de aprendizaje reforzado es el algoritmo genético (GA).

Tipos de redes neuronales

El perceptrón multicapa es una estructura jerárquica que consiste en varias capas de neuronas totalmente interconectadas, que admiten como entradas las salidas de los elementos de proceso (neuronas) de la capa anterior.

En las redes perceptrón multicapa se distinguen tres tipos de capas (Villaseñor, 2003):

- Capa de entrada. Esta formada por n unidades (siendo n el número de entradas externas) que se limitan a distribuir las señales de entrada a la capa siguiente.
- Capas ocultas. Están formadas por neuronas que no tienen contacto físico con el exterior. El número de capas ocultas es variable, pudiendo incluso ser nulo.

- Capa de salida. Está formado por m neuronas (siendo m el número de salidas externas) cuyas salidas constituyen el vector de salidas externas del perceptrón multicapa.

Los modelos dinámicos neuronales están dados por:

$$y(t) = N(y(t-1, \dots, y(t-n_y), u(t-1), \dots, u(t-n_u))) \dots \dots \dots (3.21)$$

donde N es la red neuronal que puede ser un perceptrón multicapa, como se muestra en la figura 3.10.




Figura 3.10 Perceptrón multicapa.

Las redes recurrentes son capaces de representar sistemas realimentados dinámicos no lineales (Narendra, 1990). Existen diversos modelos neuronales que son combinaciones de las redes perceptrón multicapa y redes recurrentes.




Figura 3.11 Red neuronal tipo recurrente.

Las neuronas Adaline tienen capacidad de aprendizaje debido a que sus pesos son cambiados adaptivamente de acuerdo a un algoritmo adaptable. Sus aplicaciones principales son: filtrado adaptable de señales y reconocimiento de patrones. Son fáciles de implementar en hardware debido a su sencillez y homogeneidad, sin embargo sólo son capaces de resolver problemas de clasificación linealmente separables y llevar a cabo transformaciones lineales.

En los Mapas Autoorganizativos de Kohonen las neuronas están ordenadas topológicamente. Frente a la presentación de un patrón n -dimensional de entrada, compiten lateralmente hasta que sólo una de ellas queda activa. El objetivo es que patrones de entrada con características parecidas queden asociados a neuronas topológicamente cercanas. Sus principales aplicaciones son: agrupación y representación de datos, compresión de datos y optimización (Villaseñor, 2003).

3.4 Modelado neuro-difuso

El modelado neuro-difuso se refiere a la manera de aplicar varias técnicas de aprendizaje desarrolladas en redes neuronales al modelado difuso o a un sistema de inferencia difuso (FIS). Los pesos de las neuronas en la red definen los parámetros de premisa y consecuente de un sistema de inferencia difuso. Los parámetros premisa determinan la forma y tamaño de las funciones de membresía de entrada, mientras que los parámetros consecuentes determinan las características de las funciones de membresía de salida y definen las reglas guiando el sistema de inferencia difuso (Nayak, 2004).

En un sistema neuro-difuso, las redes neuronales ayudan al sistema difuso para producir funciones de membresía, asociación de conjuntos difusos a reglas difusas e implementan la defusificación. El modelado neuro-difuso consta de un sistema difuso y una red neuronal que equipa a dicho sistema con la capacidad de aprender.

Tien y Van Straten (1998), Tien (1997), desarrollaron un sistema neuro-difuso llamado NUFZY para predecir sistemas no lineales. El sistema NUFZY es aplicado para predecir el crecimiento de un cultivo de lechuga bajo invernadero y la temperatura del aire de un invernadero a partir de datos experimentales. Los resultados mostraron que el modelo NUFZY puede llevar a cabo de manera aceptable la predicción tanto del crecimiento de la lechuga como la temperatura del invernadero. En contraste con el procedimiento de modelado mecanicista, los modelos neuro-difusos ofrecen una ruta más fácil y un modo rápido de construir el mapeo de entradas y salidas no lineales (Tien y Van Straten, 1998).

3.4.1 Sistema neuro-difuso ANFIS

El modelo ANFIS (Adaptive Neuro-based Fuzzy Inference System) fue desarrollado por Jang (1993) y es funcionalmente equivalente a los sistemas de inferencia difusos. Las capacidades adaptativas de las redes ANFIS las hacen directamente aplicables a una gran cantidad de áreas como control adaptable, procesamiento y filtrado de señales,

clasificación de datos y extracción de características a partir de ejemplos. Una propiedad interesante del modelo, es que el conjunto de parámetros se puede descomponer para utilizar una regla de aprendizaje híbrido más eficiente que los mecanismos tradicionales (Jang, 1993). Una descripción de ANFIS es como sigue:

Suponiendo que el sistema de inferencia difuso tiene dos entradas x y y y una sola salida z . Además, que tiene dos reglas difusas *Si-Entonces* (*if-then*) de tipo Takagi-Sugeno:

Regla1: If x is A_1 and y is B_1 , then $f_1 = p_1x + q_1y + r_1$
 Regla2: If x is A_2 and y is B_2 , then $f_2 = p_2x + q_2y + r_2$




Figura 3.12 Razonamiento difuso.

La figura 3.12 ilustra el mecanismo de razonamiento para este modelo, la arquitectura ANFIS equivalente al mecanismo de razonamiento utilizado para este modelo se presenta en la figura 3.13, donde los nodos situados en la misma capa realizan funciones similares como se describe a continuación:

Capa 1: Los nodos de esta capa son adaptativos, cada nodo i en esta capa es un nodo cuadrado (ver figura 3.13) con una función:

$$O_i^1 = \mu_{A_i}(x) \dots \dots \dots (3.22)$$

donde x es la entrada al nodo i , A_i es la etiqueta lingüística (*pequeño*, *grande*, etc) asociada con esta función nodo. En otras palabras, O_i^1 es la función de membresía de A_i y especifica el grado para el cual x satisface A_i . En este modelo $\mu_{A_i}(x)$ se escoge acampanada con máximo y mínimo igual a 1 y 0 respectivamente, tal como la función *campana generalizada*.

$$\mu_{A_i}(x) = \frac{1}{1 + \left[\left(\frac{x - c_i}{a_i} \right)^2 \right]^{b_i}} \dots \dots \dots (3.23)$$

o la *función Gaussiana*

$$\mu_{A_i}(x) = \exp \left[- \left(\frac{x - c_i}{a_i} \right)^2 \right] \dots \dots \dots (3.24)$$

donde (a_i, b_i, c_i) es el conjunto de parámetros. Los parámetros de esta capa se conocen como *parámetros de premisa*.




Figura 3.13 Arquitectura ANFIS equivalente para inferencia Takagi-Sugeno.

Capa 2: Cada nodo en esta capa (circulo en figura 3.13 con la etiqueta Π) multiplica las señales entrantes y emite el producto. Por ejemplo,

$$w_i = \mu_{A_i}(x) \times \mu_{B_i}(y), i = 1, 2. \dots \dots \dots (3.25)$$

Cada nodo salida representa la fuerza de disparo (firing strength) de una regla. De hecho, otros operadores T-norma que realizan operaciones lógicas AND generalizadas se pueden emplear como la función de nodo en esta capa. Cada nodo de esta capa es no adaptativo.

Capa 3: Los nodos de esta capa son no adaptativos. Cada nodo en esta capa es un nodo circular etiquetado N (figura 3.13). El i -ésimo nodo calcula la proporción de la fuerza de disparo (firing strength) de la i – ésima regla a la suma de todas las fuerzas de disparo:

$$\bar{w}_i = \frac{w_i}{w_1 + w_2}, i = 1, 2. \dots \dots \dots (3.26)$$

Por conveniencia, las salidas de esta capa se llaman *fuerzas de disparo normalizadas* (normalized firing strengths).

Capa 4: Cada nodo i en esta capa es un nodo cuadrado con una función de nodo:

$$O_i^4 = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i) \dots \dots \dots (3.27)$$

donde $\bar{w}_i$ es la salida de la capa 3, y $\{p_i, q_i, r_i\}$ es el conjunto de parámetros conocidos como *parámetros consecuentes*. El nodo de esta capa es adaptativo.

Capa 5: El único nodo de esta capa es un nodo circular etiquetado Σ que calcula la salida total como la suma de todas las señales de entrada:

$$O_1^s = \text{salida total} = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} \dots\dots\dots(3.28)$$

De esta manera se ha construido una red adaptable, la que es funcionalmente equivalente al sistema de inferencia mostrado en la figura 3.12, por lo cual es llamada ANFIS, aludiendo a los sistemas de inferencia difusos basados en redes adaptables, donde la salida de cada regla es inducida conjuntamente por la función de membresía de salida y la fuerza de disparo (firing strength).

Algoritmo de aprendizaje híbrido

De la arquitectura ANFIS (figura 3.12 y 3.13), puede observarse que dados los valores de los parámetros de la premisa, la salida total puede expresarse como las combinaciones lineales de los parámetros del consecuente. En otras palabras, la salida f se puede reescribir como:

$$\begin{aligned} f &= \frac{w_1}{w_1 + w_2} f_1 + \frac{w_2}{w_1 + w_2} f_2 \\ &= \bar{w}_1 f_1 + \bar{w}_2 f_2 \dots\dots\dots(3.29) \\ &= (\bar{w}_1 x) p_1 + (\bar{w}_1 y) q_1 + (\bar{w}_1) r_1 + (\bar{w}_2 x) p_2 + (\bar{w}_2 y) q_2 + (\bar{w}_2) r_2 \end{aligned}$$

la cual es lineal en los parámetros consecuentes (p_1 , q_1 , r_1 , p_2 , q_2 y r_2). Como resultado se tiene:

- S = conjunto de parámetros totales.
- S₁ = conjunto de parámetros premisa (no lineales).
- S₂ = conjunto de parámetros consecuente (lineales).

Jang (1993) señala que para aplicar el aprendizaje híbrido en grupo, en cada época de entrenamiento debe ejecutarse un paso *forward* y un paso *backward*. En el paso *forward*

las señales funcionales (nodos de salida) van adelante hacia la capa 4 y los parámetros de consecuencia son identificados por el estimador de mínimos cuadrados. En el paso *backward*, los índices de error se propagan hacia atrás y los parámetros de premisa se actualizan por el método del gradiente descendiente. La siguiente tabla resume las actividades en cada paso.

Tabla 3.1 Dos pasos en el proceso de aprendizaje híbrido para ANFIS.

	Paso hacia delante (<i>Forward Pass</i>)	Paso hacia atrás (<i>Backward Pass</i>)
Parámetros Premisa	Fijo	Gradiente Descendente
Parámetros Consecuente	Estimador Mínimos Cuadrados	Fijo
Señales	Salidas Nodo	Índices de Error

Cabe mencionar que los parámetros de los consecuentes identificados por el método de mínimos cuadrados son óptimos bajo la condición que los parámetros de los antecedentes (premisas) estén fijos. Este enfoque híbrido, converge más rápidamente que el método original de retro-propagación (backpropagation), ya que se reducen las dimensiones del espacio de búsqueda. Sin embargo, es claro que la complejidad computacional del estimador de mínimos cuadrados es más alta que el método del gradiente descendiente. En general pueden utilizarse cuatro métodos para actualizar los parámetros, como se listan a continuación de acuerdo a su complejidad computacional:

1. Únicamente Gradiente Descendente: todos los parámetros son actualizados mediante el método del gradiente descendiente.
2. Gradiente Descendente y Un Paso de LSE (estimador mínimos cuadrados): El LSE es aplicado solamente en la primera época para estimar los valores iniciales de los parámetros consecuentes y en las siguientes etapas se modifican los parámetros por el método del gradiente descendiente.
3. Gradiente Descendente y LSE: esta es la regla de aprendizaje híbrido propuesto por Jang (1993). Se aplican ambos métodos en cada iteración.
4. Únicamente LSE Secuencial (Aproximación): el ANFIS es linealizado con respecto a todos los parámetros premisa y se emplea el algoritmo extendido del filtro de Kalman para actualizar todos los parámetros.

Si el tamaño del conjunto de datos de entrada – salida disponible es bastante grande, entonces es aplicable (o incluso necesario) el ajuste de las funciones de membresía ya que la determinación humana de dichas funciones esta sujeta a diferencias de persona a persona y de tiempo en tiempo; por lo tanto son raramente óptimos en términos de reproducción de salidas deseadas. Sin embargo, si el conjunto de datos es demasiado pequeño, entonces probablemente no contiene suficiente información del sistema bajo consideración. En esta situación, la determinación humana de las funciones de membresía representa conocimiento importante obtenido a través de las experiencias de humanos expertos y esto no puede ser reflejado en el conjunto de datos; por lo tanto las funciones de membresía deberían de mantenerse fijas durante el proceso de aprendizaje.

3.4.2 Identificación del sistema

El problema de determinar un modelo matemático para un sistema desconocido (también llamado **sistema objetivo**) observando sus pares de datos de entrada-salida generalmente es llamado **identificación del sistema** (Nelles, 2001) . En general, el modelado neuro-difuso es una rama de la identificación de sistemas y también involucra dos fases: la identificación de la estructura y la identificación de los parámetros. Lo anterior está relacionado con encontrar un número apropiado de reglas y una partición adecuada del espacio característico. Lo último tiene que ver con el ajuste de los parámetros del sistema, tal como las funciones de membresía, coeficientes lineales, etc.

Identificación de la estructura

En este paso, se necesita aplicar un conocimiento *a priori* acerca del sistema objetivo para determinar una clase de modelos dentro de los cuales se pueda buscar el modelo más adecuado. Generalmente esta clase de modelos se denota por una función parametrizada $y = (\mathbf{u}; \boldsymbol{\theta})$, donde y , $\mathbf{u}$ es el vector de entrada y $\boldsymbol{\theta}$ es el vector de parámetros. La determinación de la función f es dependiente del problema y la función está basada en la experiencia e intuición del diseñador y en las leyes que gobiernan la

naturaleza del sistema objetivo. La identificación de la estructura en el modelado neuro-difuso involucra los siguientes aspectos (Jang et al, 1997):

- Seleccionar las variables de entrada relevantes.
- Determinar una arquitectura ANFIS inicial, incluyendo
 1. Partición del espacio de entrada.
 2. Número de funciones de membresía para cada entrada.
 3. Número de reglas difusas si-entonces (if-then).
 4. Partes antecedente (premisas) de reglas difusas.
 5. Partes consecuente (conclusión) de reglas difusas.
- Escoger parámetros iniciales para funciones de membresía.

Cuando no se dispone de conocimiento a priori, la identificación de la estructura se transforma en un problema muy complicado y algunas veces se requiere la utilización de métodos de prueba y error. Por esto se han desarrollado varios mecanismos tendientes a automatizar algunas etapas de esta tarea. Se pueden mencionar, entre otros, el enfoque CART (Classification And Regression Tree), métodos iterativos y una gran cantidad de algoritmos de agrupamiento (clustering).

Los algoritmos de agrupamiento son utilizados ampliamente, no solamente para la construcción de modelos, sino también en aplicaciones de compresión, organización y clasificación de información. Algunos de estos son C-Means (o K-Means) Clustering, Fuzzy C-Means Clustering, Mountain Clustering y Subtractive clustering. Se describen brevemente a continuación.

Agrupación sustractiva (Subtractive Clustering)

Este enfoque fue propuesto por Chiu (1994) como una extensión del método “mountain clustering”. El método Mountain Clustering es relativamente simple y efectivo, pero la complejidad del cálculo crece exponencialmente con la dimensión del problema debido a la evaluación de la función de densidad sobre todos los puntos de la rejilla. En el

agrupamiento sustractivo los puntos considerados como candidatos a un grupo son los propios datos y no los puntos de alguna rejilla. De este modo el tiempo de computación es proporcional al número de datos e independiente de la dimensión del problema. Unos de los parámetros necesarios para el funcionamiento del algoritmo es el radio el cual puede ser un vector ó un escalar que varía entre cero y uno. Este especifica el rango de influencia del centro de los grupos en cada una de las dimensiones de los datos. Valores pequeños para este radio, generan una gran cantidad de grupos, valores aceptables para este parámetro generalmente están entre 0.2 y 0.5. El algoritmo de agrupamiento sustractivo realiza los siguientes pasos:

1. Selecciona el punto con el más alto potencial para ser el centro de un grupo.
2. Remueve todos los puntos en la vecindad del primer centro del grupo basándose en el radio, de esta manera se determina la ubicación del siguiente punto que será el centro de un grupo.
3. Continúa iterando hasta que todos los puntos acorde con el radio especificado, pertenezcan a un grupo.

Si no se emplea cualquier técnica de identificación de la estructura en el modelado difuso, se tiene que aceptar la simple partición de rejilla del espacio de entrada. Sin embargo, esto conduce a la “maldición de la dimensionalidad” cuando el número de variables de entrada es grande. Una forma de aliviar este problema es emplear esquemas de selección de entradas para escoger las entradas relevantes para llevar a cabo la tarea de modelado. Otra manera de reducir el problema del crecimiento exponencial de las reglas base es tener una forma sofisticada de partición del espacio de entrada.

Selección de entradas

Generalmente la suposición de que todas las entradas tienen la misma importancia en aplicaciones de reconocimiento de patrones, predicción de series de tiempo, no es verdadera. El primer paso en un esquema general de modelado debe ser una **partición**

de entradas o selección característica, el cual puede identificar un subconjunto de todas las entradas posibles como la estradas reales en la estructura ANFIS.

Partición del espacio de entrada

La parte premisa de un sistema de inferencia difuso implementa una partición difusa en el espacio de entrada multidimensional. Un modelo ANFIS basado en la partición de rejilla forma la partición de rejilla adaptable. En otras palabras, en el inicio del entrenamiento, se toma una rejilla partida uniformemente como el estado inicial. El método del descenso más pronunciado (steepest descent) o cualquier técnica de optimización puede encontrar la localización y tamaño óptimo de las regiones difusas y el grado de traslape entre ellos. Existen dos problemas en este esquema. El primero es que el número de términos lingüísticos para cada variable de entrada es predeterminado y altamente heurístico. El segundo, la complejidad de aprendizaje sufre una explosión exponencial tanto como el número de incrementos de entradas.

La partición de rejilla aporta la estructura más restringida; en el otro extremo los algoritmos de agrupamiento difuso basados en el entrenamiento de datos dan como resultado la más flexible partición dispersa. Sin embargo, esta aproximación tiene sus propios problemas:

1. Las estructuras resultantes no son necesariamente hiper-rectángulos, necesitan ser refinados.
2. El costo tiende a ser alto porque no se garantiza la eficacia de convergencia.
3. El número total de reglas (clusters) es predeterminado en estos algoritmos. Cuando la partición resultante no es bastante buena y se quiere incrementar el número de reglas, se tiene que repetir el algoritmo de clustering desde el principio.

Sin embargo, en el contexto de entrenamiento de red adaptable no se necesita encontrar un agrupamiento perfecto, ya que el objetivo es encontrar un estado inicial satisfactorio

para ajustar la red. En otras palabras, ya que se ha verificado la validez del mecanismo de identificación de parámetros usando redes adaptivas, tiene poco sentido gastar una gran cantidad de tiempo en optimizar el criterio de cluster, no importa lo que las funciones objetivos podrían ser. Si no se tiene un conocimiento *a priori* acerca del sistema objetivo, entonces la identificación de la estructura llega a ser un problema complicado y algunas veces se deben aplicar métodos de prueba y error.

Identificación de los parámetros

En el segundo paso, la estructura del modelo es conocida y todo lo que se tiene que hacer es aplicar técnicas de optimización para determinar el vector de parámetros $\theta = \hat{\theta}$ tal que el modelo resultante $\hat{y} = (u; \hat{\theta})$ puede describir apropiadamente el sistema apropiadamente. Se deben ajustar los valores de los parámetros que lo componen de manera que el modelo pueda describir en forma mas satisfactoria al sistema real.

La figura 3.14 ilustra un diagrama de bloques de la identificación de parámetros, donde una entrada u_i es aplicada al sistema y al modelo, la diferencia entre la salida del sistema objetivo y_i y la salida del modelo $\hat{y}_i$ se emplea de una forma apropiada para actualizar un vector de parámetros θ para reducir esta diferencia. El conjunto de datos compuestos de m pares de entrada-salida deseados (u_i, y_i) , $i = 1, \dots, m$ es a menudo llamados el **conjunto de datos de entrenamiento** o **conjunto de datos de prueba**.

En el caso más general u_i y y_i representan los vectores de entrada y salida deseada. En general, la identificación del sistema no es de un solo proceso; se necesita hacer la identificación del sistema y la identificación de parámetros repetidamente hasta que se encuentre un modelo satisfactorio, de la siguiente manera:

1. Especificar y parametrizar una clase de modelos matemáticos representando el sistema a identificar.
2. Realizar la identificación de parámetros para escoger los parámetros que mejor ajusten el conjunto de datos de entrenamiento.

3. Llevar a cabo pruebas de validación para determinar si el modelo identificado responde correctamente a un conjunto de datos nunca visto (este conjunto de datos esta desacoplado del conjunto de datos de entrenamiento y se conoce como conjunto de datos de **prueba, validación o comprobación**).
4. Se termina el procedimiento una vez que los resultados de las pruebas de validación sean satisfactorios. De otra manera, se selecciona otra clase de modelos y los pasos 2 al 4 se repiten.




Figura 3.14 Diagrama de bloques para la identificación de parámetros (Jang *et al.*, 1997).

Si existen subsistemas lineales en el mecanismo de inferencia pueden utilizarse las herramientas matemáticas como son estimador mínimos cuadrados recursivo y estimador mínimos cuadrados recursivos para sistemas dinámicos. Por otra parte, si las funciones involucradas son diferenciables, puede ser de ayuda el mecanismo de minimización basado en el gradiente.

3.4.3 ANFIS en MATLAB

ANFIS soporta únicamente sistemas de inferencia de tipo Sugeno con las siguientes propiedades (Demuth, 1998):

- Ser sistemas de tipo Sugeno de orden cero o de primer orden.
- Tener una sola salida, obtenida mediante la defuzificación media ponderada. Todas las funciones de membresía de salida deben ser del mismo tipo y ya sea constantes o lineales.
- No tener reglas compartidas. Reglas diferentes no pueden compartir la misma función de membresía de salida, es decir las funciones de membresía de salida deben ser igual al número de reglas.
- Tener peso unitario para cada regla.

ANFIS usa varios algoritmos para generar condiciones iniciales de las funciones de membresía de las reglas como punto de inicio para el entrenamiento de esta. También se pueden generar reglas y funciones de membresía propias.

Sistema de inferencia difuso como estructura inicial

La función *genfis1* de MATLAB genera un sistema de inferencia difuso de tipo Sugeno de una sola salida usando una partición de rejilla en los datos. El siguiente código inicia la construcción del sistema de inferencia usando la función *genfis1*:

Fis_inicial = genfis1(data, nummfs, inputmf, outputmf)

Donde se puede definir la matriz de entrenamiento (*data*), el número de funciones de membresía (*nummfs*), el tipo de funciones de membresía de entrada (*inputmf*) así como el tipo de funciones de salida (*outputmf*).

El agrupamiento sustractivo es utilizado para generar sistemas de inferencia difusos (FIS) automáticamente, basados en los grupos creados. La función que lleva a cabo esta tarea en MATLAB R2007a, se denomina *genfis2*, y genera un FIS tipo Sugeno de un conjunto de datos de entrada-salida usando para ello la función “subclust”, que es la encargada de generar la cantidad de clusters y la ubicación de sus centros.

La función *genfis2* utiliza la información generada por *subclust* y genera los parámetros de las funciones de membresía en la entrada y salida de los FIS y construye los sistemas de inferencia difusos. Adicionalmente, *genfis2* determina el número de reglas basándose en el número de conglomerados generados, determina los antecedentes y finalmente usa estimación lineal de mínimos cuadrados para determinar los consecuentes de cada regla.

Los argumentos mínimos requeridos para utilizar la función *genfis2* son:

1. La matriz de los valores de entrada de un conjunto de datos.
2. La matriz o vector de salida de un conjunto de datos.
3. El radio de influencia de los conglomerados.

Cuando se tiene una sola salida, *genfis2* es utilizado para generar un FIS inicial el cual pueda ser mejorado con la técnica de aprendizaje adaptativa neuro-difusa ANFIS. El propósito es ajustar los valores de los parámetros (funciones de pertenencia, coeficientes lineales, etc.) de manera que el modelo pueda describir en forma satisfactoria al sistema real. El código para generar un sistema de inferencia inicial empleando agrupamiento (*genfis2*) es:

$$Fis_inicial = genfis2(Xin, Xout, radii, xBounds)$$

Donde *Xin* es la matriz que contiene en cada fila los valores de entrada para cada punto, *Xout* es la matriz que contiene en cada fila los valores de salida para cada punto, *radii* es el vector que especifica el rango de influencia de cada centro de grupo en cada una de las direcciones del espacio. Si es un escalar, este valor se utiliza para todas las dimensiones del espacio (influencia esférica), *xBounds* es una matriz que especifica cómo se transforman los datos en *Xin* y *Xout* para su escalado sobre el hiper cubo unidad. Por defecto utilizará los valores máximo y mínimo de los datos en cada dimensión.

Aplicación del algoritmo de aprendizaje

Habiendo construido un sistema de inferencia difuso (FIS, por sus iniciales en inglés) inicial, se puede comenzar a entrenar a ANFIS, para esto se llama a la función *anfis*:

```
[fismat1,error1,stepsize,fismat2,error2]=anfis(trnData,fismat,trnOpt,dispOpt,chkData,optMethod)
```

Donde *trnData* es el conjunto de entrenamiento, *fismat* es el FIS creado como estructura inicial para el ajuste del ANFIS. Si no se utiliza esta opción, la función utiliza *genfis1* para generar una estructura inicial con los valores por defecto, *trnOpt* es el vector de opciones de entrenamiento: 1 para número de iteraciones, 2 el error objetivo, 3 el paso inicial, 4 parámetro de disminución del paso y 5 el parámetro de incremento del paso; *dispOpt* es el vector de opciones de visualización para seleccionar el tipo de información que se presenta durante el proceso de aprendizaje: si es 1, se muestra, y si es 0 no se muestra. 1 información del ANFIS, 2 error, 3 tamaño del paso, 4 resultados finales. *chkData* conjunto de validación para evitar el sobreentrenamiento. *optMethod* método de entrenamiento: si es 1 se utiliza el método híbrido y, si es 0, se utilizase utiliza el de retropropagación. *fismat1* FIS correspondiente al criterio de error de entrenamiento mínimo. *error1* o *error2* array con los valores del error cuadrático medio en cada iteración para el conjunto de entrenamiento o el conjunto de validación respectivamente. *Stepsize* array con los valores del paso de aprendizaje. *fismat2* FIS correspondiente al criterio de error de validación mínimo.

IV. MATERIALES Y METODOS

4.1 Características del invernadero y adquisición de datos

Invernadero de Chapingo, México

La adquisición de datos se llevó a cabo en un invernadero ubicado en el Campo Agrícola Experimental “Tlapeaxco” de la Universidad Autónoma Chapingo, cuyas características se describen en la tabla 4.1.

Tabla 4.1 Descripción del área de estudio (invernadero de Chapingo, México).

Tipo	Dimensión (m)	No. de naves	Altura a la canaleta	Área de suelo	Latitud Norte	Longitud Oeste	Altitud
Cenital	40 x 27	3	5.2 m	1080 m ²	19° 29'	98° 54'	2244 msnm

Los datos se obtuvieron a partir de la utilización de una estación meteorológica automática marca HOBO Weather Logger [H21-001] la cual se colocó en el centro del invernadero. Las mediciones que se hicieron dentro del invernadero fueron de las variables humedad relativa y temperatura del aire a 30 cm y 2 m del suelo; El tiempo de muestreo fue de 1 minuto. En el exterior se midieron a 2 m del suelo las variables humedad relativa, radiación solar, velocidad y dirección del viento, temperatura del aire. Se empleo otro datalogger marca HOBO Weather Logger [H21-001]. Dichas mediciones se realizaron del día 24 de enero del 2007 al 30 de enero del 2007 cada minuto y se almacenaron en la tarjeta de adquisición de datos de la estación. El gráfico de las mediciones se muestran en la figura 4.1.




Figura 4.1 Variables meteorológicas del invernadero de Chapingo, México: radiación solar (Ro), humedad relativa (HRO), velocidad del viento (Vv), dirección del viento (Dv) y temperatura exterior (To); temperatura (Ti) y la humedad relativa (HRI) en el interior del invernadero.

Invernadero de la Universidad Autónoma de Querétaro

Para observar como generaliza la red neuro-difusa para los modelos creados con datos del invernadero de Chapingo, México se empleo un conjunto de datos de un invernadero de la Universidad Autónoma de Querétaro (UAQ) cuyas características son: tipo capilla, cubierto por una sola capa de plástico calibre 700 ultravioleta, constituido por cuatro naves de dimensiones 6.75 m de ancho por 37 m de largo, una altura cenital de 5 m y una altura a canaleta de 3.5 m, ventanas laterales con 2.5 m de alto por 25 m de largo y las frontales miden 2.5 m de alto por 20 m de largo, ventanas cenitales de 0.8 m de alto por 20 m de largo y la apertura y cierre de ventanas se efectúa automáticamente.

Las variables medidas fueron: radiación solar (R_o), humedad relativa exterior (H_{Ro}), velocidad del viento (V_v), Ráfagas de viento (RfV) y temperatura exterior (T_o), temperatura en el interior (T_i) y humedad relativa interior (H_{Ri}).

4.2 Modelado neuro-difuso de la temperatura y humedad relativa

Organización de los datos

Para el invernadero de Chapingo se seleccionaron cinco variables de entrada, las cuales son: radiación solar (R_o), humedad relativa exterior (H_{Ro}), velocidad del viento (V_v), dirección del viento (D_v) y temperatura exterior (T_o). Las observaciones de cada variable se colocaron en un archivo con extensión *.dat en columnas en el orden que se menciona anteriormente (R_o , H_{Ro} , V_v , D_v y T_o). La última columna es para la variable de salida, temperatura en el interior (T_i) para el modelo de temperatura y humedad relativa interior (H_{Ri}) para el caso de la humedad relativa. Se obtuvieron 10080 observaciones. Antes de entrenar un sistema de inferencia difuso se necesita dividir el conjunto total de datos en dos subconjuntos uno llamado de entrenamiento y otro de prueba. El conjunto de entrenamiento se emplea para entrenar o generar el modelo difuso, mientras que el conjunto de prueba es usado para determinar cuando debería terminar el entrenamiento para prevenir sobreajuste (overfitting).

El sobreajuste es el fenómeno que se observa cuando la red ajusta los pesos de las neuronas de forma de reproducir exactamente las respuestas suministradas por el usuario durante el proceso de entrenamiento. Cuando una red “memoriza” en lugar de “aprender”, pierde una de sus propiedades más atractivas: la capacidad de generalización (Hernández, *et al.*, 2003). Para llevar a cabo la partición de los datos de manera fácil, se generó en Matlab un programa llamado partidorm (ver apéndice A).

El conjunto de datos del invernadero de la UAQ se empleo para corroborar la generalización de la red y se obtuvieron 54662 observaciones de los días 9 de junio del 2008 al 22 de julio del 2008. Se eliminaron datos erróneos.

Selección de entradas en partición de rejilla

Las observaciones de los invernaderos se dividieron empíricamente en particiones de datos conteniendo 80%-20%, 65%-35%, 80.17%-19.83% para el caso de la variable temperatura del aire, respectivamente para porcentaje de datos de entrenamiento y datos de prueba.

Para el caso de la variable humedad relativa las particiones fueron de 80%-20%, 75%-25%, 69.14%-30.86. La partición de rejilla es el método de partición de entrada usada mas frecuentemente para ANFIS. Como en este caso existen 5 variables de entrada, la partición de rejilla conduce a al menos $2^5=32$ reglas difusas, lo cual resulta en $(5+1)*32=192$ parámetros lineales si se desea emplear el modelo difuso de Sugeno de primer orden. Esto significa que se tienen demasiados parámetros de ajuste y el modelo resultante no es confiable para entradas imprevistas. Para tratar con esto, se puede seleccionar ciertas entradas que tengan más poder de predicción en lugar de usarlas todas o escoger una partición de árbol, dispersa o agrupamiento en lugar de rejilla.

El método de selección de entradas es el propuesto por Jang (Jang, *et al.*, 1997), el cual está basado en la suposición que el modelo ANFIS con la menor raíz cuadrada del error cuadrático medio (RMSE) después de una época de entrenamiento, tiene un mayor potencial de conseguir un RMSE más bajo con más épocas de entrenamiento. Esta suposición no es absolutamente cierta pero es heurísticamente razonable.

En el programa THPartRej.m (apéndice C) se incluye la opción de seleccionar el número de variables de entrada a analizar, si se quiere seleccionar las 2 variables más relevantes como predictores, se hace un ciclo a través de todas las entradas para construir $C_2^5 = 10$ modelos difusos entrenados por la función `anfis` del Fuzzy Logic Toolbox de Matlab.

Generación del Sistema de Inferencia Difuso Inicial

- Partición de rejilla

Esta labor se lleva a cabo por medio de la función `genfis1` de MATLAB. Los parámetros a manipular son el número y tipo de funciones de membresía, la cantidad de épocas de entrenamiento y el tipo de función de membresía de salida. Cabe mencionar que con este tipo de partición del espacio de entrada, se generan reglas enumerando todas las combinaciones posibles de funciones de membresía de todas las variables de entrada. Esto conduce a un crecimiento exponencial aún cuando el número de entradas sea moderadamente grande. Por ejemplo, para un sistema de inferencia difuso con 10 variables de entrada, cada una con dos funciones de membresía, la partición de rejilla conduce a 1024 (2^{10}) reglas difusas, las cuales son muchas para cualquier método de aprendizaje práctico. En el apéndice C se muestra el código en el cual se emplea `genfis1` para la partición del espacio de entrada. El número de funciones de membresía y los tipos de estas así como todas las opciones se eligieron con el objetivo de minimizar el RMSE y r^2 comparando los resultados obtenidos en otros trabajos como por ejemplo en Salazar *et. al.* (2007). La función de membresía de salida puede ser constante (sistema de inferencia de Sugeno de orden cero) o lineal (sistema de inferencia de Sugeno de primer orden).

- Agrupamiento sustractivo

Con el uso de la función `genfis2`, para las mismas particiones empíricas que en `genfis1`, se varió el radio de influencia de los grupos escogiendo el radio con el RMSE (raíz del error cuadrático medio) más pequeño en el conjunto de prueba. Como este radio puede tomar valores continuos entre cero y uno, y no existe un valor ideal, se realizó el análisis comenzando en 0.2 hasta 1 con incrementos de 0.01. Para elegir el radio más apropiado se creó un programa llamado `radiosTHR.m` (ver apéndice B para temperatura y humedad relativa).

ANFIS para mejorar el sistema de inferencia inicial

A través de la función `anfis` del Fuzzy Logic Toolbox de Matlab se lleva a cabo la generación del modelo neuro-difuso. Se emplearon también los datos de prueba para controlar el sobreajuste. El método de optimización usado fue el híbrido, el cual combina el estimador mínimos cuadrados con retropropagación (*backpropagation*). Mediante la función `evalfis` se evalúa la salida que produce el modelo respecto al entrenamiento y también respecto al conjunto de prueba. El código para modelar la temperatura y la humedad relativa empleando `genfis1` (partición en rejilla) mediante la función ANFIS se encuentra en el apéndice C. Para modelar la temperatura y humedad relativa usando `genfis2` (agrupamiento sustractivo) y ANFIS se presenta en el apéndice D.

Calidad de predicción de los modelos

No existe una regla o una opinión unánime en cual es la medida más apropiada para evaluar el desempeño de una técnica de predicción. Para evaluar el desempeño de los modelos neuro-difusos se utilizó la raíz del error cuadrático medio (*RMSE*):

$$RMSE = \sqrt{\frac{1}{N} \sum_{j=1}^N (\theta_j - \hat{\theta}_j)^2} \dots\dots\dots(4.1)$$

También el coeficiente de determinación (r^2)

$$r^2 = 1 - \frac{\sum_{j=1}^N (\hat{\theta}_j - \theta_j)^2}{\sum_{j=1}^N (\theta_j - \bar{\theta}_j)^2} \dots\dots\dots(4.2)$$

Donde N es el número de observaciones, $\hat{\theta}_j$ es el valor estimado de ya sea la temperatura o humedad relativa. θ_j es el valor observado de la variables a estimar y $\bar{\theta}_j$

es el valor medio de los valores observados. Los programas para el modelado de la temperatura y humedad relativa generan una gráfica de dispersión, también muestra la ecuación de regresión entre las predicciones y mediciones.

4.3 Modelo de regresión lineal (mínimos cuadrados)

Con la finalidad de comparar los resultados obtenidos por los modelos ANFIS (genfis1 y genfis2) se construyeron dos modelos de regresión, uno para la temperatura y otro para la humedad relativa (invernadero de Chapingo, México). El modelo de regresión para la temperatura se expresa como:

$$Ti = a_0 + a_1 * Ro + a_2 * HRo + a_3 * Vv + a_4 * Dv + a_5 * To$$

Y el de humedad relativa del aire:

$$H Ri = a_0 + a_1 * Ro + a_2 * H Ro + a_3 * Vv + a_4 * Dv + a_5 * To$$

Donde $a_0, a_1, \dots, a_5$ son seis parámetros lineales modificables. Los valores óptimos de estos parámetros fueron obtenidos mediante el método de mínimos cuadrados. El modelo lineal toma todas las entradas en consideración.

V. RESULTADOS Y DISCUSION

5.1 Modelado de la temperatura del invernadero de Chapingo, México

Las características que se emplearon para entrenar el sistema de inferencia difuso inicial (FIS) mediante genfis1 (partición del espacio de entrada en rejilla) fueron las mismas tanto para la humedad relativa como para la temperatura, en la tabla 5.1 se muestran dichas características.

Tabla 5.1 Opciones para generar el FIS inicial mediante genfis1 en Temperatura y Humedad Relativa de un invernadero con ventilación natural en Chapingo, México.

Tipo de función de membresía de entrada	Numero de funciones de membresía por entrada	Tipo de función de membresía de salida	Número de épocas de entrenamiento
Gaussiana	2 y 3	Constante lineal	450
Campana generalizada	2 y 3	Constante lineal	450

Se analizaron diversos tipos de particiones empíricas, cada partición conduce a un modelo, después de realizar todo el análisis mediante ANFIS se eligieron las particiones empíricas de los datos que producían el menor RMSE en el conjunto de prueba, los datos seleccionados fueron 65-35, 80-20, 80.17-19.83 la primera parte para el entrenamiento y la otra para llevar a cabo la prueba, estas particiones de datos se usaron en el análisis mediante partición de rejilla así como con partición mediante agrupamiento sustractivo.

Partición del espacio de entrada en rejilla

1. Selección de entradas

En las secciones siguientes se muestran valores obtenidos usando todas las variables de entrada, pero en la tabla E.1 del apéndice E se muestran los valores de RMSE y r^2 como medidas del desempeño de los modelos para 2, 3, 4 y 5 entradas. El criterio de selección de entradas es el expuesto en la metodología.

2. Generación del sistema de inferencia difuso inicial.

Para cada una de las particiones de datos se construyó un sistema de inferencia difuso mediante genfis1 para posteriormente ser entrenado con ANFIS. En la Tabla 5.2 se muestra la topología del sistema de inferencia difuso en el modelo de Temperatura y Humedad Relativa.

Tabla 5.2 Topología del modelo difuso de temperatura y humedad relativa mediante genfis1 para un invernadero con ventilación natural en Chapingo, México.

FIS Temperatura y Humedad Relativa	
1. Sistema de Inferencia Difuso	Sugeno
2. Variables de entrada	5
3. Numero de funciones de membresía por entrada	[2 2 2 2 2]
4. Número de funciones de membresía para la salida	32
5. Número de reglas difusas	32
6. Método operador ‘AND’	PROD
7. Método operador ‘OR’	MAX
8. Método de “Implicación”	PROD
9. Método de “Agregación”	MAX
10. Método de “Desfusificación”	WTAVER
11. Tipo de Función de Membresía para Variables de Entrada	GBELL
12. Tipo de Función de Membresía para la Variable de Salida	CONSTANTE/LINEAL

Los parámetros del modelo de Temperatura está conformado por cinco variables de entrada Radiación solar (Ro), Humedad Relativa (Hro), Velocidad del viento (Vv), Dirección del viento (Dv) y temperatura del aire (To) y como variable de salida la temperatura dentro del invernadero (Ti). Cada variable de entrada tiene asociada dos

funciones de membresía tipo Campana Generalizada. La variable de salida tiene asociada 32 funciones de membresía tipo Constante o Lineal. El sistema se describe con 32 reglas difusas, los operadores lógicos “AND” y “OR” son sustituidos por las funciones producto y máximo, respectivamente. El método de implicación y agregación son el producto y el máximo respectivamente. El método de desfuzificación es el promedio de las ponderaciones. El FIS generado, se muestra la estructura en la figura 5.1.




Figura 5.1 Estructura del FIS inicial obtenido por genfis1 para el modelo de temperatura y de la humedad relativa, constituido por dos funciones de membresía en cada entrada y con una función de membresía de salida ya sea constante o lineal.

3. Entrenamiento del FIS mediante ANFIS

Con las opciones mostradas en la tabla 5.1 se entrenó el sistema neuro-difuso mediante ANFIS, la tabla 5.3 muestra los mejores valores de RMSE y r^2 obtenidos con el número de funciones de membresía, tipo de funciones de membresía y el número de épocas.

Tabla 5.3 Valores estadísticos como medidas del desempeño de los modelo de temperatura obtenidos con genfis1 y ANFIS para el invernadero de Chapingo, México.

Partición	Numero y Tipo de MF	épocas	Tipo MF salida	r^2		RMSE ANFIS	
				Entrenamiento	Prueba	Entrenamiento	Prueba
65-35	2:campana generalizada	450	lineal constante	0.97925	0.86215	1.0865	3.5277
				0.95031	0.95079	1.6814	2.1079
80-20	2:campana generalizada	450	Lineal constante	0.96837	0.89471	1.4255	2.9952
				0.95306	0.95310	1.7365	2.1097
80.17-19.83	2:campana generalizada	450	lineal constante	0.96811	0.88462	1.4330	3.1306
				0.95533	0.95466	1.6959	2.0451

Como se puede ver en la tabla anterior, las tres particiones arrojan resultados satisfactorios de RMSE y r^2 . El criterio de selección del conjunto de datos fue el que da como resultado el menor RMSE en el conjunto de prueba. El mejor ajuste tanto en RMSE como r^2 lo tiene la partición de datos 80.17-19.83 porque en tipo de función de membresía campana generalizada y MF de salida constante tuvo el menor RMSE y el mayor r^2 . Es decir, el modelo con datos 80.17%-19.83% tiene el mejor ajuste en el caso constante. Esta partición empírica se eligió para hacer el análisis de la calidad de predicción del modelo.

Con la función de membresía de salida de tipo constante se entrenó ANFIS, para observar como se comportan los datos de entrenamiento y prueba. La figura 5.2 muestra las curvas de RMSE de los datos de entrenamiento y prueba obtenidas en 450 épocas de entrenamiento.

El error de entrenamiento sigue decreciendo, pero el error de prueba, después de decrecer inicialmente, alcanza un error mínimo de prueba, y después se incrementa. Generalmente, se usa el error de prueba como una medida más confiable del desempeño del modelo. Por lo tanto, el mejor modelo que se puede conseguir ocurre cuando el error de prueba es mínimo, esto fue en la época 259. Este corresponde al círculo en la figura 5.2. Aunque entrenamientos adicionales más allá de este punto decrecen el error de entrenamiento, se degradará el desempeño del sistema de inferencia difuso en entradas

imprevistas. Cuando el error de prueba empieza a aumentar ocurre el sobreentrenamiento (overfitting) y por lo tanto se detuvo el entrenamiento.




Figura 5.2 Curvas de error usadas para detectar sobreentrenamiento en los datos 80.17%-19.83%. Modelado de temperatura en el invernadero de Chapingo, México usando genfis1 y ANFIS.

Las características de ANFIS para la partición de datos 80.17%-19.83% son:

Numero de nodos: 92

Numero de parámetros lineales: 32

Numero de parámetros no lineales: 30

Numero total de parámetros: 62

Numero de datos pares de entrenamiento: 8081

Numero de datos pares de prueba: 1999

Numero de reglas difusas: 32

4. Calidad de predicción

Los resultados de ANFIS para la temperatura se compararon con las temperaturas observadas para evaluar el desempeño de los modelos tanto en el conjunto de datos de entrenamiento como prueba. Como se puede observar en la figura 5.3, el modelo ANFIS tiene buen desempeño para la estimación de la temperatura interior del invernadero.




Figura 5.3 Temperatura medida y simulada por el modelo neuro-difuso de un invernadero con ventilación natural, en Chapingo, México. Conjunto de datos 80.17-19.83 (usando genfis1 y ANFIS).

La figura 5.4 muestra los diagramas de dispersión de los valores estimados por el modelo ANFIS para los conjuntos de entrenamiento/prueba y los valores medidos. Además, muestra que el desempeño de ANFIS es muy cercano a los valores reales con

una bastante buena correlación en conjunto de entrenamiento/prueba $r^2=0.95533$, $r^2=0.95466$ y un RMSE entrenamiento 1.6959 y RMSE de prueba 2.045.




Figura 5.4 Gráfico de dispersión del modelo neuro-difuso. Conjunto de datos 80.17%-19.83%, para la temperatura de un invernadero con ventilación natural en Chapingo, México; usando genfis1 y ANFIS.

Partición del espacio de entrada en agrupamiento sustractivo.

Para las mismas particiones de datos que se analizaron con genfis1 ahora se presentaran los resultados obtenidos mediante genfis2 (agrupamiento sustractivo). El procedimiento fue el siguiente:

1. Generación del FIS inicial mediante agrupamiento sustractivo.

Como ya se mencionó, se emplea la función *genfis2*. La cual requiere que se le especifique el radio de influencia este puede tomar valores entre 0 y 1, lo que hace un poco ardua la selección del radio óptimo. Cada valor de radio conduce a un modelo de temperatura, se hizo la selección del radio que dio el RMSE de prueba mínimo sin usar ANFIS y con este se genero el FIS inicial.

Tabla 5.4 Topología del modelo difuso de temperatura mediante *genfis2* para un invernadero con ventilación natural en Chapingo, México.

FIS Temperatura	
1. Sistema de Inferencia Difuso	Sugeno
2. Variables de entrada	5
3. Variables de salida	1
3. Numero de funciones de membresía por entrada	[6 6 6 6 6]
4. Número de funciones de membresía para la salida	6
5. Número de reglas difusas	6
6. Método operador ‘AND’	PROD
7. Método operador ‘OR’	PROBOR
8. Método de “Implicación”	PROD
9. Método de “Agregación”	MAX
10. Método de “Desfuzificación”	WTAVER
11. Tipo de Función de Membresía para Variables de Entrada	GAUSS
12. Tipo de Función de Membresía para la Variable de Salida	LINEAL

Los parámetros del modelo de temperatura está conformado por cinco variables de entrada: Radiación solar (R_o), Humedad Relativa (H_{ro}), Velocidad del viento (V_v), Dirección del viento (D_v) y temperatura del aire (T_o) y como variable de salida la temperatura dentro del invernadero (T_i). El sistema se describe con 6 reglas difusas, los operadores lógicos “AND” y “OR” son sustituidos por las funciones producto y “OR probabilístico”, respectivamente. El método de desfuzificación es el promedio de las ponderaciones. La estructura correspondiente se muestra en la figura 5.5.




Figura 5.5 Estructura del FIS inicial obtenido mediante agrupamiento sustractivo para la temperatura del invernadero de Chapingo, constituido por seis funciones de membresía por entrada y una función de membresía de salida constante o lineal.

2. Entrenamiento con ANFIS.

Se entrenó mediante ANFIS para generar la estructura del modelo, empleándose 450 épocas de entrenamiento y los dos conjuntos de datos (entrenamiento y prueba). Los resultados obtenidos para cada partición empírica de datos se muestran en la tabla 5.5.

Tabla 5.5 Desempeño de los modelos de temperatura obtenidos mediante agrupamiento sustractivo y ANFIS para el invernadero de Chapingo, México.

Partición	radio	épocas	RMSE		r^2	
			Entrenamiento	Prueba	Entrenamiento	Prueba
65-35	0.48	450	1.6317	2.2568	0.95321	0.94308
80-20	0.53	450	1.7683	1.9658	0.95133	0.95944
80.17-19.83	0.53	450	1.7669	1.9150	0.95151	0.96329

El conjunto de datos 80.17-19.83 produjo los mejores resultados de RMSE y r^2 . En la tabla E.2 del apéndice E se presentan los resultados para más radios de influencia, los aquí mostrados son los óptimos. Con los datos 80.17-19.83 se procedió a hacer todo el modelado. El sistema de inferencia difuso inicial fue evaluado usando la función evalfis y los valores de RMSE obtenidos son en el entrenamiento RMSE = 1.8106, en la prueba RMSE=1.9347 (sin ANFIS). Se analizó si ocurre sobreentrenamiento y se obtuvo la figura 5.6.




Figura 5.6 Curva de error del modelo de temperatura con datos 80.17-19.83 usando agrupamiento sustractivo y ANFIS.

En la figura 5.6 se observa que en la época de entrenamiento 30 se produce el error de prueba mínimo, después de esta época el error de entrenamiento sigue bajando pero el de prueba aumenta con lo que la capacidad de generalización de la red se ve afectada seriamente.

Las características de ANFIS fueron:

Numero de nodos: 80

Numero de parámetros lineales: 36

Numero de parámetros no lineales: 60

Numero total de parámetros: 96

Numero de datos pares de entrenamiento: 8081

Numero de datos pares de prueba: 1999

Numero de reglas difusas: 6

El número de reglas difusas se redujo considerablemente comparado con el número obtenido mediante genfis1 (partición de rejilla).

3. Calidad de predicción

Los resultados obtenidos mediante el modelo ANFIS se contrastaron con los valores medidos de temperatura en la partición empírica 80.17-19.83. Se hizo la comparación tanto para los datos de entrenamiento así como los de prueba. Como se puede observar en la figura 5.7, el modelo ANFIS tiene buen comportamiento para la estimación de la temperatura interior.




Figura 5.7 Temperatura medida y simulada por el modelo neuro-difuso para el invernadero de Chapingo, México. Conjunto de datos 80.17-19.83 y empleando genfis2 y ANFIS.

La figura 5.8 muestra la gráfica de dispersión correspondiente a los valores estimados por el modelo ANFIS para los conjuntos de entrenamiento/prueba y los valores medidos. Los resultados obtenidos para los datos de entrenamiento son $r^2=0.95151$, RMSE=1.7669 y para la prueba $r^2=0.96329$, RMSE=1.9150.




Figura 5.8 Gráfico de dispersión del conjuntos de datos 80.17-19.83 en el modelo de temperatura mediante genfis2 y ANFIS para el invernadero de Chapingo, México.

5.2 Modelo de la Humedad Relativa del invernadero de Chapingo, México

Partición del espacio de entrada en rejilla

De la misma manera que se realizó el modelado de la temperatura se procedió con la humedad relativa.

1. Selección de entradas

Se realizó el análisis para 2, 3, 4 y 5 entradas. Más adelante se muestra los resultados obtenidos usando todas las variables de entrada. En la tabla F.1 del apéndice F se muestran los valores obtenidos para menos entradas. El mismo criterio de selección de entradas que se uso en el modelado de temperatura se empleo aquí.

2. Generación del sistema de inferencia difuso inicial.

El FIS inicial se creo mediante la función `genfis1`. Se analizaron distintas particiones empíricas eligiendo a las que produjeran el menor RMSE en el conjunto de prueba. Estos conjuntos de datos son 69.14-30.86, 75-25 y 80-20. La topología del modelo difuso se muestra en la tabla 5.2 y la estructura es similar a la mostrada en la figura 5.1.

3. Entrenamiento mediante la función ANFIS

En la tabla 5.6 se muestran los valores óptimos de RMSE y r^2 . Dicha tabla muestra que la partición empírica 69.14-30.86 produce el mejor resultado. En el entrenamiento con ANFIS se emplearon los datos de prueba como control para evitar sobreentrenamiento.

Tabla 5.6 Resultados estadísticos para la humedad relativa con `genfis1` y ANFIS.

Partición	Numero y Tipode MF	épocas	Tipo MF salida	r^2		RMSE ANFIS	
				Entrena miento	Prueba	Entrena miento	Prueba
69.14-30.86	2:campana generalizada	450	constante	0.95126	0.93152	5.0482	6.2401
	2:gauss	450	Lineal	0.97446	0.90483	3.6544	7.4860
75-25	2:campana generalizada	450	constante	0.95296	0.92479	4.8597	6.8425
	2:gauss	450	lineal	0.97494	0.90203	3.5475	7.9536
80-20	2:campana generalizada	450	lineal	0.97534	0.91578	3.5626	7.4693
	2:gauss	450	constante	0.95369	0.93057	4.8816	6.9980

Esta partición empírica (69.14-30.86) se eligió para hacer el análisis de la calidad de predicción del modelo.




Figura 5.9 Curvas de error del modelo neuro-difuso de humedad relativa, obtenido empleando genfis1 y ANFIS. Con datos 69.14-30.86 del invernadero de Chapingo.

En la figura 5.9 se observa como el error de prueba desciende pero empieza a oscilar antes de la época 50, llega a su punto mínimo en la época 99 después crece pero sigue oscilando. Después de la época 99 la red empieza a memorizar y ya no generaliza por lo que se para el entrenamiento. Las características de ANFIS para la partición de datos 69.14%-30.86% es:

Numero de nodos: 92

Numero de parámetros lineales: 32

Numero de parámetros no lineales: 30

Numero total de parámetros: 62

Numero de datos pares de entrenamiento: 6969

Numero de datos pares de prueba: 3111

Numero de reglas difusas: 32

4. Calidad de predicción

Los valores de la variable de salida predichos por ANFIS se muestran en la figura 5.10, así también están los valores medidos dentro del invernadero.

Los resultados en el entrenamiento son $r^2=0.95126$, $RMSE=5.0482$, para la prueba son $r^2=0.93152$, $RMSE=6.2401$. En los gráficos de dispersión (figura 5.11) se puede notar que los valores obtenidos por el modelo ANFIS son muy cercanos a los valores reales con una correlación bastante buena entre el conjunto de entrenamiento y prueba.




Figura 5.10 Modelo neuro-difuso de la humedad relativa del invernadero de Chapingo, usando datos 69.14-30.86 con ANFIS y genfis1.




Figura 5.11 Gráficos de dispersión del conjunto 69.14-30.86 para la humedad relativa del invernadero de Chapingo. Se empleo genfis1 y se mejoro con ANFIS.

Partición del espacio de entrada en agrupamiento sustractivo

1. Generación del FIS inicial mediante agrupamiento sustractivo.

Cada valor de radio de influencia genera un modelo, por lo que se hizo la selección del radio que dio el RMSE de prueba mínimo sin usar ANFIS y con este se genero el FIS inicial. La tabla 5.7 muestra la topología del FIS.

Tabla 5.7 Topología del modelo difuso de humedad relativa mediante agrupamiento sustractivo para un invernadero con ventilación natural en Chapingo, México.

FIS Humedad Relativa	
1. Sistema de Inferencia Difuso	Sugeno
2. Variables de entrada	5
3. Variables de salida	1
3. Numero de funciones de membresía por entrada	[4 4 4 4 4]
4. Número de funciones de membresía para la salida	4
5. Número de reglas difusas	4
6. Método operador ‘AND’	PROD
7. Método operador ‘OR’	PROBOR
8. Método de “Implicación”	PROD
9. Método de “Agregación”	MAX
10. Método de “Desfusificación”	WTAVER
11. Tipo de Función de Membresía para Variables de Entrada	GAUSS
12. Tipo de Función de Membresía para la Variable de Salida	LINEAL

Los parámetros del modelo está conformado por cinco variables de entrada radiación global (R_o), humedad relativa (H_{ro}), velocidad del viento (V_v), dirección del viento (D_v) y temperatura del aire (T_o) y una variable de salida humedad relativa (H_{ri}) dentro de invernadero.

El sistema se describe con 4 reglas difusas, los operadores lógicos “AND” y “OR” son sustituidos por las funciones producto y “or” probabilístico, respectivamente. El método de desfuzificación es el promedio de las ponderaciones. La estructura se muestra en la figura 5.12.




Figura 5.12 Estructura del FIS inicial del modelo de humedad relativa, obtenido con genfis2 para el invernadero de Chapingo, constituido por cuatro funciones de membresía por entrada y una función de membresía de salida constante o lineal.

2. Entrenamiento con ANFIS.

Los datos de prueba se usaron como control para evitar sobreentrenamiento de la red, se usaron 450 épocas para el entrenamiento. Los resultados correspondientes a las mismas particiones empíricas que se usaron en genfis1 se resumieron en la tabla 5.8.

Tabla 5.8 Valores estadísticos empleando genfis2 para el FIS inicial, humedad relativa del invernadero de Chapingo.

			RMSE		r^2	
Partición	radio	épocas	Entrenamiento	Prueba	Entrenamiento	Prueba
69.14-30.86	0.68	450	4.8308	5.4178	0.95537	0.94926
75-25	0.52	450	4.6520	5.9244	0.95690	0.94672
80-20	0.73	450	4.6259	5.8026	0.95842	0.95611

La tabla muestra que el conjunto de datos 69.14-30.86 produjo los mejores resultados de RMSE y r^2 . En la tabla F.2 del apéndice F se presentan los resultados para más radios de influencia, los aquí mostrados son los óptimos. El sistema de inferencia difuso inicial fue evaluado mediante la función evalfis y los valores de RMSE obtenidos son en el entrenamiento RMSE=4.8478, en la prueba RMSE=5.4606 (sin ANFIS).

En la figura 5.13 se muestran las curvas de error, en esta se nota que en la época 43 el error de prueba es mínimo, después se incrementa, si se sigue entrenando el error de prueba aumenta pero el de entrenamiento disminuye mostrándose claramente sobreentrenamiento.




Figura 5.13 Curvas de error usando el conjunto de datos 69.14-30.86 para la humedad relativa con agrupamiento sustractivo y ANFIS.

Las características de ANFIS son:

Numero de nodos: 56

Numero de parámetros lineales: 24

Numero de parámetros no lineales: 40

Numero total de parámetros: 64

Numero de datos pares de entrenamiento: 6969

Numero de datos pares de prueba: 3111

Numero de reglas difusas: 4

El número de reglas difusas se redujo de 32 con genfis1 a 4 con genfis2.

3. Calidad de predicción

En la figura 5.14, el modelo ANFIS tiene buen comportamiento para la estimación de la humedad relativa dentro del invernadero.




Figura 5.14 Humedad relativa medida y simulada por el modelo neuro-difuso con datos 69.14-30.86 mediante ANFIS y genfis2 para el invernadero de Chapingo, México.

Los resultados en el entrenamiento son $r^2=0.95537$, $RMSE=4.8308$, para la prueba son $r^2=0.94926$, $RMSE=5.4178$. En los gráficos de dispersión de la figura 5.15 los valores

obtenidos por el modelo ANFIS son cercanos a los valores reales con una correlación bastante buena en los conjuntos de entrenamiento y prueba.




Figura 5.15 Gráfico de dispersión para el conjunto 69.14-30.86. Modelo de humedad relativa usando agrupamiento sustractivo y ANFIS para el invernadero de Chapingo.

5.3 Modelo de regresión lineal múltiple

Con las mismas particiones de datos (del invernadero de Chapingo) probados con ANFIS, se procedió a realizar el análisis de regresión lineal múltiple por el método de mínimos cuadrados (para temperatura y humedad relativa), empleando el operador backslash de MATLAB “\”.

Temperatura del aire (partición 80.17%-19.83%)

Al llevar a cabo las operaciones correspondientes se obtienen los valores de los parámetros que se observan en la siguiente ecuación:

$$Ti = -2.73782 + 0.02163 * Ro + 0.02644 * HRo - 0.72314 * Vv + 0.00098 * Dv + 1.07008 * To$$

Los resultados gráficos se muestran en las figuras 5.16 y 5.17.




Figura 5.16 Modelo de regresión lineal para la temperatura de un invernadero con ventilación natural, en Chapingo, México (datos 80.17%-19.83%).




Figura 5.17 Gráfico de dispersión de los conjuntos de datos en el modelo de regresión lineal para la temperatura de un invernadero con ventilación natural, en Chapingo, México.

El modelo de regresión lineal presento: RMSE=2.4239 en entrenamiento y RMSE=2.6117 en la prueba. Las medidas de error del modelo están todavía muy altas ya que la predicción de la temperatura es no lineal.

Humedad Relativa del aire (partición 69.14%-30.86%)

Se realizó un modelo de regresión lineal, el cual presento: RMSE=7.2139 en entrenamiento y RMSE=10.2224 en la prueba.

Los coeficientes de regresión se muestran en la siguiente ecuación:

$$HRi = 94.09586 - 0.06116 * Ro + 0.19863 * HRo - 1.84771 * Vv + 0.00210 * Dv - 1.17802 * To$$




Figura 5.18 Modelo de regresión lineal para la humedad relativa de un invernadero con ventilación natural, en Chapingo, México.

Las medidas de error del modelo están muy altas ya que la predicción de la humedad relativa es muy no lineal.




Figura 5.19 Gráfico de dispersión de los conjuntos de datos en el modelo de regresión lineal para la humedad de un invernadero con ventilación natural, en Chapingo, México.

5.4 Capacidad de generalización

Con datos del invernadero de la Universidad Autónoma de Querétaro se procedió a entrenar la red (creada con datos de Chapingo) para observar la capacidad de generalización de esta ante datos no conocidos. Se realizaron entrenamientos con las mismas particiones empíricas utilizadas en la modelación de la temperatura y humedad relativa del invernadero de Chapingo.

Modelado de la Temperatura

Al emplear la técnica de partición del espacio de entrada para generar el FIS inicial de rejilla y entrenados por ANFIS para mejorar el modelo se obtuvieron los datos que se muestran en la tabla 5.9.

Tabla 5.9 Estadísticos de la temperatura usando genfis1 y ANFIS, invernadero de la UAQ (Universidad Autónoma de Querétaro).

Partición	Numero y Tipo de MF	épocas	Tipo de MF de salida	r^2		RMSE ANFIS	
				Entrenamiento	Prueba	Entrenamiento	Prueba
65-35	2:campana gene.	450	constante	0.96631	0.95562	1.3529	1.6953
80-20	2:campana gene.	450	constante	0.96049	0.96937	1.4278	1.4402
80.17-19.83	2:campana gene.	450	constante	0.96047	0.96945	1.4269	1.4449

Se observa en la tabla anterior que los resultados en las tres particiones empíricas son muy aceptables debido a que el RMSE que se obtuvo es bajo. Para mostrar los gráficos correspondientes, se eligió la partición 80-20.




Figura 5.20 Temperatura medida y simulada por el modelo neuro-difuso de un invernadero en Querétaro, Qro empleando genfis1 y ANFIS.




Figura 5.21 Gráfico de dispersión de los conjuntos de datos para el modelo de temperatura de un invernadero con ventilación natural, en Querétaro, Qro.

Empleando agrupamiento sustractivo y mejorando el modelo por ANFIS se obtuvieron los resultados mostrados en la tabla 5.10.

Tabla 5.10 Desempeño de los modelos de temperatura obtenidos mediante agrupamiento sustractivo y ANFIS para el invernadero de la UAQ.

Partición	radio	épocas	RMSE		r^2	
			Entrena miento	Prueba	Entrena miento	Prueba
65-35	0.5	450	1.2932	1.6317	0.96922	0.95982
80-20	0.53	450	1.3920	1.4245	0.96244	0.97455
80.17-19.83	0.53	450	1.3911	1.4284	0.96242	0.97465

Los resultados gráficos se muestran por las figuras 5.22 y 5.23. La partición de datos analizada fue la 80-20.




Figura 5.22 Temperatura medida y simulada por el modelo neuro-difuso, invernadero de Querétaro, Qro. La técnica de partición del espacio de entrada fue agrupamiento sustractivo y se mejoró con ANFIS.




Figura 5.23 Gráfico de dispersión para los conjuntos de entrenamiento y prueba de la partición 80-20, se empleo genfis2 y ANFIS. Invernadero de la UAQ.

Humedad Relativa

Los resultados al usar ANFIS y partición de rejilla se muestran en la tabla 5.11.

Tabla 5.11 Estadísticos para el modelo de humedad relativa, ANFIS y partición de rejilla. Invernadero de la UAQ.

Partición	Numero y Tipo de MF	épocas	Tipo de MF de salida	r^2		RMSE ANFIS	
				Entrena miento	Prueba	Entrena miento	Prueba
69.14-30.86	2:campana gene.	450	constante	0.97705	0.97283	3.9600	4.5590
75-25	2:campana gene.	450	constante	0.97656	0.97210	3.9445	4.6865
80-20	2:campana gene.	450	constante	0.97450	0.97635	4.1068	4.0817

Los gráficos correspondientes a la partición de datos 69.14-30.86 se muestran en las figuras 5.24 y 5.25.




Figura 5.24 Modelo para la humedad relativa con datos del invernadero de Querétaro. Empleando partición de rejilla y ANFIS.




Figura 5.25 Dispersión de los conjuntos de datos para la Humedad Relativa con datos del invernadero de Querétaro.

Mediante agrupamiento sustractivo se obtuvo la tabla de resultados 5.12.

Tabla 5.12 Resultados estadísticos de los modelos de humedad relativa obtenidos mediante agrupamiento sustractivo y ANFIS para el invernadero de la UAQ.

Partición	radio	épocas	RMSE		r^2	
			Entrena miento	Prueba	Entrena miento	Prueba
69.14-30.86	0.68	450	3.9993	4.6594	0.97659	0.97171
75-25	0.52	450	3.9909	4.6728	0.97601	0.97208
80-20	0.5	450	4.1042	4.1949	0.97453	0.97549

Se analizó la partición de datos 80-20, los gráficos correspondientes se muestran en las figuras 5.26 y 5.27.




Figura 5.26 Modelo para la humedad relativa con datos del invernadero de Querétaro. Empleando agrupamiento sustractivo y ANFIS.




Figura 5.27 Dispersión de los conjuntos de datos para el modelo de la humedad relativa del invernadero de la UAQ mediante agrupamiento sustractivo y ANFIS.

VI CONCLUSIONES

Se aplicó una metodología para generar modelos neuro-difusos ANFIS, basado en la combinación de las redes adaptables y los sistemas de inferencia difusos de la temperatura y humedad relativa del ambiente de dos invernaderos en el centro de México. El trabajo ha presentado la aplicación del modelado neuro-difuso.

Se emplearon dos técnicas de partición del espacio de entrada para generar el sistema de inferencia difuso inicial: partición en rejilla y agrupamiento sustractivo. Posteriormente se disminuyó el RMSE mediante la red neuro-difusa ANFIS.

La construcción de los modelos difusos utilizando el algoritmo de agrupamiento sustractivo demostró la efectividad y alta capacidad de adaptación (se redujo el número de reglas difusas de 32 que se obtienen con partición de rejilla a 6 y 4 con agrupamiento sustractivo, la estructura es menos compleja) de esta técnica al tipo de problemas que se está modelando y ANFIS demostró capacidad para mejorar dichos modelos. Los estadísticos como medidas del desempeño de los modelos, demostraron que las dos técnicas de identificación de la estructura (partición en rejilla y agrupamiento sustractivo) y la red ANFIS son herramientas muy efectivas para predecir el comportamiento de la temperatura y humedad relativa dentro de los invernaderos estudiados, el ajuste fue mayor al 97% tanto para la humedad y la temperatura.

La red neuro-difusa tuvo capacidad de generalización, fue entrenada con datos del invernadero de Chapingo y se comprobó el funcionamiento de esta ante la presencia de datos de mediciones no conocidos por ella (datos del invernadero de la Universidad Autónoma de Querétaro).

Se desarrollaron dos modelos de regresión (temperatura y humedad relativa) para contrastar con los resultados obtenidos de los modelos neuro-difusos. El modelado neuro-difuso demostró su efectividad de acuerdo a los estadísticos de desempeño, el modelo de regresión obtuvo un ajuste del 95% para la temperatura y un 92% para la humedad relativa. El RMSE y r^2 fueron las medidas del desempeño de los modelos.

Los resultados obtenidos demostraron que los modelos neuro-difusos son una buena opción para modelar sistemas no-lineales, en el caso donde el sistema es altamente no lineal (humedad relativa) este tipo de modelos de acuerdo a los porcentajes de ajuste fue mejor que los obtenidos con regresión lineal. Con esto se pueden emplear estrategias de control para mejorar el ambiente dentro del invernadero.

Como recomendación, se sugiere que en trabajos posteriores se evalúen otros métodos de partición de espacio de entrada como el enfoque CART, K-means, C-means, etc.

BIBLIOGRAFÍA

- [1] Demuth, H., and Beale, M. 1998. Neural Network Toolbox for use with MATLAB. The MathWorks Inc. USA.
- [2] Ferreyra R., A. 2005. Redes Neuronales Difusas para modelado vía agrupamiento en línea: Aplicación a un condensador de aspiración. Tesis de Doctorado. CINVESTAV-IPN. México, D. F.
- [3] Gamboa, M., Castro, M., and Herrera, F. 2005. Use of an ANFIS Network for Relative Humidity Behaviour Modelling on the South Region of Jalisco, México. Advances in Artificial Intelligence Theory Research on Computing Science 16. México, D.F. pp. 75-84.
- [4] Gómez S., F. 2005. Sistemas difusos jerárquicos para modelado y control. Tesis de Maestría. CINVESTAV-IPN. México, D. F.
- [5] Grant, W. 2001. Ecología y manejo de recursos naturales: análisis de sistemas y simulación. ed. Agroamérica. San José, Costa Rica. pp. 15-21.
- [6] Haefner, J. 2005. Modeling biological systems: principles and applications. Second Edition. ed. Springer. New York, USA.
- [7] Haijun, C. 2008. Fuel Injection Control and Simulation of EFI engine Based on ANFIS. International Conference on Intelligent Computation Technology and Automation. ICICTA Vol. 1. Hunan, China.

- [8] Hernández C., E., *et al.* 2003. Las redes neuronales artificiales en química analítica. Parte I. Fundamentos. Revista de la sociedad venezolana de química 26(4): 17-25.
- [9] Jang, J. R., Mizutani, E., and Tsai, S. 1997. Neuro-fuzzy and soft computing: a computational approach to learning and machine intelligence. ed. Prentice-Hall. USA.
- [10] Jang, J., R. 1993. ANFIS: Adaptive-network-based fuzzy inference systems. IEEE Transactions on Systems, Man, and Cybernetics 23(3): 665-685.
- [11] Klir, G., J., and Yuan, B. 1995. Fuzzy Sets and Fuzzy Logic: theory and applications. ed. Prentice Hall. New Jersey, USA.
- [12] Lin, C., *et al.* 2007. Estimation of regional evapotranspiration by adaptive network-based fuzzy inference system for Dan-Shui basin in Taiwan. Journal of the Chinese Institute of Engineers 30(6): 1091-1096.
- [13] López, C. I., Rojano, A. A., Ojeda, B. W., and Salazar, M., R. 2007. Modelos ARX para predecir la temperatura del aire de un invernadero: una metodología. Agrociencia 41(2): 181-192.
- [14] Martín del Brío, B. y A. Sanz M. 2002. Redes Neuronales y Sistemas Difusos. Segunda Edición. ed. Alfaomega Ra-Ma. México, D.F.
- [15] Narendra, K.S. and S. Mukhopadhyay. 1997. Adaptive Control Using Neural Networks Approximate Models. IEEE Trans. Neural Networks 8(3): 475-485.
- [16] Nayak, P. C., K. P. Sudheer, D. M. Rangan, and K. S. Ramasastri. 2004. A neuro-fuzzy computing technique for modeling hydrological time series. Journal of Hydrology, 291(1– 2): 52– 66.

- [17] Nelles O. 2001. Nonlinear System Identification. ed. Springer. Berlin-Heidelberg. New York, USA.
- [18] Salazar, R., López, I., and Rojano, A. 2008. A Neural Network Model to Predict Temperature and Relative Humidity in a Greenhouse. *Acta Horticulturae* 801: 401-408.
- [19] Tien, B.T. 1997. Neural-Fuzzy Approach for System Identification. PhD. Thesis. Wageningen Agricultural University. Wageningen, The Netherlands.
- [20] Tien, B.T., van Straten, G. 1998. A Neuro-Fuzzy Approach to Identify Lettuce Growth and Greenhouse Climate. *Artificial Intelligence Review* 12: 71-93.
- [21] Villaseñor L., C. 2003. Modelado difuso neuronal con algoritmo de aprendizaje estable. Tesis de Maestría. CINVESTAV-IPN. México, D. F.
- [22] Zadeh, L. A. Fuzzy Sets. 1965. *Information and control*, Vol. 8 , 338-353.
- [23] Zuñiga, A., y Jordán, C. 2005. Aplicación de redes adaptables y sistemas de inferencia fuzzy para la previsión de caudales afluentes en centrales hidroeléctricas. Escuela Superior Politécnica del Litoral. Guayaquil, Ecuador.

Apéndice A

PROGRAMA PARA HACER PARTICIONES EMPÍRICAS DE LOS DATOS PARA EL MODELADO DE TEMPERATURA Y HUMEDAD RELATIVA

partidor.m

```
clear
entrada=input('\n\n\nArchivo a particionar (con extension):','s');
Datos=load (entrada); % carga el archivo dat de entrada
nummuestras=input('\n\nMuestras en el entrenamiento(ej. 80%):');
nomEntrena=input'\n\nNombre del archivo de entrenamiento':'s';
nomValida=input('\n\nNombre del archivo de prueba':'s');
[casos,columnas]=size(Datos);
formato='%d';
for u=2:columnas
    formato=strcat(formato,' %d');
end
formato=strcat(formato,'\n');
s=round((nummuestras/100)*10080);
extensio='.dat';
arxiu=strcat(nomEntrena,extensio);
if exist(arxiu)==2;
    delete(arxiu);
else
end
[fid, message] = fopen(arxiu,'a');
if fid==-1
    disp (message)%Error
end
for j=1:s
    fprintf(fid,formato,Datos(j,:));
end
fclose(fid);
arxiu=strcat(nomValida,extensio);
if exist(arxiu)==2;
    delete(arxiu);
else
end
[fid, message] = fopen(arxiu,'a');
if fid==-1
    disp (message)%Error
end
for j=(s+1):casos
    fprintf(fid,formato,Datos(j,:));
end
fclose(fid);
```

Apéndice B

PROGRAMA PARA SELECCIONAR EL RADIO QUE PRODUCE EL MÍNIMO RMSE CON GENFIS2

radiosTHR.m

```
%Calcula el RMSE para las particiones empíricas...se elige el radio que
%da el menor RMSE en la prueba. Sirve para la temperatura como para la
%humedad relativa
%LEOPOLDO HERNANDEZ LARRAGOITI
clc
close all;
clear all
entrada=input('\n\n\nDatos de entrenamiento(con extensión): ','s');
chkdata=input('\n\n\nDatos de prueba (con extensión): ','s');
data=load (entrada);
chkval=load(chkdata);
%Hacemos x1 datos de entrenamiento y x2 validación
x1 =data(:,1:5);
x2 =chkval(:,1:5);
% y1 salida de datos de entrenamiento y y2 de prueba
y1=data(:,6);
y2=chkval(:,6);
%Conjunto de datos de entrenamiento y prueba
traindata=[x1 y1];
testdata =[x2 y2];
%Se genera el Sistema de Inferencia Difusa inicial
for r=0.4:0.01:1
Fisini=genfis2(x1, y1, r);
%Evaluando la salida y el error (RMSE) que produce el modelo respecto
%al entrenamiento
SalidaFisini_trn=evalfis(x1,Fisini);
trnRMSE=norm(SalidaFisini_trn-y1)/sqrt(length(SalidaFisini_trn));
%Evaluando la salida y el error (RMSE) que produce el modelo respecto a
%la prueba
SalidaFisini_chk=evalfismex(x2,Fisini,101);
chkRMSE=norm(SalidaFisini_chk-y2)/sqrt(length(SalidaFisini_chk));
fprintf('radio=%.3f',r);
fprintf(' --> trn=%.4f,', trnRMSE);
fprintf(' chk=%.4f \n', chkRMSE);
end
```

Apéndice C

PROGRAMA PARA MODELAR LA TEMPERATURA O LA HUMEDAD RELATIVA DENTRO DEL INVERNADERO, CON PARTICIÓN DE REJILLA Y ANFIS PARA MEJORAR LA RESPUESTA

THPartRej.m

```
%Programa para modelar ya sea la Temperatura o Humedad Relativa del
%Aire en el interior del invernadero, empleando la red ANFIS, con una
%partición del espacio de entrada de rejilla mediante genfis1
%$ LEOPOLDO HERNANDEZ LARRAGOITI
%Mayo del 2009
```

```
close all; clear all
```

```
%.....Datos de entrada
```

```
trndata=input('\n\nDatos de Entrenamiento(con extensión): ','s');
chdata=input('\n\nDatos de prueba (con extensión): ','s');
Modelo=input('\n\nModela Temperatura(1) Modela HR (2): ');
NumEnt=input('\nEspecifique el número de entradas (2,3,4 o 5 ):');
data=load(trndata);
chkdata=load(chdata);
%x1,x2: variables de entrada datos de entrenamiento y prueba
x1 =data(:,1:5);
x2 =chkdata(:,1:5);
%y1,y2: salida del conjunto de entrenamiento y prueba
y1=data(:,6);
y2=chkdata(:,6);
diastn=[1:1:size(x1)]';
t1=diastn/1440;
diaschk=[1:1:size(x2)]';
t2=diaschk/1440;
% Conjunto de datos de entrenamiento y prueba
traindata =[x1 y1];
checkdata =[x2 y2];
if Modelo < 1 | Modelo > 2,
    error([mfilename, ...
        ' Selecciona 1 o 2 (T° o HR)']);
End
```

```
%.....Selección de entradas con más influencia sobre la predicción.
```

```
input_name = str2mat('Ro', 'HRO', 'Vv', 'Dv','To');
NumTotalEnt = size(data, 2)-1; %5 entradas totales
```

```

ModAnfis = prod(1:NumTotalEnt)/(prod(1:NumEnt)*prod(1:(NumTotalEnt...
-NumEnt)));
index = zeros(ModAnfis, NumEnt);
trn_error = zeros(ModAnfis, 1);
chk_error = zeros(ModAnfis, 1);
t0 = clock;

%Opciones de entrenamiento para identificar la estradas más influyentes

mf_n = 2;
mf_type = 'gbellmf';
epoch_n = 1;
ss = 0.04;
ss_dec_rate = 0.9;
ss_inc_rate = 1.1;

if NumEnt == 2,
    fprintf('\nEntrenando %d modelos ANFIS, cada uno con %d entradas...
seleccionadas de %d candidatas...\n\n',ModAnfis, NumEnt, NumTotalEnt);
    model = 1;
    for i=1:NumTotalEnt,
        for j=i+1:NumTotalEnt,
            in1 = deblank(input_name(i, :));
            in2 = deblank(input_name(j, :));
            index(model, :) = [i j];
            this_trn_data = traindata(:, [i j NumTotalEnt+1]);
            this_chk_data = checkdata(:, [i j NumTotalEnt+1]);
            in_fismat = genfis1(this_trn_data, mf_n, mf_type);
            [trn_out_fismat t_err step_size chk_out_fismat c_err] = ...
anfis(this_trn_data, in_fismat, ...
[epoch_n nan ss ss_dec_rate ss_inc_rate], ...
[0 0 0 0], this_chk_data, 1);
            trn_error(model) = min(t_err);
            chk_error(model) = min(c_err);
            fprintf('Modelo ANFIS %d: %s %s', model, in1, in2);
            fprintf(' --> trn=%.4f,', trn_error(model));
            fprintf(' chk=%.4f', chk_error(model));
            fprintf('\n');
            model = model+1;
        end
    end
elseif NumEnt == 3,
    fprintf('\nEntrenando %d modelos ANFIS, cada uno con %d entradas...
seleccionadas de %d candidatas...\n\n',ModAnfis, NumEnt, NumTotalEnt);
    model = 1;
    for i=1:NumTotalEnt,
        for j=i+1:NumTotalEnt,
            for k=j+1:NumTotalEnt,
                in1 = deblank(input_name(i, :));
                in2 = deblank(input_name(j, :));
                in3 = deblank(input_name(k, :));
                index(model, :) = [i j k];
                this_trn_data = traindata(:, [i j k NumTotalEnt+1]);
                this_chk_data = checkdata(:, [i j k NumTotalEnt+1]);
                in_fismat = genfis1(this_trn_data, mf_n, mf_type);
                [trn_out_fismat t_err step_size chk_out_fismat c_err] = ...
anfis(this_trn_data, in_fismat, ...

```

```

        [epoch_n nan ss ss_dec_rate ss_inc_rate], ...
        [0 0 0 0], this_chk_data, 1);
    trn_error(model) = min(t_err);
    chk_error(model) = min(c_err);
    fprintf('Modelo ANFIS %d: %s %s %s', model, in1, in2, in3);
        fprintf(' --> trn=%.4f,', trn_error(model));
        fprintf(' chk=%.4f', chk_error(model));
        fprintf('\n');
    model = model+1;
    end
end
elseif NumEnt == 4,
    fprintf('\nEntrenando %d modelos ANFIS, cada uno con %d entradas...
seleccionadas de %d candidatas...\n\n', ModAnfis, NumEnt, NumTotalEnt);
    model = 1;
    for i=1:NumTotalEnt,
        for j=i+1:NumTotalEnt,
            for k=j+1:NumTotalEnt,
                for l=k+1:NumTotalEnt,
                    in1 = deblank(input_name(i, :));
                    in2 = deblank(input_name(j, :));
                    in3 = deblank(input_name(k, :));
                    in4 = deblank(input_name(l, :));
                    index(model, :) = [i j k l];
                    this_trn_data = traindata(:, [i j k l NumTotalEnt+1]);
                    this_chk_data = checkdata(:, [i j k l NumTotalEnt+1]);
                    in_fismat = genfis1(this_trn_data, mf_n, mf_type);
                    [trn_out_fismat t_err step_size chk_out_fismat c_err] = ...
                        anfis(this_trn_data, in_fismat, ...
                            [epoch_n nan ss ss_dec_rate ss_inc_rate], ...
                            [0 0 0 0], this_chk_data, 1);
                    trn_error(model) = min(t_err);
                    chk_error(model) = min(c_err);
                    fprintf('Modelo ANFIS %d: %s %s %s %s', model, in1, in2, in3, ...
in4);
                        fprintf(' --> trn=%.4f,', trn_error(model));
                        fprintf(' chk=%.4f', chk_error(model));
                        fprintf('\n');
                    model = model+1;
                end
            end
        end
    end
elseif NumEnt == 5,
    in_fismat = genfis1(traindata, mf_n, mf_type);
    [trn_out_fismat t_err step_size chk_out_fismat c_err] = ...
        anfis(traindata, in_fismat, [epoch_n nan ss ss_dec_rate...
ss_inc_rate], [0 0 0 0], checkdata, 1);
    trn_error= min(t_err);
    chk_error= min(c_err);
    fprintf('\nModelo ANFIS 1: Ro HRo Vv Dv To --> trn=%.4f,', ...
trn_error);
    fprintf(' chk=%.4f', chk_error);
    fprintf('\n');
end
if NumEnt<=4,

```

```

% Generando el indice de entradas
[a b] = min(trn_error);
input_index = index(b,:);
elapsed_time = etime(clock, t0);
% Reordenando de acuerdo al error de entrenamiento
[a b] = sort(trn_error);
trn_error = trn_error(b);
chk_error = chk_error(b);
index = index(b, :);
% Mostrando errores de entrenamiento y prueba
figTitle = ['Selección de entradas ANFIS: Seleccionando ',...
num2str(NumEnt), ' entradas de ', num2str(NumTotalEnt), ' candidatas'];
figH = findobj(0, 'name', figTitle);
if isempty(figH),
    figH = figure('Name', figTitle, 'NumberTitle', 'off');
else
    set(0, 'currentfig', figH);
end
x = (1:ModAnfis)';
subplot(211);
plot(x, trn_error, '-', x, chk_error, '-', ...
x, trn_error, 'o', x, chk_error, '*', 'LineWidth', 2);
tmp = x(:, ones(1, 3))';
X = tmp(:);
tmp = [zeros(ModAnfis, 1) max(trn_error, chk_error)...
nan*ones(ModAnfis, 1)]';
Y = tmp(:);
hold on; plot(X, Y, 'g'); hold off;
axis([1 ModAnfis -inf inf]);
set(gca, 'xticklabel', []);
% Adicionando texto a las variables de entrada
if NumEnt == 2,
    for k = 1:ModAnfis,
        text(x(k), -0.3, ...
[deblank(input_name(index(k,1), :)) ' ' ...
deblank(input_name(index(k,2), :))]);
    end
elseif NumEnt == 3,
    for k = 1:ModAnfis,
        text(x(k), -0.3, ...
[deblank(input_name(index(k,1), :)) ' ' ...
deblank(input_name(index(k,2), :)) ' ' ...
deblank(input_name(index(k,3), :))]);
    end
elseif NumEnt == 4,
    for k = 1:ModAnfis,
        text(x(k), -0.3, ...
[deblank(input_name(index(k,1), :)) ' ' ...
deblank(input_name(index(k,2), :)) ' ' ...
deblank(input_name(index(k,3), :)) ' ' ...
deblank(input_name(index(k,4), :))]);
    end
end
h = findobj(gcf, 'type', 'text');
set(h, 'rot', 90, 'fontsize', 10, 'hori', 'right');
drawnow
title('Error de Entrenamiento (Circulos) y prueba (Asteriscos)');

```

```

        ylabel('RMSE');
elseif NumEnt==5,
    input_index=[1 2 3 4 5];
end
% Opciones de entrenamiento para más épocas
NumMF=input('\nNúmero de MF en cada variable de entrada ([2 3 3 3 2]...
o 2):');
TipoMF=input('\nTipo de MF de entrada (1:gauss, 2:campana...
generalizada, 3: trapezoidal ): ');
TipoMFOut=input('\nTipo de MF de salida (1:lineal, 2:constante ):');
NumEpoks=input('\nNúmero de épocas de entrenamiento: ');

%.....Tipo de Función de Membresía de entrada

switch TipoMF
case 1
    ITipoMF = 'gaussmf';
case 2
    ITipoMF = 'gbellmf';
case 3
    ITipoMF = 'trapmf';
otherwise
    error('MF no definida correctamente')
end

%.....Tipo de Función de Membresía de salida

switch TipoMFOut
case 1
    OTipoMF = 'linear';
case 2
    OTipoMF = 'constant';
otherwise
    error('MF no definida correctamente')
end

%....Con índices calculados se crea un nuevo conjunto de entrenamiento
% y valida

new_trn_data = traindata(:, [input_index, size(traindata,2)]);
new_chk_data = checkdata(:, [input_index, size(checkdata,2)]);

%.....Se entrena con ANFIS para más número de épocas

in_fismat2 = genfis1(new_trn_data,NumMF,ITipoMF,OTipoMF);

[trn_out_fismat2 trn_error2 step_size2 chk_out_fismat2 chk_error2]=...
anfis(new_trn_data, in_fismat2, [NumEpoks 0 0.04 0.9 1.1],[],...
new_chk_data, 1);

%.....Gráfico que nos ayuda a observar si hay overfitting

numepoks2=1:NumEpoks;
figure;
[v, w] = min(chk_error2);

```

```

plot(numepoks2, trn_error2, 'g-', numepoks2, chk_error2, 'r-', w, v,...
'ko','LineWidth',2);
title('Curva de error de entrenamiento (verde) y de prueba (rojo)');
xlabel('Epocas');
ylabel('RMSE');

%..Para evaluar la salida que produce el modelo respecto a los datos d
%entrenamiento

z0=evalfis(traindata(:, input_index),chk_out_fismat2);
RMSEtrnop1=norm(z0-y1)/sqrt(length(z0));

%.....Para evaluar la salida que produce el modelo respecto a los datos
%de prueba

z3=evalfis(checkdata(:, input_index),chk_out_fismat2);
RMSEchkop1=norm(z3-y2)/sqrt(length(z3));

%.....ANFIS vs modelo de Regresión Lineal

A_tr = [x1 ones(size(traindata,1), 1)];
B_tr = y1;
coef=A_tr\B_tr;
lr_rmsetr = norm(A_tr*coef-B_tr)/sqrt(size(traindata,1));
A_chkw = [x2 ones(size(checkdata,1), 1)];
B_chkw = y2;
lr_rmsechk = norm(A_chkw*coef-B_chkw)/sqrt(size(checkdata,1));

%.....Análisis de desempeño del modelo (Estadística)

reglintrn=polyfit(y1,z0,1); reglinval=polyfit(y2,z3,1);
ejext=0:0.1:max(y1)+2; ejexv=0:0.1:max(y2)+2;
ejeyt=polyval(reglintrn,ejext); ejeyv=polyval(reglinval,ejexv);

ypred = polyval(reglintrn,y1); dev = z0 - mean(z0);
SST = sum(dev.^2); resid = z0 - ypred;
SSE = sum(resid.^2); dfe = length(y1) - 1 - 1;
Rsq = 1 - SSE/SST; %RMSEtrn = sqrt(SSE/dfe);

ypred2 = polyval(reglinval,y2); dev2 = z3 - mean(z3);
SST2 = sum(dev2.^2); resid2 = z3 - ypred2;
SSE2 = sum(resid2.^2); dfe2 = length(y2) - 1 - 1;
Rsq2 = 1 - SSE2/SST2; %RMSEval = sqrt(SSE2/dfe2);
if Modelo==1,
figure;
%.....Gráfico de la salida del modelo z0
subplot(2,1,1)
plot(t1,y1, '- b',t1,z0, '- r')
xlabel('t [dias]');
legend('T° observada ','T° predicha por ANFIS');
ylabel('T °C');
title(['RMSE=',num2str(RMSEtrnop1),'(entrenamiento)'])
%.....Gráfico de la salida del modelo z3
subplot(2,1,2)
plot(t2,y2, '- b',t2,z3, '- r')

```

```

title(['RMSE=',num2str(RMSEchkop1),'(prueba)'])
xlabel('t [dias]');
legend('T° observada ', 'T° predicha por ANFIS');
ylabel('T °C');

figure;
%.....Dispersión para el conjunto de datos de entrenamiento con datos
%de prueba en ANFIS
subplot(2,1,1)
plot(y1,z0,'.',ejext,ejext,'--b',ejext,ejeyt,'k','LineWidth',2)
legend('Puntos Dato ', 'TANFIS=Tmedida', 'Regresión Lineal');
text(1, 35,['y = ',num2str(reglintrn(1), '%.2f'), ' * T +...
',num2str(reglintrn(2), '%.2f')])
text(1, 25,['SSE = ',num2str(SSE, '%.2f\n')])
text(1, 20,['R^2 = ',num2str(Rsq, '%.5f')])
xlabel('T medida [°C]');
ylabel('T ANFIS [°C]');
subplot(2,1,2)
%Dispersión para el conjunto de datos prueba con datos
%de prueba en ANFIS
plot(y2,z3,'.',ejexv,ejexv,'--b',ejexv,ejeyv,'k','LineWidth',2)
legend('Puntos Dato ', 'TANFIS=Tmedida', 'Regresión Lineal');
text(1, 35,['y = ',num2str(reglinval(1), '%.2f'), ' * T +...
',num2str(reglinval(2), '%.2f')])
text(1, 25,['SSE = ',num2str(SSE2, '%.2f\n')])
text(1, 20,['R^2 = ',num2str(Rsq2, '%.5f')])
xlabel('T medida [°C]');
ylabel('T ANFIS [°C]');

%=====
% Para exportar la salida a un archivo
%=====
fid = fopen('TempANFIS.xls', 'w');
fprintf(fid, '%6.2f\n', z3);
fclose(fid);
elseif Modelo==2,
figure;
%.....Gráfico de la salida del modelo HR Entren.
subplot(2,1,1)
plot(t1,y1, '- b', t1,z0, '- r')
xlabel('t [dias]');
legend('HR observada ', 'HR predicha por ANFIS');
ylabel('HR [%]');
title(['RMSE=',num2str(RMSEtrnop1), '(entrenamiento)'])
%.....Gráfico de la salida del modelo HR Valid.
subplot(2,1,2)
plot(t2,y2, '- b', t2,z3, '- r')
title(['RMSE=',num2str(RMSEchkop1), '(prueba)'])
xlabel('t [dias]');
legend('HR observada ', 'HR predicha por ANFIS');
ylabel('HR [%]');

figure;
%.....Dispersión para el conjunto de datos de entrenamiento con datos
%de prueba en ANFIS
subplot(2,1,1)

```

```

plot(y1,z0,'.',ejext,ejext,'--b',ejext,ejeyt,'k','LineWidth',2)
legend('Puntos Dato ','HRANFIS=HRmedida','Regresión Lineal');
title('Gráfico de dispersión con datos de entrenamiento');
text(2, 100,['y = ',num2str(reglintrn(1), '%.2f'), ' * HR +...
',num2str(reglintrn(2), '%.2f')])
text(2, 80,['SSE = ',num2str(SSE, '%.2f\n')])
text(2, 50,['R^2 = ',num2str(Rsq, '%.5f')])
xlabel('HR medida [%]');
ylabel('HR ANFIS [%]');
subplot(2,1,2)
%Dispersión para el conjunto de datos prueba con datos
%de prueba en ANFIS
plot(y2,z3,'.',ejexv,ejexv,'--b',ejexv,ejeyv,'k','LineWidth',2)
legend('Puntos Dato ','HRANFIS=HRmedida','Regresión Lineal');
title('Gráfico de dispersión con datos de prueba');
text(2, 100,['y = ',num2str(reglinval(1), '%.2f'), ' * HR +...
',num2str(reglinval(2), '%.2f')])
text(2, 80,['SSE = ',num2str(SSE2, '%.2f\n')])
text(2, 50,['R^2 = ',num2str(Rsq2, '%.5f')])
xlabel('HR medida [%]');
ylabel('HR ANFIS [%]');
%=====
% Para exportar la salida a un archivo
%=====
fid = fopen('HRGPANFIS.xls', 'w');
fprintf(fid, '%6.2f\n', z3);
fclose(fid);
end

fprintf('\n-----R--E--S--U--M--E--N-----\n ');
fprintf('\n ');
fprintf(' ANFIS: RMSE entrenamiento = %.4f RMSE prueba = %.4f \n ',...
RMSEtrnop1, RMSEchkop1);
fprintf('Modelo de Regresión Lineal: RMSE (entren.) = %1.4f RMSE...
(prueba) = %1.4f\n', lr_rmsetr, lr_rmsechk);
fprintf(' Funciones de Membresía = %d\n Tipo de MF = %s\n Epocas =...
%d\n', NumMF, ITipoMF, NumEpoks);
fprintf(' MF de salida = %s\n SSEtrn = %.2f\n R^2trn =...
%.5f\n', OTipoMF, SSE, Rsq);
fprintf(' SSEval = %.2f\n R^2val = %.5f\n', SSE2, Rsq2);
fprintf('\n ');
fprintf(' ----- \n ');

```

Apéndice D

PROGRAMA PARA MODELAR LA TEMPERATURA O LA HUMEDAD RELATIVA DENTRO DEL INVERNADERO, CON AGRUPAMIENTO SUSTRACTIVO Y ANFIS PARA MEJORAR LA RESPUESTA.

THRClustSubtr.m

```
%Programa para modelar la Temperatura del Aire y Humedad Relativa en el
%interior del invernadero empleando la red ANFIS, con una partición del
%espacio de entrada USANDO CLUSTERING SUSTRACTIVO mediante genfis2.
%$ LEOPOLDO HERNANDEZ LARRAGOITI
%Mayo del 2009
close all;
clear all
entrada=input('\n\n\nDatos de Entrenamiento(con extensión): ','s');
chkdata=input('\n\n\nDatos de prueba (con extensión): ','s');
Modelo=input('\n\n\nModela Temperatura(1) Modela HR (2): ');
r=input('\n\nRadio (influencia de centro de cluster [entre 0 y 1]):');
NumEpoks=input('\n\nNúmero de épocas de entrenamiento: ');
data=load (entrada);
chkval=load(chkdata);
%Hacemos x1 datos de entrenamiento y x2 prueba
x1 =data(:,1:5);
x2 =chkval(:,1:5);
% y1 salida de datos de entrenamiento y y2 de prueba
y1=data(:,6);
y2=chkval(:,6);
diastrn=[1:1:size(x1)]';
t1=diastrn/1440;
diaschk=[1:1:size(x2)]';
t2=diaschk/1440;
%Conjunto de datos de entrenamiento y prueba
traindata=[x1 y1];
testdata =[x2 y2];
if Modelo < 1 | Modelo > 2,
    error([mfilename, ...
        ' Selecciona 1 o 2 (T° o HR)']);
end
%.....Se genera el Sistema de Inferencia Difusa inicial

Fisini=genfis2(x1, y1, r);

%Evaluando la salida y el error (RMSE) que produce el modelo respecto
%al entrenamiento
SalidaFisini_trn=evalfis(x1,Fisini);
```

```

trnRMSE=norm(SalidaFisini_trn-y1)/sqrt(length(SalidaFisini_trn));
%Evaluando la salida y el error (RMSE) que produce el modelo respecto a
%la prueba
SalidaFisini_chk=evalfismex(x2,Fisini,101);
chkRMSE=norm(SalidaFisini_chk-y2)/sqrt(length(SalidaFisini_chk));

%.....Entrenando con ANFIS con datos de entrenam. y prueba

[Fisini2,trnErr2,stepSize,Fisini3,chkErr]=anfis(traindata,Fisini,...
[NumEpoks 0 0.01 0.9 1.1],[],testdata);

%.....Gráfico que nos ayuda a observar si hay overfitting

numepoks=1:NumEpoks;
figure;
[chkE, epk] = min(chkErr);
plot(numepoks, trnErr2, 'k--', numepoks, chkErr, 'b-', epk, chkE,...
'ko','LineWidth',2);
legend('error de entrenamiento ','error de prueba','mínimo error de...
prueba');
xlabel('Epocas');
ylabel('RMSE');

%Evaluamos el modelo de nuevo
SalidaFisini2_trn=evalfis(x1,Fisini3);
trnRMSE2=norm(SalidaFisini2_trn-y1)/sqrt(length(SalidaFisini2_trn));

SalidaFisini2_chk=evalfis(x2,Fisini3);
chkRMSE2=norm(SalidaFisini2_chk-y2)/sqrt(length(SalidaFisini2_chk));

%.....ANFIS vs modelo de Regresión Lineal

A_tr = [x1 ones(size(traindata,1), 1)];
B_tr = y1;
coef=A_tr\B_tr;
lr_rmsetr = norm(A_tr*coef-B_tr)/sqrt(size(traindata,1));
A_chkw = [x2 ones(size(testdata,1), 1)];
B_chkw = y2;
lr_rmsechk = norm(A_chkw*coef-B_chkw)/sqrt(size(testdata,1));

%.....Análisis de desempeño del modelo (Estadística)

coeftrn=polyfit(y1,SalidaFisini2_trn,1);
coefval=polyfit(y2,SalidaFisini2_chk,1);
ejext=0:0.1:max(y1)+2; ejexv=0:0.1:max(y2)+2;
ejeyt=polyval(coeftrn,ejext); ejeyv=polyval(coefval,ejexv);

ypred = polyval(coeftrn,y1); dev = SalidaFisini2_trn -...
mean(SalidaFisini2_trn);
SST = sum(dev.^2); resid = SalidaFisini2_trn - ypred;
SSE = sum(resid.^2); dfe = length(y1) - 1 - 1;
Rsq = 1 - SSE/SST;%RMSEtrn = sqrt(SSE/dfe);

ypred2 = polyval(coefval,y2); dev2 = SalidaFisini2_chk -...
mean(SalidaFisini2_chk);

```

```

SST2 = sum(dev2.^2); resid2 = SalidaFisini2_chk - ypred2;
SSE2 = sum(resid2.^2); dfe2 = length(y2) - 1 - 1;
Rsq2 = 1 - SSE2/SST2; %RMSEval = sqrt(SSE2/dfe2);

%...Escoger los títulos del gráfico ya sea si estamos modelando T° o HR

if Modelo==1,

%.....Gráfico de la salida del modelo: entrenamiento

figure;
subplot(2,1,1)
plot(t1,y1, '- b',t1,SalidaFisini2_trn,'- r')
xlabel('t [dias]');
legend('T° observada ', 'T° predicha por ANFIS');
ylabel('T °C');
title(['ANFIS con datos de entrenamiento y prueba...
RMSE=',num2str(trnRMSE2),'(entrenamiento)'])

%.....Gráfico de la salida del modelo: prueba

subplot(2,1,2)
plot(t2,y2, '- b',t2,SalidaFisini2_chk,'- r')
title(['ANFIS con datos de entrenamiento y prueba...
RMSE=',num2str(chkRMSE2),'(prueba)'])xlabel('t [dias]');
legend('T° observada ', 'T° predicha por ANFIS');
ylabel('T °C');

figure;
%....Dispersión para el conjunto de datos de entrenamiento con datos
%de prueba en ANFIS
subplot(2,1,1)
plot(y1,SalidaFisini2_trn, '.',ejext,ejext,...
'--b',ejext,ejeyt,'k','LineWidth',2)
legend('Puntos Dato ', 'TANFIS=Tmedida', 'Regresión Lineal');
text(1, 35,['y = ',num2str(coeftrn(1),'%.2f'),' * T +...
',num2str(coeftrn(2),'%.2f')])
text(1, 25,['SSE = ',num2str(SSE,'%.2f\n')])
text(1, 20,['R^2 = ',num2str(Rsq,'%.5f')])
xlabel('T medida [°C]');
ylabel('T ANFIS [°C]');
subplot(2,1,2)
%Dispersión para el conjunto de datos prueba con datos de prueba en
%ANFIS
plot(y2,SalidaFisini2_chk, '.',ejexv,ejexv,...
'--b',ejexv,ejeyv,'k','LineWidth',2)legend('Puntos Dato...
', 'TANFIS=Tmedida', 'Regresión Lineal');
text(1, 35,['y = ',num2str(coefval(1),'%.2f'),' * T +...
',num2str(coefval(2),'%.2f')])
text(1, 25,['SSE = ',num2str(SSE2,'%.2f\n')])
text(1, 20,['R^2 = ',num2str(Rsq2,'%.5f')])
xlabel('T medida [°C]');
ylabel('T ANFIS [°C]');

```

```

%=====
% Para exportar la salida a un archivo
%=====
fid = fopen('TSCANFIS.xls', 'w');
fprintf(fid, '%6.2f\n', SalidaFisini2_chk);
fclose(fid);

elseif Modelo==2,
%.....Gráfico de la salida del modelo: entrenamiento
figure;
subplot(2,1,1)
plot(t1,y1, '- b', t1, SalidaFisini2_trn, '--r')
xlabel('t [dias]');
legend('HR observada ', 'HR predicha por ANFIS');
ylabel('HR [%]');
title(['ANFIS con datos de entrenamiento y prueba...
RMSE=', num2str(trnRMSE2), '(entrenamiento)'])

%.....Gráfico de la salida del modelo: prueba

subplot(2,1,2)
plot(t2,y2, '- b', t2, SalidaFisini2_chk, '--r')
title(['ANFIS con datos de entrenamiento y prueba...
RMSE=', num2str(chkRMSE2), '(prueba)'])
xlabel('t [dias]');
legend('HR observada ', 'HR predicha por ANFIS');
ylabel('HR [%]');
figure;
%.....Dispersión para el conjunto de datos de entrenamiento con datos
%de prueba en ANFIS
subplot(2,1,1)
plot(y1, SalidaFisini2_trn, '.', ejext, ejext, ...
'--b', ejext, ejeyt, 'k', 'LineWidth', 2)
legend('Puntos Dato ', 'HRANFIS=HRmedida', 'Regresión Lineal');
text(3, 110, ['y = ', num2str(coeftrn(1), '%.2f'), ' * HR +...
', num2str(coeftrn(2), '%.2f')])
text(3, 90, ['SSE = ', num2str(SSE, '%.2f\n')])
text(3, 70, ['R^2 = ', num2str(Rsq, '%.5f')])
xlabel('HR medida [%]');
ylabel('HR ANFIS [%]');
subplot(2,1,2)
%Dispersión para el conjunto de datos prueba con datos
%de prueba en ANFIS
plot(y2, SalidaFisini2_chk, '.', ejexv, ejexv, ...
'--b', ejexv, ejeyv, 'k', 'LineWidth', 2)
legend('Puntos Dato ', 'HRANFIS=HRmedida', 'Regresión Lineal');
text(3, 110, ['y = ', num2str(coefval(1), '%.2f'), ' * HR +...
', num2str(coefval(2), '%.2f')])
text(3, 90, ['SSE = ', num2str(SSE2, '%.2f\n')])
text(3, 70, ['R^2 = ', num2str(Rsq2, '%.5f')])
xlabel('HR medida [%]');
ylabel('HR ANFIS [%]');

```

```

%=====
% Para exportar la salida a un archivo
%=====
fid = fopen('HRANFIS.xls', 'w');
fprintf(fid, '%6.2f\n', SalidaFisini2_chk);
fclose(fid);
end
fprintf('\n-----R--E--S--U--M--E--N-----\n ');
fprintf('\n ');
fprintf(' FIS inicial: RMSE entrenamiento = %.4f RMSE prueba =...
%.4f\n', trnRMSE, chkRMSE);
fprintf(' ANFIS: RMSE entrenamiento = %.4f RMSE prueba = %.4f \n '...
, trnRMSE2, chkRMSE2);
fprintf('Modelo de Regresión Lineal: RMSE (entren.) = %1.4f RMSE...
(prueba) = %1.4f\n', lr_rmsetr, lr_rmsechk);
fprintf(' Epocas = %d\n Radio = %.3f\n', NumEpoks, r);
fprintf(' SSEtrn = %.2f\n R^2trn = %.5f\n', SSE, Rsq);
fprintf(' SSEval = %.2f\n R^2val = %.5f\n', SSE2, Rsq2);
fprintf('\n ');
fprintf(' -----\n ');

```

Apéndice E

SELECCIÓN DE ENTRADAS, TEMPERATURA DEL INVERNADERO DE CHAPINGO, MEXICO

Tabla E.1 Resultados del Modelo de Temperatura obtenidos con partición de rejilla y ANFIS, haciendo selección de entradas. Para distintas particiones de datos. Invernadero de Chapingo.

5 entradas: Ro HRo Vv Dv To							
				r^2		RMSE ANFIS	
Partición	Número y tipo de MF	épocas	Tipo MF salida	Entren.	Prueba	Entren.	Prueba
65:35	2:gbell	450	lineal	0.97925	0.86215	1.0865	3.5277
	2:gbell	450	constante	0.95031	0.95079	1.6814	2.1079
	2:gauss	450	lineal	0.97896	0.84840	1.0942	3.7043
	2:gauss	450	constante	0.93471	0.92797	1.9274	2.6210
	3:gbell	10	lineal	0.98973	0.13824	0.7643	21.1882
	3:gbell	450	constante	0.97634	0.92731	1.1602	2.5584
	3:gauss	450	constante	0.96714	0.86288	1.3675	3.5104
	3:gauss	10	lineal	0.99034	0.15650	0.7415	19.1972
4 entradas: Ro HRo Vv To							
65:35	2:gbell	450	lineal	0.97280	0.89005	1.2440	3.1389
	2:gbell	450	constante	0.94896	0.94792	1.7041	2.1695
	2:gauss	450	lineal	0.97058	0.88268	1.2937	3.2454
	2:gauss	450	constante	0.93360	0.92648	1.9438	2.6393
	3:gbell	20	lineal	0.98170	0.52961	1.0205	7.4813
	3:gbell	450	constante	0.96940	0.92021	1.3196	2.6792
	3:gauss	450	constante	0.95289	0.88175	1.6371	3.3149
	3:gauss	20	lineal	0.98303	0.20997	0.9826	13.7037
3 entradas: Ro Vv To							
65:35	2:gbell	450	lineal	0.94524	0.93274	1.7651	2.4644
	2:gbell	450	constante	0.93726	0.94572	1.8894	2.2839
	2:gauss	450	lineal	0.94894	0.93178	1.7045	2.4856
	2:gauss	450	constante	0.92656	0.91700	2.0441	2.8135
	3:gbell	450	lineal	0.96347	0.88279	1.4417	3.2685
	3:gbell	450	constante	0.95372	0.93318	1.6227	2.4516
	3:gauss	450	constante	0.94017	0.93560	1.8450	2.4263
	3:gauss	450	lineal	0.96491	0.91273	1.4130	2.8141

Tabla E.1 Continuación...

				r ²	RMSE ANFIS		
Partición	Numero y Tipo de MF	épocas	Tipo MF salida	Entren.	Prueba	Entren.	Prueba
2 entradas: Ro To							
65:35	2:gbell	450	lineal	0.92830	0.91979	2.0197	2.6861
	2:gbell	450	constante	0.90742	0.93348	2.2951	2.5306
	2:gauss	450	lineal	0.92766	0.91491	2.0287	2.7676
	2:gauss	450	constante	0.89436	0.91973	2.4517	2.8550
	3:gbell	450	lineal	0.94759	0.90713	1.7269	2.8941
	3:gbell	450	constante	0.90092	0.91699	2.3744	2.8097
	3:gauss	450	constante	0.90116	0.91923	2.3714	2.8022
	3:gauss	450	lineal	0.94713	0.91128	1.7344	2.8280
5 entradas: Ro HRo Vv Dv To							
80:20	2:gbell	450	lineal	0.96837	0.89471	1.4255	2.9952
	2:gbell	450	constante	0.95306	0.95310	1.7365	2.1097
	2:gauss	450	lineal	0.97420	0.87379	1.2874	3.2798
	2:gauss	450	constante	0.93776	0.93698	1.9997	2.6035
	3:gbell	10	lineal	0.98588	0.06372	0.9523	38.3703
	3:gbell	450	constante	0.97472	0.92506	1.2745	2.5025
	3:gauss	450	constante	0.96784	0.87664	1.4374	3.2655
	3:gauss	10	lineal	0.98661	0.07482	0.9273	31.1895
4 entradas: Ro HRo Vv To							
80:20	2:gbell	450	lineal	0.96705	0.89914	1.4549	2.9442
	2:gbell	450	constante	0.95185	0.95578	1.7589	2.0350
	2:gauss	450	lineal	0.96884	0.90789	1.4149	2.8369
	2:gauss	450	constante	0.93566	0.93115	2.0331	2.6703
	3:gbell	20	lineal	0.97752	0.47766	1.2017	8.1913
	3:gbell	450	constante	0.94716	0.91840	1.8424	2.7089
	3:gauss	450	constante	0.95092	0.93102	1.7757	2.6041
	3:gauss	20	lineal	0.97840	0.43214	1.1779	8.9543
3 entradas: Ro Vv To							
80:20	2:gbell	450	lineal	0.94550	0.94823	1.8711	2.2429
	2:gbell	450	constante	0.94078	0.93861	1.9505	2.4480
	2:gauss	450	lineal	0.94842	0.94955	1.8204	2.2419
	2:gauss	450	constante	0.92876	0.91811	2.1393	2.9139
	3:gbell	450	lineal	0.96295	0.93268	1.5427	2.5237
	3:gbell	450	constante	0.95213	0.94843	1.7537	2.1815
	3:gauss	450	constante	0.94335	0.93714	1.9077	2.4834
	3:gauss	450	lineal	0.96116	0.93578	1.5795	2.4358
2 entradas: Ro To							
80:20	2:gbell	450	lineal	0.93065	0.92662	2.1107	2.5918
	2:gbell	450	constante	0.91417	0.93530	2.3482	2.6238
	2:gauss	450	lineal	0.92325	0.92736	2.2205	2.6047
	2:gauss	450	constante	0.91145	0.93388	2.3852	2.6051
	3:gbell	450	lineal	0.94301	0.92383	1.9134	2.5869
	3:gbell	450	constante	0.91925	0.92432	2.2777	2.6147
	3:gauss	450	constante	0.90925	0.92463	2.4146	2.7371
	3:gauss	450	lineal	0.94011	0.93161	1.9616	2.5240

Tabla E.1 Continuación...

5 entradas: Ro HRo Vv Dv To							
r^2				RMSE ANFIS			
Partición	Numero y Tipo de MF	épocas	Tipo MF salida	Entren.	Prueba	Entren.	Prueba
80.17:19.83	2:gbell	450	lineal	0.96811	0.88462	1.4330	3.1306
	2:gbell	450	constante	0.95533	0.95466	1.6959	2.0451
	2:gauss	450	lineal	0.97389	0.86798	1.2967	3.3304
	2:gauss	450	constante	0.93708	0.94056	2.0128	2.5420
	3:gbell	10	lineal	0.98580	0.06586	0.9561	36.9513
	3:gbell	450	constante	0.96822	0.91520	1.4305	2.7259
	3:gauss	450	constante	0.96626	0.85849	1.4739	3.4958
	3:gauss	10	lineal	0.98658	0.07480	0.9294	30.9108
4 entradas: Ro HRo Vv To							
80.17:19.83	2:gbell	450	lineal	0.96639	0.89641	1.4711	2.9871
	2:gbell	450	constante	0.95123	0.95832	1.7721	1.9779
	2:gauss	450	lineal	0.96815	0.90641	1.4320	2.8557
	2:gauss	450	constante	0.93474	0.93455	2.0498	2.6143
	3:gbell	20	lineal	0.97717	0.46650	1.2125	8.2107
	3:gbell	450	constante	0.94719	0.91887	1.8440	2.7130
	3:gauss	450	constante	0.95011	0.93695	1.7923	2.6076
	3:gauss	20	lineal	0.97794	0.43624	1.1919	8.9135
3 entradas: Ro Vv To							
80.17:19.83	2:gbell	450	lineal	0.94685	0.95228	1.8498	2.1560
	2:gbell	450	constante	0.93982	0.94250	1.9684	2.4054
	2:gauss	450	lineal	0.94765	0.95363	1.8360	2.1311
	2:gauss	450	constante	0.92804	0.92210	2.1525	2.8777
	3:gbell	450	lineal	0.95753	0.92647	1.6536	2.6017
	3:gbell	450	constante	0.95162	0.94879	1.7650	2.1650
	3:gauss	450	constante	0.94272	0.94119	1.9204	2.4023
	3:gauss	450	lineal	0.96082	0.92515	1.5883	2.5870
2 entradas: Ro To							
80.17:19.83	2:gbell	450	lineal	0.93014	0.92944	2.1208	2.5599
	2:gbell	450	constant	0.91348	0.94050	2.3603	2.6155
	2:gauss	450	lineal	0.92272	0.93136	2.2307	2.5501
	2:gauss	450	constant	0.90919	0.93636	2.4180	2.6156
	3:gbell	450	lineal	0.94245	0.92249	1.9249	2.6085
	3:gbell	450	constant	0.92067	0.93117	2.2600	2.5163
	3:gauss	450	constant	0.91829	0.92475	2.2937	2.6384
	3:gauss	450	lineal	0.93954	0.93321	1.9730	2.5388

Tabla E.2 Resultados del Modelo de Temperatura obtenidos con partición mediante agrupamiento sustractivo y ANFIS, para distintas particiones de datos.

Partición	radio	épocas	RMSE ANFIS		r^2	
			Entren.	Prueba	Entren.	Prueba
65:35	0.47	450	1.7758	2.4337	0.94457	0.93475
	0.48	450	1.6317	2.2568	0.95321	0.94308
	0.49	450	1.6337	2.2585	0.95309	0.94301
70:30	0.56	450	1.8740	2.3462	0.94123	0.94084
	0.57	450	1.8407	2.2765	0.94330	0.94447
	0.58	450	1.8400	2.2772	0.94335	0.94446
75:25	0.57	450	1.8412	2.4280	0.94367	0.93809
	0.58	450	1.8408	2.4267	0.94369	0.93811
	0.59	450	1.8401	2.4273	0.94374	0.93806
80:20	0.52	450	1.7838	2.0052	0.95047	0.95560
	0.53	450	1.7683	1.9658	0.95133	0.95944
	0.54	450	1.7713	2.2040	0.95116	0.95173
80.17:19.83	0.52	450	1.7684	1.9370	0.95143	0.96275
	0.53	450	1.7669	1.9150	0.95151	0.96329
	0.54	450	1.7801	2.1627	0.95079	0.95303
85:15	0.55	450	1.7437	2.1680	0.95101	0.96438
	0.56	450	1.7223	2.1319	0.95221	0.96224
	0.57	450	1.7222	2.1308	0.95221	0.96239

Apéndice F

SELECCIÓN DE ENTRADAS, HUMEDAD RELATIVA DEL INVERNADERO DE CHAPINGO, MEXICO

Tabla F.1 Resultados del Modelo de Humedad Relativa mediante partición de rejilla y ANFIS, para distintas particiones de datos. Invernadero de Chapingo, México.

5 entradas: Ro HRo Vv Dv To							
				r^2		RMSE ANFIS	
Partición	Numero y Tipo de MF	épocas	Tipo MF salida	Entren.	Prueba	Entren.	Prueba
69.14:30.86	2:gbell	450	lineal	0.97212	0.88116	3.8181	8.3012
	2:gbell	450	constante	0.95126	0.93152	5.0482	6.2401
	2:gauss	450	lineal	0.97446	0.90483	3.6544	7.4860
	2:gauss	450	constante	0.93098	0.88397	6.0072	8.6811
	3:gbell	10	lineal	0.98745	0.14096	2.5619	61.0935
	3:gbell	450	constante	0.97945	0.90309	3.2782	7.7334
	3:gauss	450	constante	0.96823	0.81668	4.0753	10.9113
	3:gauss	10	lineal	0.98677	0.09447	2.6305	76.3569
4 entradas: Ro HRo Vv To							
69.14:30.86	2:gbell	450	lineal	0.97057	0.87444	3.9223	8.4730
	2:gbell	450	constante	0.94644	0.93065	5.2919	6.3894
	2:gauss	450	lineal	0.97069	0.88243	3.9145	8.3477
	2:gauss	450	constante	0.92945	0.88366	6.0732	8.7478
	3:gbell	20	lineal	0.98104	0.72695	3.1483	15.0592
	3:gbell	450	constante	0.97106	0.89820	3.8898	7.9157
	3:gauss	450	constante	0.96304	0.87105	4.3957	8.6687
	3:gauss	20	lineal	0.98152	0.71825	3.1084	15.3339
3 entradas: Ro HRo To							
69.14:30.86	2:gbell	450	lineal	0.96367	0.93646	4.3582	6.0973
	2:gbell	450	constante	0.94464	0.93594	5.3799	6.1448
	2:gauss	450	lineal	0.96180	0.90171	4.4692	7.4634
	2:gauss	450	constante	0.91394	0.90983	6.7078	7.5426
	3:gbell	450	lineal	0.97336	0.85304	3.7318	9.5442
	3:gbell	450	constante	0.95004	0.93046	5.1109	6.4434
	3:gauss	450	constante	0.95559	0.92247	4.8186	6.9849
	3:gauss	450	lineal	0.97753	0.85729	3.4276	9.6607

Tabla F.1 Continuación...

2 entradas: Ro HRo							
r^2				RMSE ANFIS			
Partición	Numero y Tipo de MF	épocas	Tipo MF salida	Entren.	Prueba	Entren.	Prueba
69.14:30.86	2:gbell	450	lineal	0.95520	0.93799	4.8397	6.1346
	2:gbell	450	constante	0.93186	0.93344	5.9688	6.1075
	2:gauss	450	lineal	0.95529	0.94039	4.8346	6.0452
	2:gauss	450	constante	0.92471	0.92523	6.2739	7.0507
	3:gbell	450	lineal	0.96189	0.93486	4.4638	6.1994
	3:gbell	450	constante	0.94797	0.92768	5.2158	6.5832
	3:gauss	450	constante	0.95201	0.93147	5.0091	6.5030
	3:gauss	450	lineal	0.95858	0.92864	4.6534	6.4923
5 entradas: Ro HRo Vv Dv To							
75:25	2:gbell	450	lineal	0.97220	0.87984	3.7363	8.6332
	2:gbell	450	constante	0.95296	0.92479	4.8597	6.8425
	2:gauss	450	lineal	0.97494	0.90203	3.5475	7.9536
	2:gauss	450	constante	0.93184	0.87185	5.8502	9.4935
	3:gbell	10	lineal	0.98757	0.07887	2.4979	83.8469
	3:gbell	450	constante	0.97963	0.88076	3.1978	8.9454
	3:gauss	450	constante	0.96957	0.81035	3.9089	11.6927
	3:gauss	10	lineal	0.98686	0.09905	2.5690	74.6477
4 entradas: Ro HRo Vv To							
75:25	2:gbell	450	lineal	0.97120	0.86232	3.8024	9.2497
	2:gbell	450	constante	0.94828	0.92236	5.0958	7.0668
	2:gauss	450	lineal	0.97143	0.87083	3.7874	9.1078
	2:gauss	450	constante	0.93043	0.87319	5.9100	9.5145
	3:gbell	20	lineal	0.98153	0.68891	3.0456	16.9152
	3:gbell	450	constante	0.97187	0.89073	3.7581	8.5026
	3:gauss	450	constante	0.96334	0.85496	4.2902	9.5375
	3:gauss	20	lineal	0.98185	0.68202	3.0188	17.0968
3 entradas: Ro HRo To							
75:25	2:gbell	450	lineal	0.96495	0.92879	4.1948	6.7127
	2:gbell	450	constante	0.94629	0.92889	5.1932	6.7946
	2:gauss	450	lineal	0.96260	0.89838	4.3335	7.8926
	2:gauss	450	constante	0.91515	0.91141	6.5269	7.8426
	3:gbell	450	lineal	0.97416	0.84045	3.6018	10.4621
	3:gbell	450	constante	0.95568	0.92304	4.7174	6.9764
	3:gauss	450	constante	0.96047	0.88934	4.4551	8.5053
	3:gauss	450	lineal	0.97605	0.88840	3.4675	8.4568
2 entradas: Ro HRo							
75:25	2:gbell	450	lineal	0.95551	0.93749	4.7262	6.3561
	2:gbell	450	constante	0.93459	0.92565	5.7308	6.7311
	2:gauss	450	lineal	0.95574	0.93846	4.7141	6.3715
	2:gauss	450	constante	0.92398	0.92262	6.1780	7.4366
	3:gbell	450	lineal	0.96208	0.92946	4.3632	6.7142
	3:gbell	450	constante	0.94805	0.92378	5.1074	7.0157
	3:gauss	450	constante	0.95023	0.94554	4.9991	6.0306
	3:gauss	450	lineal	0.95910	0.92375	4.5318	6.9773

Tabla F.1 Continuación...

5 entradas: Ro HRo Vv Dv To							
r^2				RMSE ANFIS			
Partición	Numero y Tipo de MF	épocas	Tipo MF salida	Entren.	Prueba	Entren.	Prueba
80:20	2:gbell	450	lineal	0.97534	0.91578	3.5626	7.4693
	2:gbell	450	constante	0.95369	0.93057	4.8816	6.9980
	2:gauss	450	lineal	0.97383	0.92406	3.6696	7.6695
	2:gauss	450	constante	0.93081	0.89602	5.9669	9.0425
	3:gbell	10	lineal	0.98699	0.06447	2.5876	99.6991
	3:gbell	450	constante	0.97733	0.78607	3.4158	12.5993
	3:gauss	450	constante	0.97197	0.90546	3.7980	8.3802
	3:gauss	10	lineal	0.98707	0.24302	2.5792	45.0545
4 entradas: Ro HRo Vv To							
80:20	2:gbell	450	lineal	0.97096	0.92068	3.8657	7.2256
	2:gbell	450	constante	0.94713	0.92966	5.2161	7.1976
	2:gauss	450	lineal	0.96717	0.91743	4.1101	7.4479
	2:gauss	450	constante	0.92911	0.89339	6.0396	9.1123
	3:gbell	20	lineal	0.98088	0.70052	3.1364	15.2718
	3:gbell	450	constante	0.97188	0.88525	3.8037	8.6601
	3:gauss	450	constante	0.96219	0.90438	4.4107	7.7908
	3:gauss	20	lineal	0.98057	0.70523	3.1621	15.6629
3 entradas: Ro HRo To							
80:20	2:gbell	450	lineal	0.96383	0.94771	4.3142	6.1327
	2:gbell	450	constante	0.94629	0.93492	5.2573	6.9761
	2:gauss	450	lineal	0.96053	0.95509	4.5068	5.6927
	2:gauss	450	constante	0.92282	0.93419	6.3021	7.6163
	3:gbell	450	lineal	0.97693	0.89493	3.4459	8.7347
	3:gbell	450	constante	0.95523	0.93322	4.7998	6.8014
	3:gauss	450	constante	0.95205	0.92517	4.9672	7.1095
	3:gauss	450	lineal	0.97297	0.88810	3.7293	9.2411
2 entradas: Ro HRo							
80:20	2:gbell	450	lineal	0.95497	0.94790	4.8135	5.9666
	2:gbell	450	constante	0.92834	0.94933	6.0725	5.7443
	2:gauss	450	lineal	0.95529	0.94870	4.7966	6.0804
	2:gauss	450	constante	0.92467	0.93504	6.2258	7.4871
	3:gbell	450	lineal	0.95583	0.95358	4.7672	5.9086
	3:gbell	450	constante	0.94988	0.94626	5.0786	6.1282
	3:gauss	450	constante	0.95132	0.94684	5.0050	6.3744
	3:gauss	450	lineal	0.95704	0.94729	4.7015	6.1413

Tabla F.2 Resultados del Modelo de Humedad Relativa obtenidos mediante agrupamiento sustantivo y ANFIS , para distintas particiones de datos. Invernadero de Chapingo, México.

Partición	radio	épocas	RMSE ANFIS		r^2	
			Entren.	Prueba	Entren.	Prueba
50:50	0.49	450	4.5759	6.1172	0.95950	0.93349
	0.5	450	4.6809	5.8662	0.95762	0.93910
	0.51	450	4.6727	5.8666	0.95776	0.93909
55:45	0.49	450	4.7344	6.2628	0.95346	0.93489
	0.5	450	4.7824	6.0718	0.95251	0.93932
	0.51	450	4.7759	6.0740	0.95264	0.93928
60:40	0.46	450	4.6178	6.4078	0.95387	0.93527
	0.47	450	4.6127	6.3763	0.95397	0.93591
	0.48	450	4.6061	6.3787	0.95411	0.93586
65:35	0.60	450	4.6244	5.6424	0.95647	0.94583
	0.61	450	4.6423	5.9099	0.95613	0.94462
	0.62	450	4.6308	5.6560	0.95635	0.94497
69.14:30.86	0.67	450	4.8222	5.4362	0.95552	0.94905
	0.68	450	4.8308	5.4178	0.95537	0.94926
	0.69	450	4.8157	5.5061	0.95564	0.94748
70:30	0.60	450	4.8020	5.5197	0.95560	0.94826
	0.61	450	4.8069	5.4829	0.95551	0.94884
	0.62	450	4.8073	5.4877	0.95550	0.94870
75:25	0.51	450	4.6567	5.9318	0.95681	0.94658
	0.52	450	4.6520	5.9244	0.95690	0.94672
	0.53	450	4.6545	5.9725	0.95685	0.94528
80:20	0.72	450	4.6544	5.9151	0.95790	0.95452
	0.73	450	4.6492	5.9095	0.95799	0.95463
	0.74	450	4.6400	5.7236	0.95816	0.95593
85:15	0.29	450	4.7723	6.2298	0.95683	0.95558
	0.3	450	4.7746	6.2046	0.95679	0.95554
	0.31	450	4.7558	6.4310	0.95713	0.94841