



# PREDICCIÓN DE HUMEDAD Y TEMPERATURA EN INVERNADEROS USANDO MÉTODOS DE OPTIMIZACIÓN PARA CONJUNTOS DIFUSOS

Jonathan Steven Capera Quintana  
Sebastian Camilo Vanegas Ayala

UNIVERSIDAD DISTRITAL FRANCISCO JOSÉ DE CALDAS  
FACULTAD DE INGENIERÍA  
PROYECTO CURRICULAR INGENIERÍA DE SISTEMAS  
BOGOTÁ D.C., COLOMBIA  
2020

# **PREDICCIÓN DE HUMEDAD Y TEMPERATURA EN INVERNADEROS USANDO MÉTODOS DE OPTIMIZACIÓN PARA CONJUNTOS DIFUSOS**

**Jonathan Steven Capera Quintana  
Sebastian Camilo Vanegas Ayala**

Trabajo de grado presentado como requisito para optar por el título de:  
**Ingeniero de Sistemas**

Director:  
**Ing. Julio Barón Velandia PhD**

**UNIVERSIDAD DISTRITAL FRANCISCO JOSÉ DE CALDAS  
FACULTAD DE INGENIERÍA  
PROYECTO CURRICULAR INGENIERÍA DE SISTEMAS  
BOGOTÁ D.C., COLOMBIA  
2020**

*Dedicamos este proyecto a nuestras familias que nos han apoyado y acompañado paso a paso en nuestro camino de formación con gran esfuerzo e inmenso amor, a nuestros amigos y las personas que nos han brindado su compañía que son un pilar de fortaleza y motivación en el día a día, a la universidad y a su comunidad académica por formarnos como profesionales integrales con valores y otorgarnos herramientas para brindar un aporte significativo a la sociedad.*

## Agradecimientos

Agradecemos a la vida y a su espíritu creador, por brindarnos las herramientas, los momentos y las personas que nos han permitido llegar hasta este punto y alcanzar las metas que nos hemos planteado, a pesar de las adversidades y los obstáculos presentados durante el camino.

De igual forma agradecemos a nuestras familias por el apoyo incondicional, el acompañamiento en cada una de nuestras etapas, porque son un motivo de inspiración cada día y por mostrarnos que a través del amor y la disciplina podemos lograr cualquier cosa. A nuestros amigos por acompañarnos en nuestra vida académica y enseñarnos el valor del trabajo en equipo, la lealtad y la fraternidad. A las personas que nos han brindado su compañía en los malos y buenos momentos y que guardaremos en nuestro corazón.

A nuestra alma máter, la Universidad Distrital Francisco José de Caldas, por ser un recinto de conocimiento, esparcimiento y un entorno de crecimiento personal y académico, que nos ha brindado las herramientas y los recursos para convertirnos en profesionales de bien para enfrentar los retos que atañen a nuestra sociedad.

A los docentes que nos han acompañado en todos los espacios universitarios, en particular al docente Helbert Eduardo Espitia Cuchango, por su acompañamiento a través de los espacios académicos de Cibernética, que dieron origen a la idea del proyecto y sentaron las bases de un buen desarrollo, así mismo por su guía y recomendaciones durante la elaboración del mismo.

Y en especial, a nuestro director, Julio Barón Velandia, por el tiempo y seguimiento en cada uno de los pasos de la investigación, por ayudarnos a crecer como profesionales y mediante su orientación guiarnos en el camino para alcanzar nuestros objetivos.

# TABLA DE CONTENIDO

<b>1. INTRODUCCIÓN</b>	<b>1</b>
<b>2. PLANTEAMIENTO DEL PROBLEMA</b>	<b>3</b>
2.1. DESCRIPCIÓN DEL PROBLEMA . . . . .	3
2.2. FORMULACIÓN DEL PROBLEMA . . . . .	4
<b>3. OBJETIVOS</b>	<b>5</b>
3.1. OBJETIVO GENERAL . . . . .	5
3.2. OBJETIVOS ESPECÍFICOS . . . . .	5
<b>4. JUSTIFICACIÓN</b>	<b>7</b>
<b>5. MARCO TEÓRICO</b>	<b>9</b>
5.1. MARCO CONCEPTUAL . . . . .	9
5.1.1. Lógica Difusa . . . . .	9
5.1.2. Algoritmo Genético . . . . .	15
5.1.3. Algoritmos Cuasi-Newton . . . . .	16
5.1.4. Medición del Error . . . . .	18
5.2. MARCO REFERENCIAL . . . . .	20
5.2.1. Implementaciones relacionadas . . . . .	20
5.2.2. Tipos de ANFIS . . . . .	22
5.2.3. Predicción de humedad y temperatura climática . . . . .	27
5.2.4. Predicción de humedad y temperatura en invernaderos . . . . .	31
<b>6. ALCANCES Y LIMITACIONES</b>	<b>37</b>
6.1. ALCANCES . . . . .	37
6.2. LIMITACIONES . . . . .	37
<b>7. METODOLOGÍA</b>	<b>39</b>
7.1. RECOLECCIÓN DE DATOS . . . . .	40
7.2. DESARROLLO DE LAS PROPUESTAS . . . . .	40
7.3. CONSTRUCCIÓN Y DESPLIEGUE PROTOTIPO DE VISUALIZACIÓN . . . . .	41

<b>8. DESARROLLO</b>	<b>43</b>
8.1. SISTEMAS DE INFERENCIA DIFUSA TIPO MAMDANI . . . . .	43
8.1.1. Humedad . . . . .	44
8.1.2. Temperatura . . . . .	44
8.2. SISTEMA DE INFERENCIA DIFUSA TIPO SUGENO . . . . .	45
8.2.1. Humedad . . . . .	46
8.2.2. Temperatura . . . . .	47
8.3. ALGORITMO GENÉTICO PARA SISTEMA DE INFERENCIA DIFUSA TIPO MAM- DANI . . . . .	48
8.4. ALGORITMO GENÉTICO PARA SISTEMA DE INFERENCIA DIFUSA TIPO SU- GENO . . . . .	49
8.5. CUASI-NEWTON PARA SISTEMA DE INFERENCIA DIFUSA TIPO MAMDANI . .	50
8.6. CUASI-NEWTON PARA SISTEMA DE INFERENCIA DIFUSA TIPO SUGENO . . .	50
<b>9. RESULTADOS Y DISCUSIÓN</b>	<b>51</b>
9.1. PREDICCIÓN DE HUMEDAD Y TEMPERATURA EN EL AMBIENTE . . . . .	51
9.1.1. ALGORITMO GENÉTICO PARA SISTEMA DE INFERENCIA DIFUSA TI- PO MAMDANI . . . . .	51
9.1.2. ALGORITMO GENÉTICO PARA SISTEMA DE INFERENCIA DIFUSA TI- PO SUGENO . . . . .	55
9.1.3. CUASI-NEWTON PARA SISTEMA DE INFERENCIA DIFUSA TIPO MAM- DANI . . . . .	59
9.1.4. CUASI-NEWTON PARA SISTEMA DE INFERENCIA DIFUSA TIPO SUGENO	62
9.1.5. ANÁLISIS DE PREDICCIÓN HUMEDAD Y TEMPERATURA EN EL AM- BIENTE . . . . .	65
9.2. PREDICCIÓN DE HUMEDAD Y TEMPERATURA EN INVERNADEROS . . . . .	73
9.2.1. ALGORITMO GENÉTICO PARA SISTEMA DE INFERENCIA DIFUSA TI- PO MAMDANI . . . . .	73
9.2.2. ALGORITMO GENÉTICO PARA SISTEMA DE INFERENCIA DIFUSA TI- PO SUGENO . . . . .	77
9.2.3. CUASI-NEWTON PARA SISTEMA DE INFERENCIA DIFUSA TIPO MAM- DANI . . . . .	81
9.2.4. CUASI-NEWTON PARA SISTEMA DE INFERENCIA DIFUSA TIPO SUGENO	84
9.2.5. ANÁLISIS INVERNADERO . . . . .	86
<b>10. PROTOTIPO DE VISUALIZACIÓN</b>	<b>95</b>
10.1. FUNCIONAMIENTO DEL PROTOTIPO . . . . .	95
10.2. DESPLIEGUE DEL PROTOTIPO . . . . .	99
10.2.1. Aplicación de escritorio . . . . .	99
10.2.2. Aplicación Web . . . . .	100

<b>11.CONCLUSIONES</b>	<b>103</b>
<b>12.PROSPECTIVA DEL TRABAJO DE GRADO</b>	<b>105</b>
12.1. PRODUCTOS . . . . .	105
12.1.1. ARTÍCULOS . . . . .	105
12.1.2. PONENCIAS EN EVENTOS CIENTÍFICOS . . . . .	106
12.1.3. REGISTRO DE SOFTWARE Y PROPIEDAD INTELECTUAL . . . . .	106
12.2. LÍNEAS DE INVESTIGACIÓN FUTURAS . . . . .	106
12.3. TRABAJOS DE INVESTIGACIÓN FUTUROS . . . . .	106
<b>GLOSARIO</b>	<b>109</b>
<b>BIBLIOGRAFÍA</b>	<b>111</b>



# LISTA DE FIGURAS

5.1. Sistema de inferencia difusa convencional. . . . .	11
5.2. Ejemplo de Inferencia en un sistema de inferencia difusa de tipo Mamdani. . . . .	11
5.3. Inferencia en un sistema de inferencia difusa de tipo Sugeno. . . . .	12
5.4. Sistema de razonamiento difuso tipo 1 y su equivalente ANFIS de tipo 1. a) Razonamiento difuso de tipo 1. b) Equivalente ANFIS de tipo 1. . . . .	13
5.5. Funcionamiento del sistema de inferencia Tsukamoto. . . . .	15
7.1. Metodología aplicada. . . . .	39
8.1. Estructura ANFIS para humedad. . . . .	47
8.2. Estructura ANFIS para temperatura. . . . .	48
9.1. Comparación Humedad en el Ambiente (C1). . . . .	53
9.2. Error Humedad en el Ambiente (C1). . . . .	54
9.3. Comparación Temperatura en el Ambiente (C1). . . . .	54
9.4. Error Temperatura en el Ambiente (C1). . . . .	55
9.5. Comparación Humedad en el Ambiente (C2). . . . .	57
9.6. Error Humedad en el Ambiente (C2). . . . .	57
9.7. Comparación Temperatura en el Ambiente (C2). . . . .	58
9.8. Error Temperatura en el Ambiente (C2). . . . .	58
9.9. Comparación Humedad en el Ambiente (C3). . . . .	60
9.10. Error Humedad en el Ambiente (C3). . . . .	61
9.11. Comparación Temperatura en el Ambiente (C3). . . . .	61
9.12. Error Temperatura en el Ambiente (C3). . . . .	62
9.13. Comparación Humedad en el Ambiente (C4). . . . .	63
9.14. Error Humedad en el Ambiente (C4). . . . .	64
9.15. Comparación Temperatura en el Ambiente (C4). . . . .	64
9.16. Error Temperatura en el Ambiente (C4). . . . .	65
9.17. Funciones de pertenencia para humedad en el ambiente. . . . .	67
9.18. Reglas del sistema de inferencia para humedad en el ambiente. . . . .	68
9.19. Superficie de salida humedad en el ambiente. . . . .	68

9.20. Tabla de análisis de la varianza de la humedad en el ambiente mediante la prueba de Kruskal-Wallis. . . . .	69
9.21. Distribución de los datos de humedad del ambiente obtenidos mediante la prueba de Kruskal-Wallis. . . . .	69
9.22. Funciones de pertenencia para temperatura en el ambiente. . . . .	70
9.23. Reglas del sistema de inferencia para temperatura en el ambiente. . . . .	71
9.24. Superficie de salida para temperatura en el ambiente. . . . .	71
9.25. Tabla de análisis de la varianza de la temperatura en el ambiente mediante la prueba de Kruskal-Wallis. . . . .	72
9.26. Distribución de los datos de temperatura del ambiente obtenidos mediante la prueba de Kruskal-Wallis. . . . .	72
9.27. Comparación Humedad en Invernadero (C1). . . . .	75
9.28. Error Humedad en Invernadero (C1). . . . .	75
9.29. Comparación Temperatura en Invernadero (C1). . . . .	76
9.30. Error Temperatura en Invernadero (C1). . . . .	77
9.31. Comparación Humedad en Invernadero (C2). . . . .	79
9.32. Error Humedad en Invernadero (C2). . . . .	79
9.33. Comparación Temperatura en Invernadero (C2). . . . .	80
9.34. Error Temperatura en Invernadero (C2). . . . .	80
9.35. Comparación Humedad en Invernadero (C3). . . . .	82
9.36. Error Humedad en Invernadero (C3). . . . .	82
9.37. Comparación Temperatura en Invernadero (C3). . . . .	83
9.38. Error Temperatura en Invernadero (C3). . . . .	83
9.39. Comparación Humedad en Invernadero (C4). . . . .	84
9.40. Error Humedad en Invernadero (C4). . . . .	85
9.41. Comparación Temperatura en Invernadero (C4). . . . .	85
9.42. Error Temperatura en Invernadero (C4). . . . .	86
9.43. Funciones de pertenencia para humedad en invernadero. . . . .	88
9.44. Reglas del sistema de inferencia para humedad en invernadero. . . . .	89
9.45. Superficie de salida humedad en invernadero. . . . .	89
9.46. Tabla de análisis de la varianza de la humedad en invernadero mediante la prueba de Kruskal-Wallis. . . . .	90
9.47. Distribución de los datos de humedad en invernadero obtenidos mediante la prueba de Kruskal-Wallis. . . . .	90
9.48. Funciones de pertenencia para temperatura en invernadero. . . . .	91
9.49. Reglas del sistema de inferencia para temperatura en invernadero. . . . .	92
9.50. Superficie de salida para temperatura en invernadero. . . . .	92
9.51. Tabla de análisis de la varianza de la temperatura en invernadero mediante la prueba de Kruskal-Wallis. . . . .	93
9.52. Distribución de los datos de temperatura en invernadero obtenidos mediante la prueba de Kruskal-Wallis. . . . .	93

10.1. Datos de humedad y temperatura del ambiente e invernadero. . . . .	96
10.2. Carga de datos 48 horas. . . . .	96
10.3. Interfaz prototipo de visualización. . . . .	97
10.4. Prototipo de visualización, predicción de humedad en un invernadero. . . . .	98
10.5. Prototipo de visualización, conjuntos difusos humedad en un invernadero. . . . .	99
10.6. Archivos de despliegue prototipo de visualización. . . . .	100
10.7. Servidor de aplicaciones Web. . . . .	100
10.8. Prototipo como aplicación Web. . . . .	101



# LISTA DE TABLAS

5.1. Implementaciones relacionadas. . . . .	20
5.2. Tipos de ANFIS de predicción de fenómenos. . . . .	23
5.3. Modelos de predicción de humedad y temperatura climática. . . . .	28
5.4. Modelos de predicción de humedad y temperatura en invernaderos. . . . .	32
8.1. Configuración sistema de inferencia difusa tipo Mamdani. . . . .	43
8.2. Configuración sistema de inferencia difusa tipo Sugeno. . . . .	45
8.3. Configuración algoritmo genético sistema de inferencia difusa tipo Mamdani. . . . .	48
8.4. Configuración algoritmo genético sistema de inferencia difusa tipo Sugeno. . . . .	49
8.5. Configuración Cuasi-Newton sistema de inferencia difusa tipo Mamdani. . . . .	50
8.6. Configuración Cuasi-Newton sistema de inferencia difusa tipo Sugeno. . . . .	50
9.1. Ejecuciones Algoritmo Genético para Sistema de Inferencia Difusa Tipo Mamdani (C1) en el Ambiente . . . . .	52
9.2. Ejecuciones Algoritmo Genético para Sistema de Inferencia tipo Sugeno (C2) en el Ambiente. . . . .	55
9.3. Cuasi-Newton para Sistema de Inferencia Difusa Tipo Mamdani (C3) en el Ambiente. . . . .	59
9.4. Cuasi-Newton para Sistema de Inferencia Difusa Tipo Sugeno (C4) en el Ambiente. . . . .	62
9.5. Resultados de predicción de humedad y temperatura en el ambiente. . . . .	66
9.6. Ejecuciones Algoritmo Genético para Sistema de Inferencia Difusa Tipo Mamdani (C1) en Invernadero . . . . .	73
9.7. Ejecuciones Algoritmo Genético para Sistema de Inferencia Difusa Tipo Sugeno (C2) en Invernadero . . . . .	77
9.8. Cuasi-Newton para Sistema de Inferencia Difusa Tipo Mamdani (C3) en Invernadero. . . . .	81
9.9. Cuasi-Newton para Sistema de Inferencia Difusa Tipo Sugeno (C4) en Invernadero. . . . .	84
9.10. Resultados de predicción de humedad y temperatura en invernadero. . . . .	87



# Capítulo 1

## INTRODUCCIÓN

Teniendo en cuenta las aplicaciones masivas de las Tecnologías de la Información y las Comunicaciones (TIC) y su influencia en el modo de producción agrícola, se han vinculado procesos derivados de la era de Internet, como Big Data, en el flujo de información que hace parte de la cadena agrícola (Kang y col., 2018). En este contexto, los datos tienen un papel relevante, por ejemplo, la información del medio ambiente y del registro de gestión, obtenidos durante el proceso de producción, son utilizados para la predicción de condiciones climáticas en ambientes controlados.

Para la creación de un microclima interior para el desarrollo de cultivos, manteniendo el confort térmico y aplicando las TIC existen modelos que desarrollan un sistema de monitoreo, utilizando sensores instalados en ciertas ubicaciones en el terreno de la plantación, donde los usuarios pueden monitorear el estado del cultivo desde cualquier lugar y en cualquier momento desde un dispositivo que permite el acceso remoto al sistema de información (Nugroho y col., 2017). Esta información puede ser usada para predicción de condiciones ambientales y aplicar técnicas de control como la división del proceso en períodos, utilizando un controlador que permita impulsar el clima interno del invernadero a partir de las condiciones monitoreadas (Fourati, 2014).

El control de las condiciones climáticas en un invernadero requiere establecer modelos que permitan un gran precisión en la predicción de las condiciones ambientales como lo es la humedad y temperatura, pero que también brinde una facilidad de uso e interpretación, es decir un alto grado de interpretabilidad para desarrollar un entendimiento del comportamiento del cultivo a lo largo de su ciclo de vida y poder aplicar las acciones necesarias, ya sean de control, prevención o alerta, para que este tenga un alto grado de desarrollo.



## Capítulo 2

# PLANTEAMIENTO DEL PROBLEMA

### 2.1. DESCRIPCIÓN DEL PROBLEMA

El propósito principal de los invernaderos agrícolas es permitir la creación de un microclima interior para el desarrollo de cultivos que pueda proteger a las plantas de condiciones climáticas adversas en el exterior (temperatura exterior y humedad). Para un diseño de control avanzado de invernaderos el primer paso es el desarrollo de un modelo dinámico de las variables climáticas que intervienen en el invernadero, es por ello que un aspecto fundamental es mantener la calidad del modelo para lograr rendimientos de control adecuados (Outanoute y col., 2015).

Actualmente adquiere gran importancia el confort térmico, ya que es necesario para los microclimas en una atmósfera cerrada considerar que hay elementos principales que determinan la percepción de la calidad ambiental desde el punto de vista térmico, tales como mediciones de la temperatura y humedad relativa del ambiente exterior así como la humedad relativa interna, las cuales son variables de entrada del sistema analizado (Castañeda-Miranda & Castaño, 2017). Por otra parte, es importante poder predecir las variables que definen este confort térmico, ya que se deben destinar recursos con el fin de mantener un control adecuado de los cultivos, para ello la predicción de las variables de temperatura y humedad de un invernadero puede realizarse a partir de diversos datos obtenidos de un sistema de monitoreo. Sin embargo, esta predicción requiere algoritmos eficientes para obtener una mayor exactitud, es por esto que se aplican diversas técnicas de optimización heurísticas o exactas para mejorar los modelos de predicción (Lenka & Mohapatra, 2015).

Los modelos de predicción de condiciones medio ambientales externas como internas de un invernadero se basan en técnicas orientadas a la alta precisión del modelo, por ejemplo, las redes neuronales artificiales (Putro y col., 2018), o en técnicas cualitativas que brindan una alta interpretabilidad, co-

mo los conjuntos difusos (Chen y col., 2016). Se observa, a través de la revisión bibliográfica, que no se cuenta con un modelo que defina de manera clara un balance entre precisión y significancia, que pueda brindar al usuario del invernadero la posibilidad de interpretar, de manera sencilla, los datos de predicción y tomar decisiones respecto a los mismos de manera acertada como consecuencia de una alta exactitud.

## **2.2. FORMULACIÓN DEL PROBLEMA**

¿Cómo predecir humedad y temperatura en invernaderos manteniendo una alta interpretabilidad y precisión, usando métodos de optimización de conjuntos difusos, para contribuir a la mejora en técnicas de control en el desarrollo de cultivos?

## Capítulo 3

# OBJETIVOS

### 3.1. OBJETIVO GENERAL

Desarrollar un modelo que permita predecir los valores de humedad y temperatura en un invernadero con una alta precisión e interpretabilidad, basado en el establecimiento de conjuntos difusos y abordados con técnicas de optimización, esto con el fin de que los usuarios del invernadero puedan determinar su comportamiento de forma clara y sencilla.

### 3.2. OBJETIVOS ESPECÍFICOS

- Elaborar modelos de conjuntos difusos que permitan predecir los valores de humedad y temperatura del ambiente, mediante un análisis estadístico de los datos de entrada, para presentar diferentes alternativas que puedan brindar distintos niveles de precisión.
- Aplicar técnicas de optimización que permitan mejorar la precisión de los modelos propuestos, usando métodos heurísticos como los algoritmos genéticos y métodos exactos como Cuasi-Newton, permitiendo asegurar un alto grado de significancia.
- Analizar los resultados obtenidos en cada propuesta determinando su grado de precisión, mediante el uso de técnicas estadísticas como el error medio cuadrático, con el propósito de identificar la propuesta que proporcione la más alta precisión e interpretabilidad.



## Capítulo 4

# JUSTIFICACIÓN

La agricultura es un campo de vital importancia en el desarrollo de la vida humana, con el creciente aumento de las tecnologías y desarrollos científicos se han propuesto diversas herramientas, cuyo objetivo ha sido el de propiciar mejores condiciones para el desarrollo de esta actividad, de manera que se pueda cumplir con la necesidad requerida por la sociedad de abastecer a sus habitantes. Dentro de este aspecto, se analizan los invernaderos como una alternativa a técnicas de cultivo tradicionales, que permite establecer un ambiente controlado, brindando protección a los cultivos de agentes externos (Nugroho y col., 2017).

La automatización es un aspecto de alta relevancia en la implementación de invernaderos, donde la distribución de un conjunto de sensores y actuadores permite evaluar las condiciones del microclima que presenta el invernadero, así como establecer las acciones de control pertinentes para el crecimiento óptimo de los especímenes vegetales. Para poder realizar la detección del comportamiento de un invernadero, es necesario tener claridad a la hora de determinar las variables que participan en el sistema, de este análisis se obtiene que la temperatura y humedad del ambiente representan la mayor parte de la dinámica del sistema. Por ende, los modelos que se basen en la predicción del estado del microclima interno de los invernaderos deben tener en cuenta la interacción de estas variables en el sistema (Outanoute y col., 2015).

Distintas técnicas han sido usadas para realizar modelos que se acerquen al comportamiento del ambiente interno de los invernaderos, algunas están centradas en asegurar la mayor precisión posible a través del análisis cuantitativo de los datos, entre las que se encuentran el uso de diversos tipos de redes neuronales y algoritmos genéticos que otorgan resultados adecuados en cuanto a la predicción, pero carecen de un modelo que sea representativo y cuya dinámica no es fácil de distinguir. Por otra parte, se encuentran aquellos modelos que se enfocan en la interpretabilidad, a través del análisis cualitativo, dentro de los cuales se tienen los sistemas de inferencia mediante conjuntos difusos que hacen uso de un conocimiento previo de la dinámica del sistema para determinar las predicciones que se realizarán sobre su comportamiento y que cuentan con la ventaja de brindar una comprensión relativamente

sencilla de la forma en que actúa el sistema.

Dentro de la revisión bibliográfica realizada se observa que no existen estudios relevantes en este campo que permitan encontrar un balance entre precisión y significancia de los modelos propuestos, es por ello que se considera que el combinar una técnica de optimización con la aplicación de conjuntos difusos para la predicción de las variables de humedad y temperatura, brinda una mayor comprensión y entendimiento, ya que se basa en aspectos cualitativos y genera resultados adecuados para el control de las variables manteniendo un alto grado de precisión, considerando la necesidad del cultivo en un periodo de tiempo determinado.

## Capítulo 5

# MARCO TEÓRICO

### 5.1. MARCO CONCEPTUAL

Acorde a los objetivos planteados, se propone un esquema de investigación para definir el estado del arte y priorizar los elementos conceptuales, que constituyen el insumo para el planteamiento, diseño y desarrollo del proyecto. Se identifican 4 enfoques principales en los que se destaca el análisis de sistemas de inferencia basados en lógica difusa, la aplicación de métodos estocásticos como los algoritmos genéticos y métodos determinísticos como los algoritmos Cuasi-Newton, así como un apartado dedicado al proceso de medición y obtención de resultados, relacionado con el cálculo y determinación del error.

#### 5.1.1. Lógica Difusa

El lenguaje natural es posiblemente la más poderosa forma de comunicación que poseen los seres humanos para cualquier problema o situación que requiera solución o razonamiento. Este poder no se ha explotado en los paradigmas matemáticos moderno, no tanto como en la lógica difusa (Ross, 2010).

Un sistema difuso consiste en un sistema en el cual los rangos de las variables sobre los cuales representan sus estados (o, al menos, algunas de ellas) se tratan de conjuntos difusos. Para cada variable, los conjuntos difusos son definidos en un algún conjunto difuso que a menudo es un intervalo de números reales y las variables asociadas son variables lingüísticas (Klir & Yuan, 1995).

Se presentan los sistemas de inferencia difusa de tipo Mamdani, así como de tipo Sugeno y para finalizar, un sistema de inferencia neurodifuso adaptativo (ANFIS).

### Sistema de Inferencia Difusa MAMDANI

Los sistemas de inferencia difusa de tipo Mamdani fueron diseñados originalmente para imitar el rendimiento de los operarios humanos encargados de controlar ciertos procesos industriales (Izquierdo & Izquierdo, 2018).

La idea de este sistema era resumir la experiencia del operario en una serie de reglas (lingüísticas) condicionales SI-ENTONCES (IF-THEN) que una máquina pueda emplear para controlar automáticamente el proceso. Específicamente, utilizando este conjunto de reglas condicionales, un sistema difuso de tipo Mamdani define una función  $f$  que genera salidas numéricas  $y = f(x)$  a partir de valores (por lo general numéricos) de entrada  $x$  (Izquierdo & Izquierdo, 2018).

La mayoría de sistemas Mamdani están compuestos de múltiples reglas condicionales (IF-THEN). Naturalmente, cada una de estas reglas puede pertenecer a distintos conjuntos difusos. Además, los antecedentes y los consecuentes se pueden conectar a través de conectores lógicos “Y” (AND) y “O” (OR) (Izquierdo & Izquierdo, 2018).

Dado que los sistemas de tipo Mamdani cuentan con una base de reglas fácil de comprender e intuitivo, son apropiados para aplicaciones de sistemas expertos donde las reglas son creadas a partir del conocimiento experto humano, como en diagnósticos médicos (MathWorks Inc., 2019).

El sistema Mamdani pasa por seis etapas o pasos para calcular la respectiva salida, los cuales son (Knapp, 2007b):

- Determinar un conjunto de reglas difusas.
- Realizar el proceso de crear los conjuntos borrosos o difusos (“fuzzify” en inglés) en las entradas utilizando las funciones de pertenencia de la entrada.
- Combinar las entradas difusas de acuerdo a las reglas difusas para establecer el peso de la regla.
- Encontrar la consecuencia de la regla combinando el peso de la regla y la función de pertenencia de la salida.
- Combinar los consecuentes para obtener una distribución de salida.
- Realizar el proceso de “defuzzify” sobre la distribución de la salida. Se realiza cuando se una salida concreta.

Este proceso se lleva a cabo se puede observar en la Fig. 5.1, en el cual se realiza este proceso en el cual, dada una entrada concreta, se obtiene una salida (que puede ser difusa o concreta).

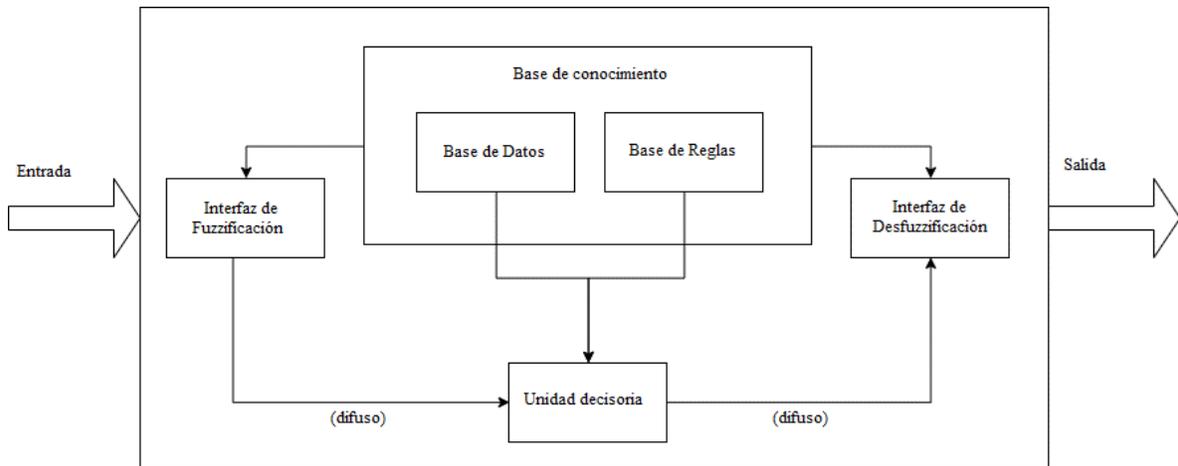


Fig. 5.1: Sistema de inferencia difusa convencional. Adaptado de (Mehran, 2008)

En la Fig. 5.2, para el proceso de inferencia en un sistema Mamdani mediante un sencillo ejemplo mediante el cual, de acuerdo al servicio proporcionado, se otorga la propina correspondiente.

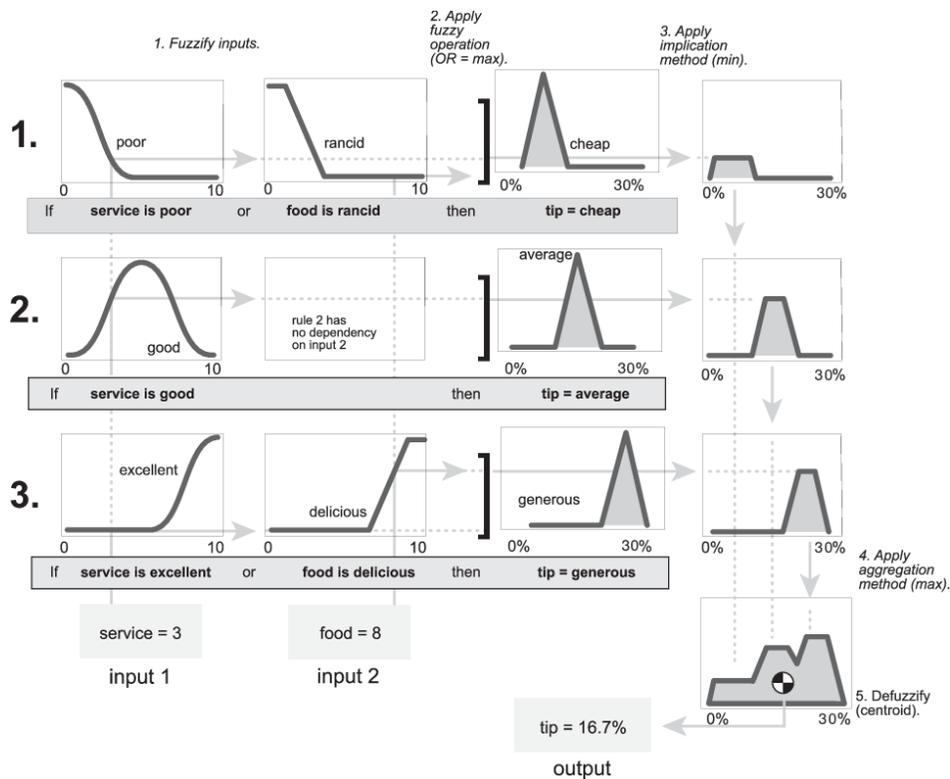


Fig. 5.2: Ejemplo de Inferencia en un sistema de inferencia difusa de tipo Mamdani. Tomado de (MathWorks Inc., 2019) © 2019 The MathWorks, Inc.

Entre las ventajas con las que cuenta un sistema de inferencia difusa de este tipo se puede mencionar

(MathWorks Inc., 2019):

- Intuitivo.
- Diseñado para una apropiada entrada de datos para un ser humano.
- Base de reglas con mayor interpretabilidad.
- Amplia aceptación.

### Sistema de Inferencia Difusa SUGENO

Este sistema de inferencia es similar al sistema Mamdani, la diferencia principal entre este y otros es que, en el sistema Sugeno no hay como tal una función de pertenencia en la salida, sino que se trata de un número concreto que es calculado multiplicando cada entrada por una constante (coeficientes) y luego sumando los resultados correspondientes (Knapp, 2007b). La característica principal de este modelo es que permite expresar la dinámica local de cada regla difusa mediante una expresión lineal (Mehran, 2008).

Entre las ventajas con las que cuenta un sistema de inferencia difusa de este tipo se puede mencionar (MathWorks Inc., 2019):

- Eficiencia a nivel computacional.
- Funciona bien con técnicas de optimización y técnicas adaptativas.
- Funciona bien con técnicas lineales (ej: Control PID).
- Apropiada para realizar análisis matemático.

En la Fig. 5.3 se puede observar como el sistema Sugeno opera, en este caso, para un sistema de dos entradas  $x$  e  $y$ .

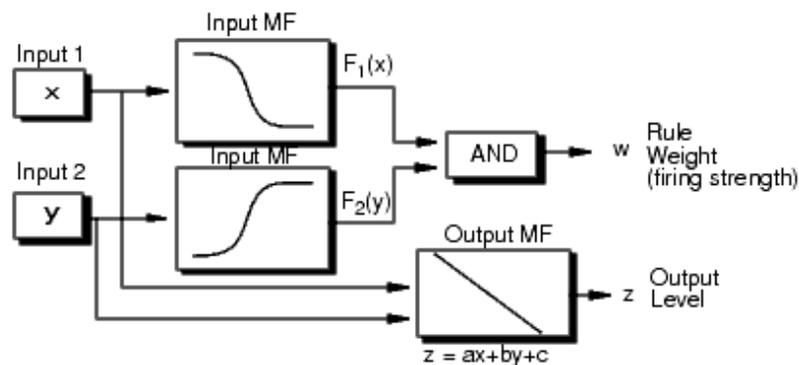


Fig. 5.3: Inferencia en un sistema de inferencia difusa de tipo Sugeno. Tomado de (MathWorks Inc., 2019) © 2019 The MathWorks, Inc.

Uno de los problemas que posee este tipo de sistemas es que no hay un método intuitivo confiable para determinar los valores de los coeficientes. Además de esto, sólo cuenta con salidas concretas, un elemento que puede no ser conveniente en una aplicación de interacción humano-máquina (HCI) (Knapp, 2007b).

La razón por la cual se podría utilizar este sistema en vez de un sistema Mamdani resulta en que existen algoritmos que pueden optimizar el sistema (como el ANFIS, del cual se hará una mención posteriormente).

**Sistema de Inferencia Neurodifusa Adaptativo (ANFIS)**

El Sistema de Inferencia Neurodifuso Adaptativo (ANFIS) consiste de un sistema de inferencia difuso implementado en el marco de trabajo de las redes neuronales adaptativas. Utilizando un procedimiento de aprendizaje híbrido, el ANIFIS puede construir un mapa de entrada-salida basado tanto en conocimiento humano así como de pares de entrada-salida estipulados (Shing & Jang, 1993). Entre sus aplicaciones se encuentra el modelo de funciones no lineales, predicción de series de tiempo caóticas así como de sistemas de control automático y procesamiento de señales (Shing & Jang, 1993).

En la Fig. 5.4 se puede observar un sistema de razonamiento difuso de tipo 1, junto a su equivalente en una arquitectura de tipo ANFIS (denominado ANFIS de tipo 1):

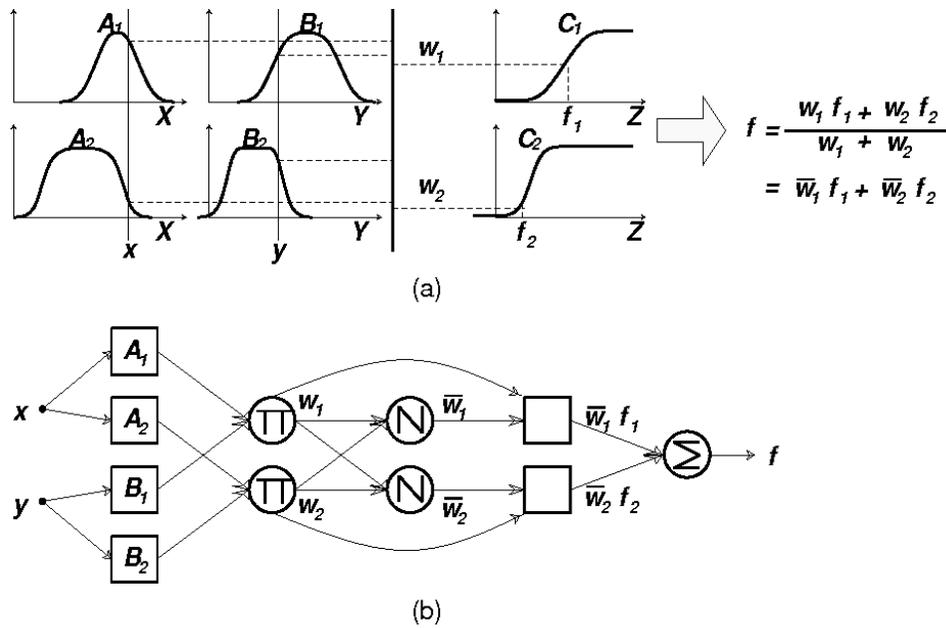


Fig. 5.4: Sistema de razonamiento difuso tipo 1 y su equivalente ANFIS de tipo 1. a) Razonamiento difuso de tipo 1. b) Equivalente ANFIS de tipo 1. Tomado de (Shing & Jang, 1993) © 1993 IEEE.

Los parámetros de un sistema de inferencia difuso se pueden optimizar automáticamente utilizando

un algoritmo (Knapp, 2007a). El Sistema de Inferencia Neurodifuso adaptativo es uno de los algoritmos, que toma los parámetros del sistema de inferencia difuso y los adapta utilizando redes neuronales (Knapp, 2007a).

Los pasos que se deben realizar para construir un sistema ANFIS son (Knapp, 2007a):

- Diseñar un sistema de inferencia (FIS) de tipo Sugeno para realizar la clasificación.
- Optimizar manualmente el sistema de inferencia difuso (FIS) dado los datos de clasificación de entrada.
- Preparar los datos de entrenamiento y de prueba. Estos datos están compuestos de entradas y la clasificación correspondiente a esas entradas.
- Ejecutar el algoritmo ANFIS en los datos de entrenamiento.
- Validar los resultados utilizando los datos de prueba.

Las ventajas que presenta un sistema ANFIS sobre una red neuronal perceptrón multicapa son las siguientes; cabe mencionar que estas ventajas salen a partir que ANFIS presenta una estructura matemática más específica, lo cual le permite ser un aproximador adaptativo (Isanta Navarro, s.f.)

- Mejor habilidad para el aprendizaje ya que se llega a una convergencia de error menor.
- No presenta una convergencia súbita precedida de una región de inestabilidad considerable.
- Requiere menor cantidad de parámetros ajustables.
- Su estructura permite uso de la computación paralela.

Y las ventajas que posee son:

- Integración de representación de conocimiento bien estructurado.
- Integración con otros métodos de diseño de control.

### **Sistema de Inferencia Difusa TSUKAMOTO**

Lo que caracteriza a este sistema de inferencia es que el consecuente de cada regla condicional está representado por un conjunto difuso con una función de pertenencia monótona. Esto significa que, las entradas de cada regla son concretas (crisp) presentando un predicado y obteniendo como resultado final un promedio ponderado (Ariani & Endra, 2013). El valor  $\mu$  hace referencia al valor mínimo del grado de pertenencia (Czabanski y col., 2017; Perangin-angin y col., 2016).

En la Fig. 5.5 se evidencian las etapas que caracterizan el funcionamiento del sistema de inferencia Tsukamoto (Adriyendi, 2018):

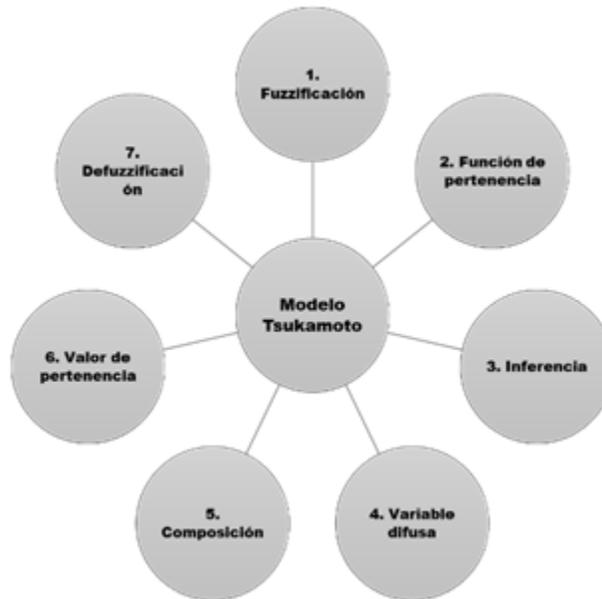


Fig. 5.5: Funcionamiento del sistema de inferencia Tsukamoto. Adaptado de (Adriyendi, 2018).

Este modelo de inferencia es bastante útil en situaciones de vaguedad e incertidumbre, aportando tanto flexibilidad como tolerancia en el análisis de los datos (Adriyendi, 2018).

### 5.1.2. Algoritmo Genético

Los algoritmos genéticos son algoritmos basados en los principios de la genética y de la selección natural. Los elementos de la genética natura –Reproducción, cruzamiento y mutación – son utilizados para el procedimiento de búsqueda genética (Rao, 2009).

Estos algoritmos difieren de otros métodos de optimización en los siguientes aspectos (Rao, 2009):

- Una población de puntos es utilizada por empezar el procedimiento de un único punto de diseño. Si el número de variables de diseño es  $n$ , usualmente el tamaño de la población se toma como  $2n$  hasta  $4n$ . Debido a que muchos puntos son utilizados como soluciones candidatas, estos algoritmos no suelen caer atrapados en un mínimo local.
- Usa solo los valores de la función objetivo. Las derivadas no se utilizan.
- Las variables de diseño son representadas como cadenas de variables binarias que corresponden a cromosomas de la genética. Por ello, el método de búsqueda es naturalmente aplicable para

resolver problemas de programación entera y discreta; para el caso continuo, la cadena puede variar para llegar a la solución deseada.

- La función objetivo corresponde a un vector de diseño que toma el rol de “aptitud” (“fitness” en inglés) en la genética.
- En cada generación, un nuevo conjunto de cadenas se produce utilizando selección aleatoria de los padres y cruzamiento de las generaciones anteriores (conjuntos de cadenas anteriores). No son técnicas de búsqueda aleatoria, sino que exploran eficientemente las nuevas combinaciones con el conocimiento disponible para hallar una nueva generación con mejor “fitness” o valor de la función objetivo.

Algunas implementaciones de algoritmos genéticos (Guo y col., 2010)

- Algoritmo Genético Híbrido (HGA): Este algoritmo surge de la necesidad de encontrar los valores iniciales adecuados para el algoritmo genético, ya que por lo general estos son seleccionados por la intuición y diferentes valores iniciales derivan en diferentes resultados óptimos. La debilidad del algoritmo genético tradicional reside en su dificultad cuando se establecen restricciones al problema, en especial a los problemas con restricciones exactas. Para ello, el HGA consiste en aplicar un algoritmo genético para proveer un conjunto inicial de variables de diseño y así evitar el proceso de prueba; posteriormente, se aplica un algoritmo de optimización tradicional para hallar el resultado óptimo.
- Algoritmo Genético de Intervalo (Interval Genetic Algorithm - IGA): En ingeniería no es fácil de manufacturar variables de diseño exactas por los errores de medición y también porque es más costoso. En el proceso tradicional de optimización de intervalos, el análisis es presentado como una parte del proceso y su propósito es establecer las cotas superiores e inferiores en el efecto de todos los errores en una cantidad computada. Este análisis sirve para comprender la relación entre los parámetros del sistema y su rendimiento, no obstante, la formulación del intervalo no es fácil de construir. En IGA, los parámetros optimizados se pueden obtener y, además, el análisis de intervalo se puede excluir del proceso de optimización.
- Algoritmo Genético Híbrido de Intervalo (Hybrid Interval Genetic Algorithm - HIGA): En el algoritmo anterior, el error objetivo es calculado de la ecuación formulada. En los sistemas complicados, formular un sistema de ecuaciones que le describa resulta complejo y aun si se puede formular el sistema, es difícil determinar soluciones precisas. Para resolver esto, se combina IGA con software de método de elementos finitos para la optimización de intervalos.

### 5.1.3. Algoritmos Cuasi-Newton

El método de Newton posee muy buenas propiedades: es extremadamente rápido, al menos una vez llega cerca al mínimo y, con algunas modificaciones se convierte en un método descendiente que busca un mínimo en vez de puntos críticos generales (Bryan, 2017).

No obstante, la contra de utilizar este método es el costo computacional en el que debe incurrirse para solucionar sistemas de ecuaciones no lineales mediante el cálculo de derivadas parciales en un punto y luego solucionar el sistema a través de la matriz jacobiana correspondiente. Este algoritmo no reutiliza la información de iteraciones previas y la evaluación de las derivadas parciales puede ser costosa a nivel computacional (Lambers, 2011b).

Para ello, los algoritmos Cuasi-Newton aparecen. Estos algoritmos son iterativos, conllevan una serie de búsquedas lineales y generalmente conllevan cálculo del valor de una función  $f$  y su gradiente en cada iteración (Bryan, 2017). Son algoritmos que se basan en el método de la secante.

### Método de Broyden

El cálculo de la matriz jacobiana requiere  $n^2$  derivadas parciales en la matriz jacobiana aproximada requiere evaluarse  $2n^2$  veces. Por lo que un método eficiente computacionalmente es preferible. Es un método que se basa en el método de la secante (Lambers, 2011a; Mathews, 2005). En una versión general, se aprovecha la propiedad de la matriz jacobiana que se presenta en (5.1) (Mathews, 2005):

$$J(\vec{X})\Delta\vec{X} \approx \Delta\vec{F}(\vec{X}) \quad (5.1)$$

Con ello se puede reescribir la ecuación

$$J(\vec{P}_k)(\vec{P}_k - P_{k-1}^{\vec{}}) = \vec{F}(\vec{P}_k) - \vec{F}(P_{k-1}^{\vec{}}) \quad (5.2)$$

El método parte de la matriz jacobiana  $A_0 = J(\vec{P}_0)$ . Luego en iteraciones sucesivas se utiliza una actualización de la matriz jacobiana aproximada con la matriz  $A_k$

$$A_k(\vec{P}_k - P_{k-1}^{\vec{}}) = \vec{F}(\vec{P}_k) - \vec{F}(P_{k-1}^{\vec{}}), k = 1, 2, \dots \quad (5.3)$$

La expresión anterior se conoce como la condición de la secante o condición cuasi newtoniana. Hay que mencionar que se requieren dos valores o puntos iniciales  $\vec{P}_0$  y  $\vec{P}_1$  para iniciar el método de la secante descrito anteriormente; no obstante si se cuenta con solo un valor inicial y hallar  $\vec{P}_1$  mediante el método de Newton.

### Método de Broyden-Fletcher-Goldfarb-Shanno (BFGS)

Este es uno de los métodos más populares y exitosos cuando se trata de métodos cuasi newtonianos. La usabilidad del algoritmo se basa en su tasa de convergencia y al ser este un método iterativo, depende en gran medida del problema (Auken y col., 2017).

El algoritmo BFGS es descrito así (Nocedal & Wright, 2006):

$x_0$  Punto inicial  
 $\epsilon$ : Tolerancia

```

k ← 0;
while ||∇fk|| > ε
  while pk = -Hk∇fk;
    while xk+1 = xk + αkpk; αk es calculado de un procedimiento de
      búsqueda lineal para satisfacer las condiciones de Wolfe.
      sk = xk+1 - xk;
      yk = ∇fk+1 - ∇fk;
      Hk+1 = (I - pkskykT)Hk(I - pkskykT) + pkskykT; pk =  $\frac{1}{(y_k^T s_k)}$ 
      k ← k+1;
end (while)

```

#### 5.1.4. Medición del Error

La evaluación del éxito de una predicción numérica se puede establecer a través de diversas medidas. Los valores predichos en instancias de prueba son  $p_i, 0 \leq i \leq n$ , mientras que los valores actuales  $a_i, 0 \leq i \leq n$ . Algunas de las medidas son (Witten y col., 2017):

- Mean-Squared Error (Error Cuadrático Medio): Es la medida principal y la más común; algunas veces se utiliza la raíz cuadrada para expresar el error en las mismas dimensiones que los valores predichos. Muchas técnicas utilizan esta medida porque es fácil de manipular matemáticamente no obstante todas las medidas de rendimiento son fáciles de calcular por lo que no ofrece una ventaja particular.

$$\frac{(p_1 - a_1)^2 + \dots + (p_n - a_n)^2}{n} \quad (5.4)$$

- Mean-Absolute Error (Error Absoluto Medio): Es una medida que promedia la magnitud de los errores individuales sin tener en cuenta el signo. El error cuadrático medio tiende a exagerar el efecto de los valores atípicos en el resultado final; en este caso los errores son tratados de acuerdo a su magnitud, por lo que no es tan sensible a los valores atípicos respecto a MSE.

$$\frac{|p_1 - a_1| + \dots + |p_n - a_n|}{n} \quad (5.5)$$

- Relative squared error (Error Cuadrático Relativo): El error es construido relativo a lo que hubiera sucedido si un predictor simple se hubiese aplicado. Lo que hace este predictor es promediar los valores actuales de los datos de entrenamiento denotados por  $\vec{a}$ . Entonces el error cuadrático toma el error cuadrático total y lo normaliza mediante dividiéndolo entre el error cuadrático total del predictor. Se usa la raíz cuando se quiere expresar en las mismas dimensiones que los valores predichos.

$$\frac{(p_1 - \bar{p})^2 + \dots + (p_n - \bar{p})^2}{(a_1 - \bar{a})^2 + \dots + (a_n - \bar{a})^2} \quad (5.6)$$

- Relative Absolute Error (Error Relativo Absoluto): Es similar al anterior y es el error absoluto

total dividido entre el error absoluto total del predictor que predice valores promedio. La fórmula se presenta en (5.7).

$$\frac{|p_1 - \bar{p}| + \dots + |p_n - \bar{p}|}{|a_1 - \bar{a}| + \dots + |a_n - \bar{a}|} \quad (5.7)$$

- Correlation Coefficient (Coeficiente de Correlación): Mide la correlación estadística entre el conjunto de datos entrenamiento respecto a los datos generados por predicción. Si vale 0, no hay correlación entre los datos y si vale 1, hay correlación perfecta entre los datos. Es independiente de la escala de los datos y también difiere de otras medidas de error ya que entre más grande sea el valor de correlación mejor será el rendimiento (a diferencia de las otras, que el rendimiento es mejor cuando los valores son pequeños). La fórmula se presenta en (5.8).

$$\frac{\frac{\sum (p_i - \bar{p})(a_i - \bar{a})}{n-1}}{\sqrt{\frac{\sum (p_i - \bar{p})^2}{n-1} \frac{\sum (a_i - \bar{a})^2}{n-1}}} \quad (5.8)$$

## 5.2. MARCO REFERENCIAL

Se realiza una revisión de la literatura, en bases de datos académicas, donde se encuentran varios artículos académicos acerca de aspectos relevantes para el desarrollo de la propuesta, en primer lugar, sobre implementaciones relacionadas con el tema de estudio como lo son sistemas de monitoreo y/o predicción de variables climatológicas como temperatura y humedad en ambientes controlados o invernaderos, en segundo lugar, un análisis de los sistemas de inferencia tipo ANFIS, donde se buscan relacionar con aspectos medioambientales y como se aplicaron en la gestión o análisis de los mismos, en tercer lugar, métodos, técnicas o herramientas usadas para la predicción de humedad y temperatura climáticas, y por ultimo modelos, técnicas o métodos usados para la predicción de humedad y temperatura en invernaderos. Todos estos aspectos forman una base sólida de conocimiento desde la cual se puede avanzar en la búsqueda de diversas alternativas para abordar el tema de estudio y contrastarlo con la idea inicialmente propuesta.

### 5.2.1. Implementaciones relacionadas

Implementaciones relacionadas incluye una serie de modelos, usados para el monitoreo, predicción y análisis de las variables climáticas en ambientes controlados o invernaderos. La Tabla 5.1 relaciona algunas implementaciones y su descripción, relacionadas con el tema de estudio y que presentan una adecuada actualidad y pertinencia. Dentro de estas se destaca las realizadas por (Yue y col., 2018), el cual predice temperatura y humedad en un invernadero con alta precisión usando un modelo basado en LM-RBF mejorado, modelo que sirve de punto de comparación para la propuesta que se realiza, adicionalmente el modelo propuesto por (Chen y col., 2016), que combina el uso de modelado de temperatura con control difuso, da indicios de éxito a las técnicas que usan sistemas de inferencia difusa para el modelado de temperatura y humedad, y su posterior control.

Tabla 5.1: Implementaciones relacionadas. Elaboración Propia.

AUTOR	DESCRIPCIÓN
(Kang y col., 2018)	Los datos desempeñan un papel importante, incluidos los datos de registro de gestión y los datos medioambientales durante el proceso de producción. Los cuales son utilizados para la predicción de futuras condiciones climáticas en el ambiente controlado.

Tabla 5.1 Implementaciones relacionadas. Elaboración Propia.

AUTOR	DESCRIPCIÓN
(Nugroho y col., 2017)	Modelo aplicado a web que desarrolla un sistema de monitoreo, utilizando sensores instalados en ciertas ubicaciones en el terreno de la plantación, donde los usuarios pueden monitorear el estado del cultivo desde cualquier lugar y en cualquier momento desde un dispositivo que permite el acceso remoto al sistema de información.
(Fourati, 2014)	La información medioambiental monitoreada puede ser usada para predicción de condiciones ambientales y aplicar técnicas de control como la división del proceso en períodos, utilizando un controlador que permita impulsar el clima interno del invernadero a partir de las condiciones monitoreadas.
(NETO y col., 2015)	La aplicación de las redes neuronales artificiales para estudiar comportamientos dinámicos como el clima, en el desarrollo de aplicaciones agrícolas su alta versatilidad facilita el balance hídrico en el manejo de la irrigación.
(Putro y col., 2018)	Se utiliza una red neuronal artificial optimizada por back-propagation, el cual es uno de los algoritmos que se pueden optimizar para que los sistemas agrícolas inteligentes puedan predecir datos mediante el reconocimiento inteligente de patrones de datos agrícolas.
(Yue y col., 2018)	Mejora la precisión de la predicción de la temperatura y la humedad del invernadero, usando un modelo basado en LM-RBF mejorado, utilizando los datos meteorológicos internos y externos del invernadero como entrada, así como la temperatura y humedad en un invernadero como salida.

Tabla 5.1 Implementaciones relacionadas. Elaboración Propia.

AUTOR	DESCRIPCIÓN
(Chen y col., 2016)	Modelo de predicción de la temperatura que combina las ventajas de dos métodos de modelado con control difuso, el cual puede usarse para regular y controlar los invernaderos con ventilación natural además incluye las ventajas del modelo matemático y el modelo de red neuronal de back-propagation.

### 5.2.2. Tipos de ANFIS

Algunas técnicas que son comúnmente utilizadas para abordar aspectos ambientales y modelar aspectos de su comportamiento son los sistemas de inferencia ANFIS, la Tabla 5.2 relaciona diversos tipos de ANFIS que se han usado para predecir diversos fenómenos, resaltando las ventajas, desventajas e implementación de los mismos al momento de abordar el mismo. Dentro de los ANFIS más relevantes para la propuesta realizada, se encuentran los ANFIS- BPLS, propuestos por (Jang, 1993), el cual tiene una alta probabilidad de pronósticos viables para series de tiempo, aunque su procesamiento es lento debido a la gran cantidad de datos, se vislumbra la posibilidad de ser usados para predecir valores de temperatura y humedad en una serie de tiempo, al igual que el ANFIS- PSO, propuesto por (Seydi Ghomsheh y col., 2007), el cual brinda más precisión en la predicción pero es más complejo en su implementación.

Tabla 5.2: Tipos de ANFIS de predicción de fenómenos. Elaboración Propia.

TIPOS DE ANFIS	AUTOR	DESCRIPCIÓN	VENTAJAS	DESVENTAJAS	IMPLEMENTACIÓN
Modelado de retrasos troposféricos	(Suparta & Alhasa, 2016)	Aplicación de la red de modificación ANFIS para el desarrollo de retrasos troposféricos para estimar el valor del retraso del camino cenital (ZPD por sus siglas en inglés) sobre las regiones de la Antártica y Malasia.	Permite seleccionar y comparar las habilidades de entrada de datos de un ZPD. ANFIS es utilizado para no tener la necesidad de usar GPS para obtener los datos de ZPD. Mejora la capacidad y precisión de la toma de datos de los dispositivos.	La suma de dependencia de redes neuronales artificiales produciría un retraso en las predicciones de los datos con cualquier fallo del sistema.	Cálculo de Retrasos troposféricos.

Tabla 5.2 Tipos de ANFIS de predicción de fenómenos. Elaboración Propia.

TIPOS DE ANFIS	AUTOR	DESCRIPCIÓN	VENTAJAS	DESVENTAJAS	IMPLEMENTACIÓN
Problema predictivo de caudales medios mensuales del río Bogotá en Villa pinzón	(Gómez Vargas y col., 2010)	Implementación del Modelo Neuro Difuso ANFIS y de las redes neuronales para la predicción de caudales medios mensuales en la cuenca del río Bogotá en la ciudad de Villa Pinzón utilizando diferentes características presentadas en el río.	Permite la facilidad de razonamiento predictivo por el uso de la lógica difusa. La predicción mejora gracias a la capacidad de aprendizaje y adaptación de las redes neuronales.	ANFIS tiene un comportamiento incierto, por lo tanto se requiere tiempo para entrenar los parámetros de antecedentes y consecuentes del modelo.	Predecir Caudales de la cuenca de un río.

Tabla 5.2 Tipos de ANFIS de predicción de fenómenos. Elaboración Propia.

TIPOS DE ANFIS	AUTOR	DESCRIPCIÓN	VENTAJAS	DESVENTAJAS	IMPLEMENTACIÓN
ANFIS- BPLS	(Jang, 1993)	Agrupación del algoritmo ANFIS y los algoritmos de propagación hacia atrás y menor cuadrado (BP-LS)	Proporcionan criterios de referencia para inversiones. Tiene una alta probabilidad de pronósticos viables para series de tiempo. Permite construir modelos a partir de pares de datos de entrada/salida.	Es bastante lento porque el cómputo complejo de grandes cantidades de datos debe llevarse a cabo en el entrenamiento. Dificulta la interpretación de la separación entre las clases de sus capas de proceso durante el mapeo en el desarrollo de la misma.	Generalmente aplicaciones ANFIS como predicción de series de tiempo.
ANFIS-GA	(Calp, 2018)	Implementación del modelo ANFIS en conjunto al modelo de algoritmos genéticos (GA), para mejorar la efectividad del análisis en los procesos de cada paso de ANFIS.	Reduce considerablemente el tiempo de modelamiento y requerimientos de expertos. Minimiza la pérdida de vida y factores positivos en el ambiente calculado. Es fácilmente usado en la predicción de eventos.	Sobrestima la predicción de la velocidad límite de estimación que nota un error de sobre 19 % en los cálculos del mismo.	Sistema de suspensión vehicular, estimación de la cantidad de lluvia regional.

Tabla 5.2 Tipos de ANFIS de predicción de fenómenos. Elaboración Propia.

TIPOS DE ANFIS	AUTOR	DESCRIPCIÓN	VENTAJAS	DESVENTAJAS	IMPLEMENTACIÓN
ANFIS- PSO	(Seydi Ghomsheh y col., 2007)	Es un híbrido entre ANFIS y Optimización por nubes de partículas (PSO), para optimizar problemas de naturaleza continua.	Incrementa la precisión de la velocidad límite de cálculo en los procesos de lógica difusa en ANFIS. Tiene una mejor precisión en las predicciones comparado con ANFIS-BPLS.	Presenta un alto error relativo en las predicciones en ciertas circunstancias hasta un 18%. Su principal problema se centra en la complejidad de su implementación con una respuesta dinámica pobre.	Predicción del precio de las acciones, clasificación de obesidad en niños y adolescentes.
ANFIS- PSO GA	(Gharabaghi y col., 2019)	Algoritmo utilizado para mejorar el rendimiento del algoritmo ANFIS implementando la optimización por enjambre de partículas a la vez que los algoritmos genéticos.	Presenta una mayor velocidad de convergencia y eficiencia de rastreo de datos. Tiene una alta capacidad de precisión de modelado que los algoritmos anteriores. Optimiza la función de membresía de ANFIS.	No Aplica.	Predecir la velocidad límite en la tubería de alcantarillado para evitar la deposición de sedimentos.

Tabla 5.2 Tipos de ANFIS de predicción de fenómenos. Elaboración Propia.

TIPOS DE ANFIS	AUTOR	DESCRIPCIÓN	VENTAJAS	DESVENTAJAS	IMPLEMENTACIÓN
Problemas de clasificación y modelización	(Martín, 2000)	Intentar combinar las cualidades de las redes neuronales y de la descripción de sistemas mediante Lógica Difusa utilizando la estructura de 5 capas de ANFIS.	Sistema de interferencia difuso sencillo con 2 entradas y 2 reglas. Apropiado para resolver problemas de modelización y control.	Es poco apropiado para la solución de problemas de clasificación. Al manejar una pequeña cantidad de reglas disminuye la precisión del sistema si no se utilizan consecuentes neuronales más sofisticados.	Problemas de clasificación y modelización.

### 5.2.3. Predicción de humedad y temperatura climática

Los modelos de predicción hallados, como se muestra en la Tabla 5.3, permiten identificar la importancia de las variables de humedad y temperatura en la condición climática, así como su relación con otras variables como el CO<sub>2</sub>, cuya interacción es descrita los modelos Manabe y Cox, donde se hace uso de modelos computacionales basados en el procesamiento de la información recolectada en estaciones meteorológicas para definir la concentración de CO<sub>2</sub> en la atmósfera terrestre. Además, se analizan modelos como el CMI y el CSM4, que se centran particularmente en la humedad y temperatura para la descripción del clima y que están basados en un modelo general de circulación atmosférica, se pudo establecer la importancia de estas variables en el ejercicio de predicción propuesto.

Tabla 5.3: Modelos de predicción de humedad y temperatura climática. Elaboración Propia.

MODELOS DE PREDICCIÓN	AUTOR	DESCRIPCIÓN	VENTAJAS	DESVENTAJAS	IMPLEMENTACIÓN
Modelo MANABE	(Manabe y col., 1965)	Se trata de modelos computacionales capaces de simular el comportamiento del clima y proyectar el impacto de los gases de efecto invernadero en la temperatura terrestre.	Son modelos pioneros para proyectar la respuesta del clima de la Tierra a los cambios en las concentraciones del CO2 atmosférico.	Sólo manejan el comportamiento a causa del CO2, haría falta la implementación de la circulación oceánica para los análisis predictivos del clima.	Procesamiento de información en estaciones meteorológicas. Simulación del comportamiento de la atmósfera.
Modelos de circulación general	(Ballabrera, 2010)	Son modelos del tipo matemático que se basan en ecuaciones de Navier-Stokes sobre una esfera rotatoria utilizando términos termodinámicos para las diversas fuentes de energía.	Pueden presentar todas las variables de la información espacial sobre las condiciones climáticas futuras. Pueden mantener la coherencia de la información interna.	La resolución espacial es relativamente baja. Pueden no presentar con precisión los parámetros climáticos.	Pronóstico del tiempo, comprensión del clima y proyección del cambio climático.
Modelos de Stainforth	(Stainforth y col., 2005)	Emplea modelos computacionales que simulan la física de la atmósfera y de los océanos.	Son capaces de prever cambios significativos futuros en el clima con consecuencias económicas.	La naturaleza caótica de cada uno de estos modelos hace que tengan una alta proporción de incertidumbre.	Escenarios de predicción y adaptación al cambio climático.

Tabla 5.3 Modelos de predicción de humedad y temperatura climática. Elaboración Propia.

MODELOS DE PREDICCIÓN	AUTOR	DESCRIPCIÓN	VENTAJAS	DESVENTAJAS	IMPLEMENTACIÓN
Modelos de Cox	(Jensen y col., 1993)	Son modelos que toman en cuenta el efecto invernadero en el planeta, realizando un análisis del CO2 presentado en la atmosfera para deducir el aumento de la temperatura promedio.	Toma en cuenta el acoplamiento de gas en la atmósfera, y su absorción por los ecosistemas terrestres y marinos para deducir emisiones de gas invernadero.	Únicamente analiza la concentración del CO2, existen otros factores de efectos climáticos que no son abordados por estos modelos.	Predicción de la acumulación de gases invernaderos y CO2.
Modelo Dinámico CFS	(Saha y col., 2010)	Representa la interacción global entre el océano, la tierra y la atmósfera, ofreciendo datos por hora con una resolución horizontal de hasta medio grado (hasta 56 Km) alrededor de la Tierra.	Maneja datos verídicos de los centros nacionales para la predicción ambiental y del sistema de asimilación de datos oceánicos globales.	Su principal desventaja es el trabajo con grillas grandes, por las cuales dejarían de tomar en cuenta fenómenos que ocurren a menor escala.	Modelos climáticos globales para análisis de los fenómenos del niño y la niña.

Tabla 5.3 Modelos de predicción de humedad y temperatura climática. Elaboración Propia.

MODELOS DE PREDICCIÓN	AUTOR	DESCRIPCIÓN	VENTAJAS	DESVENTAJAS	IMPLEMENTACIÓN
Modelo CMC1 y 2	(Gobierno de Canadá, 2019)	Son usados para estudiar el cambio climático y su variabilidad y para entender los diferentes procesos en los cuales se maneja el sistema climático.	Se compone esencialmente del modelo de Circulación general atmosférica de segunda generación.	Fue utilizado únicamente para el análisis del clima en las zonas de Norteamérica con un gran porcentaje de error, por lo cual tuvo que ir actualizándose.	Predicción de concentración del CO2 para evaluar la estabilidad del clima.
Modelo GFDL	(Gobierno de Canadá, 2019)	Se compone de modelos de análisis de predicción atmosféricos y oceánicos, para analizar el flujo del viento sobre el océano sur.	Es el que mejor describe el contexto de la nubosidad en el clima.	Usado para la predicción del flujo del viento, provoca falencias en el análisis del cambio climático sobre el centro de las placas terrestres.	Informes de evaluación climática del IPCC.
Modelo Educativo Global Climate Model (EdGCM)	(NASA, 2019)	Es un modelo educativo para aprender sobre la ciencia del clima, participando en los procesos científicos incluida la experimentación y simulaciones por ordenador.	Cualquier estudiante puede utilizar el modelo para realizar simulaciones y análisis del cambio climático.	Por ser de carácter educativo puede presentar errores de análisis a nivel global en tiempo real.	Estudios a nivel estudiantil y universitario.

Tabla 5.3 Modelos de predicción de humedad y temperatura climática. Elaboración Propia.

MODELOS DE PREDICCIÓN	AUTOR	DESCRIPCIÓN	VENTAJAS	DESVENTAJAS	IMPLEMENTACIÓN
Modelo CCSM4	(Gobierno de Canada, 2019)	Es un modelo climático acoplado para simular el sistema climático de la Tierra, este está compuesto por cuatro modelos separados que simulan simultáneamente la atmósfera, el océano, la superficie terrestre y el hielo marino.	Permite a los investigadores realizar investigaciones fundamentales sobre los estados climáticos pasados presentes y futuros de la Tierra.	No Aplica.	Diagnósticos en el modelado de los sistemas climáticos de la Tierra.

#### 5.2.4. Predicción de humedad y temperatura en invernaderos

Se muestra en la Tabla 5.4, un análisis comparativo que relaciona diversos tipos de modelos de predicción de humedad y temperatura en invernaderos a través del tiempo, se describen tanto en su composición como implementación y se muestran los resultados al validar los mismos en un escenario determinado en el caso de estudio. Los modelos hallados permitieron identificar el comportamiento de las variables de humedad y temperatura de acuerdo a un conjunto de sensores y actuadores que hacen parte de la estructura que conforma a un sistema automatizado, en este caso un invernadero, en donde se destacan los modelos tipo ANFIS y el modelo Ahmadi & Glockner, que hacen alusión a los sistemas de ventilación y calefacción empleados con el fin de realizar el control de estos parámetros, en donde se utiliza un diseño de sistemas de calefacción para analizar el efecto de las perturbaciones debido al aire y el calor, y cuyos resultados de validación arrojaron un alto grado de coincidencia entre los valores medidos y estimados de la temperatura.

Tabla 5.4: Modelos de predicción de humedad y temperatura en invernaderos. Elaboración Propia.

MODELOS DE PREDICCIÓN	AUTOR	DESCRIPCIÓN	RESULTADOS DE VALIDACIÓN	IMPLEMENTACIÓN
Modelos ARX	(LOPEZ-CRUZ y col., 2007)	Modelo dinámico lineal de auto-regresión con variables exógenas que se presenta para predecir el comportamiento de la temperatura del aire en el interior de un invernadero.	Los modelos ARX lograron un ajuste mayor a 70% sobre el conjunto de datos de estimación y validación, satisfaciendo así el análisis residual con coeficientes precisos.	Análisis del comportamiento de la temperatura, radiación solar, humedad relativa y velocidad del viento sobre un invernadero.
Modelos ANFIS	(Fernández y col., 2010)	Estudio de modelos neuro-difusos para predecir el comportamiento de la temperatura y la humedad relativa del aire dentro de invernaderos.	El análisis de los resultados mostró que los modelos neuro-difusos predicen aceptablemente el comportamiento del clima dentro del invernadero.	Análisis en invernaderos con ventilación natural para predecir el comportamiento del clima.
Modelo de Ahmadi & Glockner	(Palomo Del Barrio, 1992)	Utiliza un diseño de sistemas de calefacción para analizar el efecto de las perturbaciones debido al aire y el calor.	Alto grado de coincidencia entre los valores medidos y estimados de la temperatura.	En sistemas de calefacción y ventilación de invernaderos.
Modelo de Boisson	(Boisson, 1991)	Modela la temperatura de la cubierta, el aire, el cultivo, la superficie del suelo y las tres capas siguientes dentro del invernadero.	No se comenta la validación del modelo.	Análisis de ventilación natural.

Tabla 5.4 Modelos de predicción de humedad y temperatura en invernaderos. Elaboración Propia.

MODELOS DE PREDICCIÓN	AUTOR	DESCRIPCIÓN	RESULTADOS DE VALIDACIÓN	IMPLEMENTACIÓN
Modelo de Bot	(Palomo Del Barrio, 1992)	Analiza la temperatura en la superficie interior y exterior de la cubierta del invernadero junto al modelamiento de la temperatura y humedad del aire y la radiación en el mismo.	Muestra resultados aceptables de temperaturas de aire.	Análisis de relación entre cultivo y clima de distintas escalas de tiempo. Análisis de distintas estrategias de ahorro de energía.
Modelo de Chaabane	(Chaabane, 1986)	Considera dentro de su análisis varios volúmenes de aire para modular su temperatura y humedad respecto a la temperatura del cultivo, la superficie del suelo y una malla térmica empleada.	No se comenta la validación del modelo.	Estudio de la influencia de una malla térmica sobre el clima nocturno.
Modelo de Cormary	(Rodríguez Díaz, 2005)	Modela la temperatura de la superficie interior y exterior de la cubierta del invernadero, junto a la temperatura y humedad del aire y la temperatura del cultivo y la superficie del suelo.	No presenta actuadores y tiene un vacío de 2°C en la temperatura del aire y 1°C en la del suelo.	Análisis en los aportes y efectos en cada proceso de los sistemas que actúan en un invernadero.
Modelo de DeCristopher	(Rodríguez Díaz, 2005)	Utiliza actuadores de ventilación natural y calefacción para modelar la temperatura del aire, el cultivo y la superficie del suelo.	No se comenta la validación del modelo.	Análisis del efecto de distintos materiales de la cubierta. Diseños de sistemas que actúen sobre el ambiente del invernadero.

Tabla 5.4 Modelos de predicción de humedad y temperatura en invernaderos. Elaboración Propia.

MODELOS DE PREDICCIÓN	AUTOR	DESCRIPCIÓN	RESULTADOS DE VALIDACIÓN	IMPLEMENTACIÓN
Modelo de Halleux	(Rodríguez Díaz, 2005)	Uso de ventilación natural y forzada junto a una malla térmica y Aero-termos para modular la humedad del aire y la temperatura de la cubierta interior y exterior y del cultivo y la superficie del suelo.	Durante un año de experiencias y en casos con/sin cultivo y con/sin calefacción, los errores medios menores de 2°C para temperatura y 5 % para humedad.	Análisis en el material de la cubierta. Análisis en la influencia del cultivo respecto al clima. Análisis de sistemas de calefacción.
Modelo de Kindelan	(Palomo Del Barrio, 1992)	Modela la temperatura general del suelo y del cultivo mediante ventilación natural, humidificadores y calefacción.	No se comenta la validación del modelo.	Análisis de los aportes y efectos de los sistemas que actúan dentro del invernadero.
Modelo de Manera, Picuno & Scarascia	(Rodríguez Díaz, 2005)	Este es un modelo estático que modela la condición de contorno del aire y una capa del suelo junto a las condiciones de temperatura de la cubierta y la superficie del suelo.	En el 45 % de los casos la diferencia entre los reales y estimados es menor que 1°C y en el resto no es mayor que 3°C.	Diseño de nuevas estructuras empleadas en el proceso de invernadero. Dimensionamiento de los sistemas de calefacción.
Modelo de Takakura	(Palomo Del Barrio, 1992)	Modela la temperatura, humedad y concentración del CO <sub>2</sub> en el aire, la superficie del suelo y en una división del suelo en 20 bloques en el plano YZ.	Resultados aceptables de temperatura de superficie de suelo, aire, y radiación sobre cultivo.	Análisis de relación entre cultivo y clima. Diseño de control de invernaderos.

Tabla 5.4 Modelos de predicción de humedad y temperatura en invernaderos. Elaboración Propia.

MODELOS DE PREDICCIÓN	AUTOR	DESCRIPCIÓN	RESULTADOS DE VALIDACIÓN	IMPLEMENTACIÓN
Modelo de Tavares	(Rodríguez Díaz, 2005)	Modela la cubierta, el aire, los cultivos y la superficie del suelo para a analizar sus temperaturas y condición del contorno.	Resultados aceptables.	Identificación de parámetros del clima. Predecir el consumo durante una campaña y situaciones límites como heladas.



## Capítulo 6

# ALCANCES Y LIMITACIONES

### 6.1. ALCANCES

Para el desarrollo del ejercicio de predicción sobre las variables de humedad y temperatura internas de los invernaderos, se proponen 4 técnicas de optimización de conjuntos difusos. Estas técnicas están basadas en el uso de dos tipos de sistemas de inferencia difusa Mamdani y Sugeno, así como también la utilización de dos técnicas de optimización: los algoritmos genéticos y el algoritmo Cuasi-Newton.

Este proyecto comprende la obtención de un prototipo software que, a través de un conjunto de datos de entrada usando valores de humedad y temperatura correspondientes a 48 horas de medición, pueda establecer la predicción de los valores de las 24 horas posteriores al punto de control y poder determinar la dinámica del sistema.

Se busca obtener una serie de modelos respectivos para el comportamiento de cada una de las variables involucradas, es decir, por cada propuesta se tiene un modelo de temperatura y un modelo de humedad, los cuales son analizados para determinar su efectividad mediante técnicas estadísticas como el error cuadrático medio. Estos modelos para la predicción de la humedad y temperatura de los invernaderos deben ser capaces de otorgar un equilibrio entre precisión e interpretabilidad.

### 6.2. LIMITACIONES

Dentro de la determinación del modelo de comportamiento de un invernadero se pueden identificar variables como el nivel de pH del suelo, la radiación UV y el nivel de CO<sub>2</sub>, que hacen parte del microclima que presenta el invernadero. Sin embargo, a través de la investigación realizada se restringe por tomar las variables de humedad y temperatura ambiental, que en este caso son el punto clave para determinar la dinámica del invernadero.

Analizando el aspecto relacionado a los datos que alimentan los modelos propuestos, se determina restringir el intervalo de medición de humedad y temperatura a 72 horas, usando los registros de las primeras 48 horas como datos de entrada y las siguientes 24 horas como datos de validación de la predicción otorgada por cada uno de los modelos. Teniendo en cuenta lo anterior, debido a la facilidad de obtención de información sobre la medición de humedad y temperatura ambiental otorgada por entidades gubernamentales como el IDEAM, se decide recurrir a esta colección de datos para realizar las pruebas del funcionamiento de los modelos y de la precisión que otorgan al contrastar con los pronósticos reales.

La recolección de información proporcionada por un prototipo de invernadero automatizado, que se encargará de reunir los datos de las condiciones de humedad y temperatura internas para su posterior análisis en cada uno de los modelos propuestos estará determinada por la fiabilidad de los datos recolectados, que a su vez depende de la calidad de los sensores y dispositivos usados en el proceso de identificación del comportamiento del invernadero a analizar.

## Capítulo 7

# METODOLOGÍA

La metodología establecida para el desarrollo del proyecto de grado, se muestra en la Fig. 7.1, la cual se divide en tres fases principales, la recolección de datos, el desarrollo de las propuestas y la construcción y despliegue del prototipo de visualización.



Fig. 7.1: Metodología aplicada. Adaptado de (Pressman, 2019).

## 7.1. RECOLECCIÓN DE DATOS

Se establece un conjunto de entradas determinadas por las mediciones de los valores de humedad y temperatura registrados con 48 horas de antelación al día de predicción. En este caso, se utilizaron datos provenientes del Instituto de Hidrología, Meteorología y Estudios Ambientales (IDEAM) correspondientes a las mediciones periódicas de humedad y temperatura de la ciudad de Bogotá, Colombia (IDEAM - Instituto de Hidrología, Meteorología y Estudios Ambientales, 2019) y datos censados por parte de un sensor de humedad y temperatura DHT22 dentro de un prototipo de invernadero elaborado.

## 7.2. DESARROLLO DE LAS PROPUESTAS

Se cuenta con 4 propuestas que se basan en el establecimiento de sistemas de inferencia difusa de tipo Mamdani y Sugeno, que son determinados mediante la relación existente entre las variables y como un acercamiento a la interpretación que se tenía del funcionamiento del sistema. Desde este punto de vista, se abordaron 2 técnicas de optimización para estos conjuntos, usando métodos heurísticos como los algoritmos genéticos y métodos exactos como Cuasi-Newton. El desarrollo de cada una de las propuestas sigue una metodología ágil de modelo de proceso evolutivo basado en prototipos de software (Pressman, 2019), dividido en 5 etapas: comunicación, plan rápido, modelado y diseño rápido, construcción del prototipo y despliegue, entrega y retroalimentación.

Al seguir la metodología basada en prototipos:

- En la fase de comunicación se hace el levantamiento de requerimientos de la solución propuesta por parte de los interesados, en este caso las características de las 4 propuestas que relacionan un tipo de conjunto difuso con una técnica de optimización específica.
- En la etapa de plan rápido se define una hoja de ruta a seguir para implementar el conjunto de requerimientos acordados en un periodo de tiempo corto y acorde al cronograma propuesto.
- Se establece un modelo y diseño rápido del prototipo que dé solución a los requerimientos, en este caso las características de una de las cuatro propuestas, de manera que exista una adecuada implementación y relación entre la creación del conjunto difuso y su optimización con el algoritmo escogido.
- Cuando el diseño sea factible y acorde a las necesidades se pasa a la etapa de construcción del prototipo, posteriormente, se prueba la propuesta con el set de datos y se verifica la predicción de valores de humedad y temperatura. Cabe resaltar que si algún requerimiento no se cumple o es necesario adicionar otra funcionalidad se realiza otro ciclo con las etapas anteriormente mencionadas.

### **7.3. CONSTRUCCIÓN Y DESPLIEGUE PROTOTIPO DE VISUALIZACIÓN**

A partir de las 4 mejores configuraciones de conjuntos difusos obtenidos para humedad y temperatura tanto en el ambiente como en el invernadero, se construye un prototipo de visualización, donde al tener los datos de 48 horas anteriores al momento de predicción se pueda predecir el comportamiento de las variables las siguientes 24 horas, la funcionalidad de este prototipo de visualización se prueba para una variable y escenario específico, y finalmente se muestra la forma de ser desplegado.



## Capítulo 8

# DESARROLLO

Se realiza una descripción de las configuraciones utilizadas para los diversos elementos que se utilizaran para optimizar los conjuntos difusos para predecir la humedad y temperatura. En primer lugar, se detallan las características necesarias por los dos tipos de sistemas de inferencia a usar: Mamdani y Sugeno, tanto para humedad como para temperatura, y, en segundo lugar, se describe la configuración de los métodos de optimización que se aplicaran para estos dos sistemas de inferencia difusa, es decir mediante algoritmo genético y Cuasi-Newton.

### 8.1. SISTEMAS DE INFERENCIA DIFUSA TIPO MAMDANI

Para configurar el sistema de inferencia difusa tipo Mamdani, se requiere usar en MATLAB la función **newfis**, la cual permite crear conjuntos difusos, los parámetros que requiere son descritos en la Tabla 8.1, dónde se especifica el parámetro y su valor para la configuración tipo Mamdani.

Tabla 8.1: Configuración sistema de inferencia difusa tipo Mamdani. Elaboración Propia.

PARÁMETRO	VALOR
Tipo de sistema de inferencia difusa.	Sistema difuso tipo Mamdani.
Método de operador difuso AND.	El mínimo de valores de entrada difusos.
Método de operador difuso OR.	El máximo de valores de entrada difusos.
Método de defuzzificación para calcular valores de salida nítidos.	Centroide del área debajo del conjunto difuso de salida.

Método de implicación para calcular el conjunto difuso consecuente.	Truncar la función de pertenencia consecuente en el valor del resultado antecedente.
Método de agregación para combinar consecuentes de reglas.	Máximo de conjuntos difusos consecuentes.

Se consideran dos entradas con los valores de humedad o temperatura, según sea el caso, la entrada 1 corresponde a los valores del segundo día anterior a la predicción y la entrada 2 a los valores del día anterior a la predicción.

### 8.1.1. Humedad

La entrada 1, para humedad, tomara valores dentro del rango de -1.5 a 4, y se le agregaran tres funciones de pertenencia a la misma, que representaran los valores de humedad “Baja”, “Media” y “Alta”, que permitirán a las personas interpretar los datos de manera sencilla, las funciones serán de tipo triangular.

De igual forma la entrada 2 y la salida del conjunto difuso tomará valores dentro del mismo rango y tendrá tres funciones de pertenencia de la misma naturaleza.

Las reglas que regirán el sistema son:

- Si la humedad de los dos días anteriores es baja, la humedad del día pronosticado será baja.
- Si la humedad de los dos días anteriores varía entre alta y media, respectivamente, la humedad del día pronosticado será media.
- Si la humedad de los dos días anteriores es alta, la humedad del día pronosticado será alta.

### 8.1.2. Temperatura

La entrada 1, para temperatura, tomara valores dentro del rango de -1.5 a 4, y se le agregaran tres funciones de pertenencia a la misma, de tipo triangular, que representaran los valores de temperatura “Baja”, “Media” y “Alta”.

De igual forma la entrada 2 y la salida del conjunto difuso tomará valores dentro del mismo rango y tendrá tres funciones de pertenencia de la misma naturaleza.

Las reglas para la interacción del sistema son:

- Si la temperatura de los dos días anteriores es baja, la temperatura del día pronosticado será baja.
- Si la temperatura de los dos días anteriores es media, la temperatura del día pronosticado será media.
- Si la temperatura de los dos días anteriores varía entre media y alta, respectivamente, la temperatura del día pronosticado será alta.

## 8.2. SISTEMA DE INFERENCIA DIFUSA TIPO SUGENO

La configuración del conjunto difuso del sistema de inferencia de tipo Sugeno, usando la función **newfis**, requiere algunos parámetros para su correcto funcionamiento que son descritos en la Tabla 8.2, dónde se especifica el parámetro y su valor para la configuración tipo Sugeno.

Tabla 8.2: Configuración sistema de inferencia difusa tipo Sugeno.  
Elaboración Propia.

PARÁMETRO	VALOR
Tipo de sistema de inferencia difusa.	Sistema de inferencia tipo Sugeno.
Método de operador difuso AND.	El producto de valores de entrada difusos.
Método de operador difuso OR.	OR probabilístico de valores de entrada difusos.
Método de defuzzificación para calcular valores de salida nítidos.	Promedio ponderado de todas las salidas de reglas.
Método de implicación para calcular el conjunto difuso consecuente.	Escale la función de pertenencia consecuente por el valor del resultado antecedente.
Método de agregación para combinar consecuentes de reglas.	Suma de conjuntos difusos consecuentes.

Se consideran en este caso tres entradas con los valores de humedad o temperatura, según sea el caso, la entrada 1 corresponde a los valores del segundo día anterior a la predicción, la entrada 2 a los del día anterior a la predicción y la entrada 3 al día de predicción, esto debido a la naturaleza misma del sistema de inferencia difusa tipo Sugeno, que contrasta directamente los datos de salida con una de sus entradas.

Adicionalmente los sistemas de inferencia difusa, contienen una característica adicional y es la incorporación de redes neuronales para dar el resultado de su salida.

### 8.2.1. Humedad

La entrada 1, para humedad, tomara valores dentro del rango de -1.5 a 4, y se le agregaran tres funciones de pertenencia a la misma, que representaran los valores de humedad “Baja”, “Media” y “Alta”, las funciones serán de tipo forma z, gaussiana y forma de s, respectivamente, esto con el fin de no dejar ninguno de los limites lateras desprovisto de la aplicación de alguna función de transferencia y en el centro un pico suavizado.

De igual forma la entrada 2 y 3 del conjunto difuso tomará valores dentro del mismo rango y tendrá tres funciones de pertenencia de la misma naturaleza. La salida por ser un sistema de inferencia difuso de tipo Sugeno, tendrá tres funciones de pertinencia que representarán las tres categorías anteriores, dentro de los mismos rangos de funcionamiento, pero serán de tipo constantes.

Las reglas que regirán el sistema son:

- Si la humedad de los tres días anteriores es baja, la humedad del día pronosticado será baja.
- Si la humedad de los dos días anteriores varía entre alta y media, respectivamente, y la humedad del tercer día es media, la humedad del día pronosticado será media.
- Si la humedad de los tres días anteriores es alta, la humedad del día pronosticado será alta.
- Si la humedad de los dos días anteriores es baja y la humedad del tercer día es media, la humedad del día pronosticado será media.
- Si la humedad de los dos días anteriores varía entre alta y media, respectivamente, y la humedad del tercer día es alta, la humedad del día pronosticado será alta.
- Si la humedad de los dos días anteriores es alta y la humedad del tercer día es media, la humedad del día pronosticado será media.

La estructura sistema de inferencia neurodifuso adaptativo o ANFIS se muestra en la Fig. 8.1, donde se evidencia la interacción de las tres entradas y sus tres funciones de pertenencia para obtener el valor de salida.

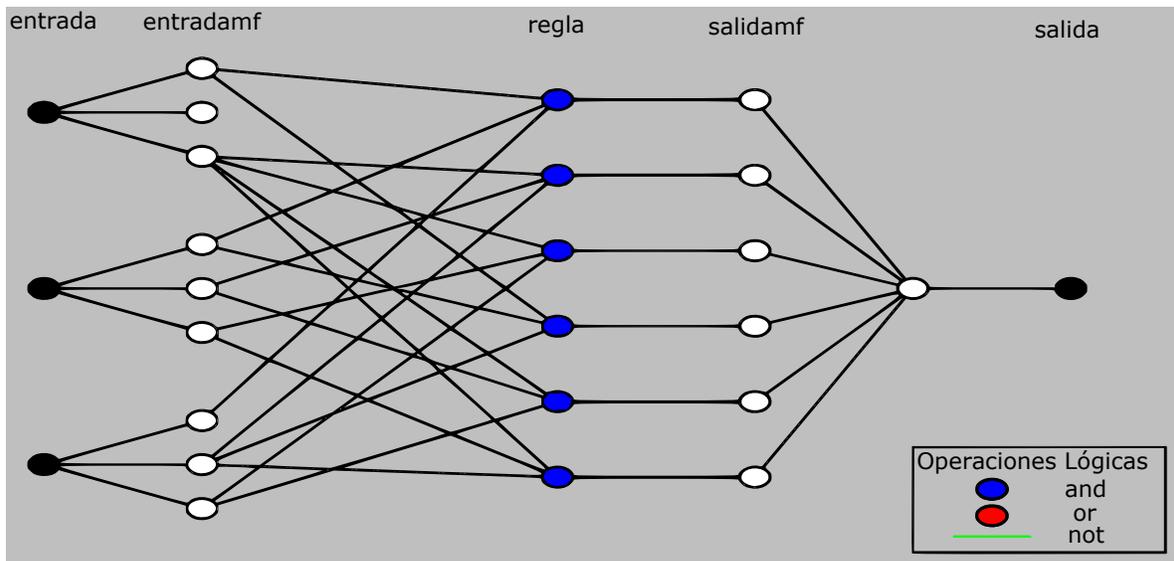


Fig. 8.1: Estructura ANFIS para humedad. Elaboración Propia. (Entorno MATLAB®)

### 8.2.2. Temperatura

La entrada 1, para temperatura, tomara valores dentro del rango de -1.5 a 4, y se le agregaran tres funciones de pertenencia a la misma, que representaran los valores de temperatura “Baja”, “Media” y “Alta”, las funciones serán de tipo forma z, gaussiana y forma de s, respectivamente.

De igual forma la entrada 2 y 3 del conjunto difuso tomará valores dentro del mismo rango y tendrá tres funciones de pertenencia de la misma naturaleza. La salida tomara valores dentro del mismo rango y tendrá tres funciones que representaran los mismos valores de temperatura que las entradas, pero estas serán de tipo constante.

Las reglas para la interacción del sistema son:

- Si la temperatura de los tres días anteriores es baja, la temperatura del día pronosticado será baja.
- Si la temperatura de los tres días anteriores es media, la temperatura del día pronosticado será media.
- Si la temperatura de los dos días anteriores varía entre media y alta, respectivamente, y la temperatura del tercer día es alta, la temperatura del día pronosticado será alta.
- Si la temperatura de los dos días anteriores es baja y la temperatura del tercer día es media, la temperatura del día pronosticado será media.
- Si la temperatura de los dos días anteriores es media y la temperatura del tercer día es alta, la temperatura del día pronosticado será alta.

- Si la temperatura de los dos días anteriores varía entre media y alta, respectivamente, y la temperatura del tercer día es media, la temperatura del día pronosticado será media.

La estructura sistema de inferencia neurodifuso adaptativo o ANFIS se muestra en la Fig. 8.2, donde se evidencia la interacción de las tres entradas y sus tres funciones de pertenencia para obtener el valor de salida.

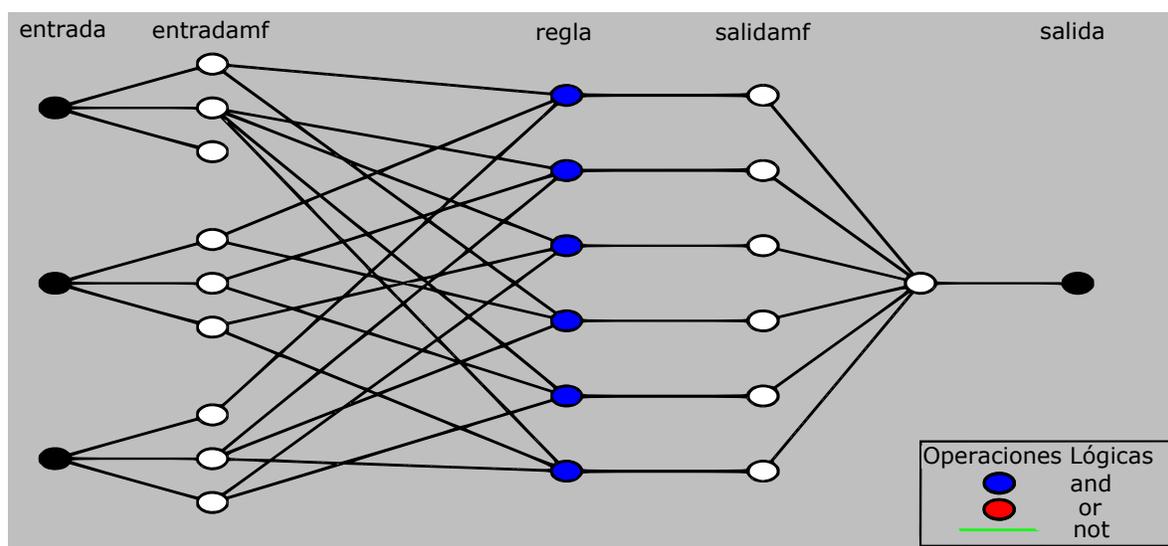


Fig. 8.2: Estructura ANFIS para temperatura. Elaboración Propia. (Entorno MATLAB®)

### 8.3. ALGORITMO GENÉTICO PARA SISTEMA DE INFERENCIA DIFUSA TIPO MAMDANI

Se establece una configuración de algoritmo genético mediante la función **gaoptimset**, como se muestra en la Tabla 8.3, donde se especifica el parámetro y su valor para la configuración del algoritmo genético que mejor se adapta a un sistema de inferencia difusa tipo Mamdani.

Tabla 8.3: Configuración algoritmo genético sistema de inferencia difusa tipo Mamdani. Elaboración Propia.

PARÁMETRO	VALOR
Tamaño de la población	50 individuos
Número máximo de iteraciones antes de que el algoritmo se detenga	200 generaciones
Rango de los individuos en la población inicial	[0.6,2] para temperatura y [0.5,1] para humedad

Individuos de la generación actual que tienen garantizado sobrevivir hasta la próxima generación	2
La fracción de la población en la próxima generación, sin incluir a los que se les garantizo la supervivencia, que crea la función cruce	0.8
Tipo de datos de la población	Debe ser 'doubleVector' para problemas de enteros mixtos.
Tiempo para que el algoritmo se detenga después de ejecutarse	60 segundos

## 8.4. ALGORITMO GENÉTICO PARA SISTEMA DE INFERENCIA DIFUSA TIPO SUGENO

Se establece una configuración de algoritmo genético mediante la función **gaoptimset**, como se muestra en la Tabla 8.4, dónde se especifica el parámetro y su valor para la configuración del algoritmo genético para el sistema de inferencia de tipo Sugeno.

Tabla 8.4: Configuración algoritmo genético sistema de inferencia difusa tipo Sugeno. Elaboración Propia.

PARÁMETRO	VALOR
Tamaño de la población	50 individuos
Número máximo de iteraciones antes de que el algoritmo se detenga	200 generaciones
Rango de los individuos en la población inicial	[0,2] para temperatura y [0.5,1] para humedad
Individuos de la generación actual que tienen garantizado sobrevivir hasta la próxima generación	2
La fracción de la población en la próxima generación, sin incluir a los que se les garantizo la supervivencia, que crea la función cruce	0.8
Tipo de datos de la población	Debe ser 'doubleVector' para problemas de enteros mixtos.
Tiempo para que el algoritmo se detenga después de ejecutarse	60 segundos

## 8.5. CUASI-NEWTON PARA SISTEMA DE INFERENCIA DIFUSA TIPO MAMDANI

Se establece una configuración del algoritmo Cuasi-Newton mediante la función **optimset**, como se muestra en la Tabla 8.5, dónde se especifica el parámetro y su valor para la configuración del algoritmo de optimización, para sistema de inferencia difusa tipo Mamdani.

Tabla 8.5: Configuración Cuasi-Newton sistema de inferencia difusa tipo Mamdani. Elaboración Propia.

PARÁMETRO	VALOR
Número máximo de iteraciones	2000
Número máximo de evaluaciones de funciones	4000

## 8.6. CUASI-NEWTON PARA SISTEMA DE INFERENCIA DIFUSA TIPO SUGENO

Se establece una configuración del algoritmo Cuasi-Newton mediante la función **optimset**, como se muestra en la Tabla 8.6, dónde se especifica el parámetro y su valor para la configuración del algoritmo de optimización, que mejor se ajusta a conjuntos difusos del sistema de inferencia de tipo Sugeno.

Tabla 8.6: Configuración Cuasi-Newton sistema de inferencia difusa tipo Sugeno. Elaboración Propia.

PARÁMETRO	VALOR
Número máximo de iteraciones	2000
Número máximo de evaluaciones de funciones	4000

## Capítulo 9

# RESULTADOS Y DISCUSIÓN

En esta sección se detallan los hallazgos obtenidos al realizar la comparación de los datos obtenidos mediante la predicción con los datos reales de humedad y temperatura, tanto en el ambiente como en el microclima del invernadero. Este proceso se realizó con cada uno de los 4 modelos propuestos: 1) Algoritmo genético para sistema de inferencia difusa tipo Mamdani, 2) Algoritmo genético para sistema de inferencia difusa tipo Sugeno, 3) Cuasi-Newton para sistema de inferencia difusa tipo Mamdani y 4) Cuasi-Newton para sistema de inferencia difusa tipo Sugeno.

### 9.1. PREDICCIÓN DE HUMEDAD Y TEMPERATURA EN EL AMBIENTE

En este apartado se describe el análisis realizado frente a la predicción obtenida para humedad y temperatura en el ambiente con base en los 4 modelos propuestos, mostrando las herramientas estadísticas usadas y presentando los recursos gráficos que permiten evaluar el desempeño de cada modelo.

#### 9.1.1. ALGORITMO GENÉTICO PARA SISTEMA DE INFERENCIA DIFUSA TIPO MAMDANI

Para la aplicación del algoritmo se propone el uso de conjuntos difusos para un sistema de inferencia de tipo Mamdani, considerando dos entradas subdivididas en conjuntos de tipo triangular (trimf) y una salida del mismo tipo, para cada una de las variables.

Se realizan 30 ejecuciones del algoritmo genético obteniendo los errores mínimo, máximo y MSE de cada ejecución. Se calcula un valor promedio para los MSE de humedad de  $9,09 \text{ E-}04$  y de temperatura de  $5,39 \text{ E-}03$ , presentando una desviación estándar para humedad de  $2,80 \text{ E-}04$  y para temperatura de

1,95 E-03. En la Tabla 9.1 E1, E2, ..., E30, hacen referencia a las ejecuciones aleatorias.

Tabla 9.1: Ejecuciones Algoritmo Genético para Sistema de Inferencia Difusa Tipo Mamdani (C1) en el Ambiente. Elaboración propia.

	HUMEDAD			TEMPERATURA		
	MÍNIMO	MÁXIMO	MSE	MÍNIMO	MÁXIMO	MSE
<b>E1</b>	1,41 E-03	5,79 E-02	1,08 E-03	3,39 E-03	1,36 E-01	4,97 E-03
<b>E2</b>	1,38 E-03	6,46 E-02	7,35 E-04	1,65 E-03	2,01 E-01	6,02 E-03
<b>E3</b>	2,53 E-05	1,01 E-01	1,19 E-03	0,00 E+00	1,74 E-01	5,60 E-03
<b>E4</b>	4,42 E-03	6,08 E-02	1,49 E-03	1,45 E-03	1,62 E-01	7,85 E-03
<b>E5</b>	3,25 E-03	6,17 E-02	1,15 E-03	1,32 E-02	1,54 E-01	9,68 E-03
<b>E6</b>	5,00 E-03	5,79 E-02	9,92 E-04	1,83 E-02	1,93 E-01	5,65 E-03
<b>E7</b>	2,58 E-04	4,55 E-02	6,19 E-04	2,01 E-03	1,40 E-01	5,65 E-03
<b>E8</b>	3,20 E-03	4,90 E-02	9,81 E-04	0,00 E+00	1,54 E-01	5,28 E-03
<b>E9</b>	5,24 E-03	7,00 E-02	1,45 E-03	5,42 E-04	2,22 E-01	1,10 E-02
<b>E10</b>	1,29 E-03	1,00 E-01	1,38 E-03	0,00 E+00	2,25 E-01	5,91 E-03
<b>E11</b>	1,78 E-03	5,93 E-02	7,17 E-04	6,59 E-04	1,36 E-01	3,98 E-03
<b>E12</b>	1,64 E-03	5,31 E-02	6,03 E-04	5,13 E-03	1,20 E-01	3,12 E-03
<b>E13</b>	2,93 E-03	4,35 E-02	4,97 E-04	1,22 E-03	1,68 E-01	5,85 E-03
<b>E14</b>	6,62 E-04	9,71 E-02	1,04 E-03	7,38 E-04	1,61 E-01	4,00 E-03
<b>E15</b>	6,54 E-05	8,00 E-02	9,56 E-04	3,96 E-04	1,50 E-01	3,02 E-03
<b>E16</b>	2,48 E-04	7,86 E-02	1,26 E-03	2,44 E-03	1,17 E-01	3,69 E-03
<b>E17</b>	1,40 E-03	8,01 E-02	9,86 E-04	9,35 E-04	1,20 E-01	3,78 E-03
<b>E18</b>	4,32 E-04	6,45 E-02	1,08 E-03	1,11 E-02	1,35 E-01	5,90 E-03
<b>E19</b>	9,06 E-04	5,03 E-02	4,24 E-04	1,02 E-03	1,32 E-01	4,72 E-03
<b>E20</b>	8,27 E-04	6,11 E-02	8,80 E-04	0,00 E+00	1,65 E-01	6,10 E-03
<b>E21</b>	7,37 E-04	9,59 E-02	1,02 E-03	4,62 E-03	1,40 E-01	4,83 E-03
<b>E22</b>	1,30 E-03	4,70 E-02	5,92 E-04	5,65 E-04	1,73 E-01	4,70 E-03
<b>E23</b>	6,09 E-03	8,29 E-02	1,02 E-03	7,26 E-03	1,82 E-01	8,05 E-03
<b>E24</b>	1,94 E-04	7,38 E-02	6,69 E-04	7,44 E-03	1,97 E-01	4,19 E-03
<b>E25</b>	6,89 E-03	6,91 E-02	6,30 E-04	0,00 E+00	1,80 E-01	3,65 E-03
<b>E26</b>	1,90 E-03	9,42 E-02	8,92 E-04	2,96 E-03	1,56 E-01	2,84 E-03
<b>E27</b>	1,05 E-03	7,25 E-02	6,24 E-04	5,70 E-03	1,49 E-01	7,73 E-03
<b>E28</b>	1,06 E-03	6,26 E-02	6,91 E-04	8,17 E-03	1,13 E-01	4,44 E-03
<b>E29</b>	7,43 E-03	5,20 E-02	7,70 E-04	4,01 E-03	1,19 E-01	3,13 E-03
<b>E30</b>	1,83 E-04	7,64 E-02	8,64 E-04	1,42 E-03	1,29 E-01	6,40 E-03
$\bar{x}$	2,11 E-03	6,87 E-02	9,09 E-04	3,54 E-03	1,57 E-01	5,39 E-03
	<b>DESVIACIÓN ESTANDAR</b>		2,80 E-04	<b>DESVIACIÓN ESTANDAR</b>		1,95 E-03

## Humedad

Los datos de humedad obtenidos a partir de la predicción vs la medición real se muestran en la Fig. 9.1 donde, de manera gráfica, se evidencia la ejecución E19 la cual, de acuerdo a los datos de la Tabla 9.1, presenta el mejor desempeño. En el eje de abscisas se relaciona el periodo de tiempo analizado, que en este caso fue de 24 horas, correspondientes a la predicción del tercer día, y en el eje de ordenadas se encuentran los valores de humedad medidos en porcentaje (%).

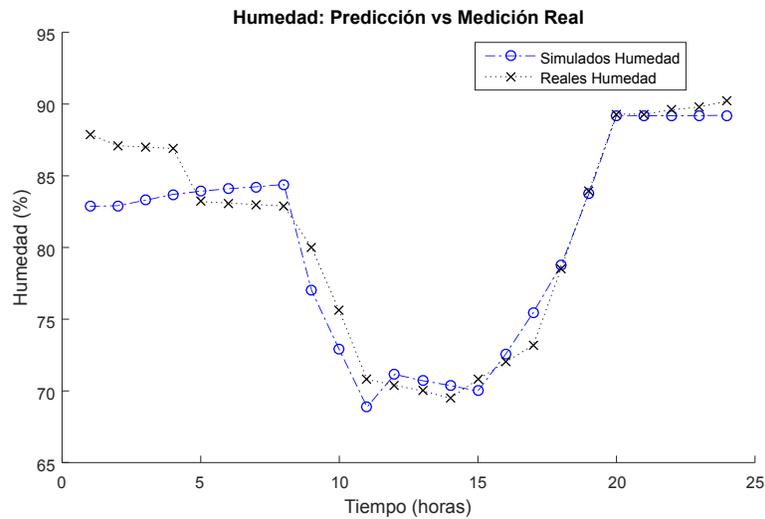


Fig. 9.1: Comparación Humedad en el Ambiente (C1). Elaboración propia (Entorno MATLAB®).

Se consigue un MSE o error cuadrático medio de  $4,24 \text{ E-}04$  en la ejecución E19 como se muestra en la Fig. 9.2 donde se muestra la relación del error a través del tiempo de los datos de humedad de la predicción con los datos reales. Además, se pueden visualizar los instantes de tiempo en donde se presenta mayor diferencia entre los dos grupos de datos.

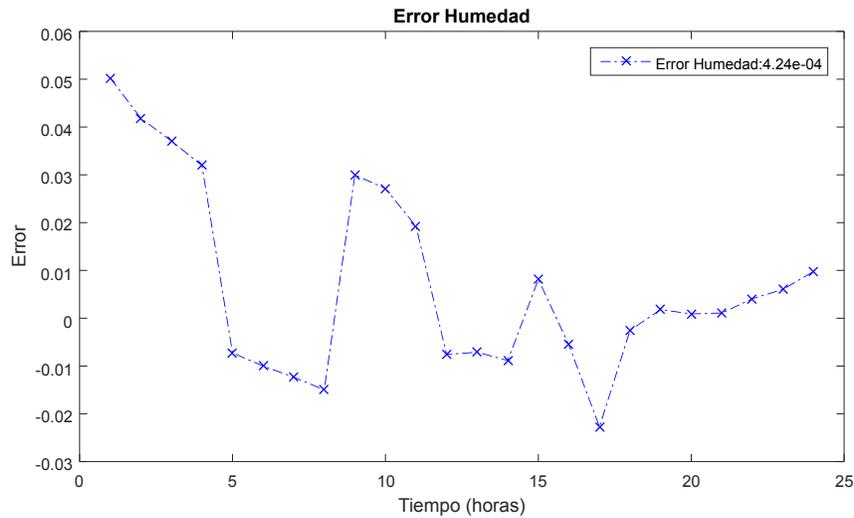


Fig. 9.2: Error Humedad en el Ambiente (C1). Elaboración propia (Entorno MATLAB®).

### Temperatura

En la Fig. 9.3 se pueden evidenciar los resultados de la ejecución E26, que de acuerdo a la Tabla 9.1 es la que presenta el mejor desempeño. En la gráfica se muestran los datos de temperatura obtenidos por la predicción vs la medición real. En el eje de abscisas se relaciona el periodo de tiempo analizado, medido en horas, y en el eje de ordenadas se encuentran los valores de temperatura, medidos en grados centígrados ( $^{\circ}\text{C}$ ).

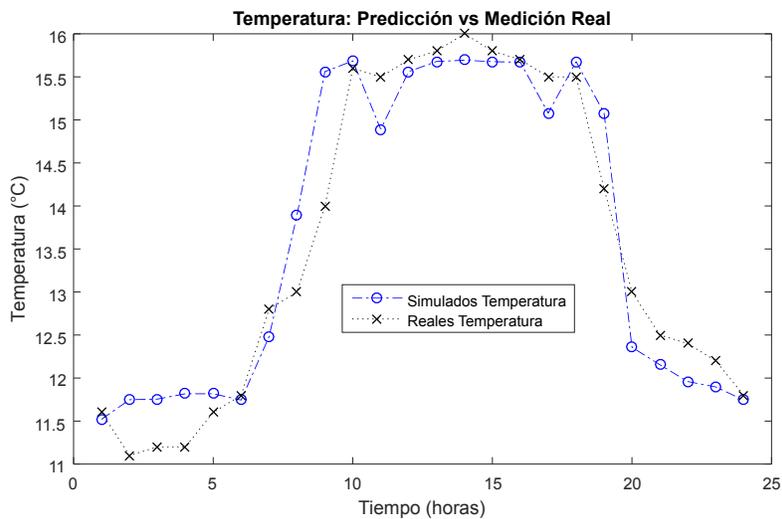


Fig. 9.3: Comparación Temperatura en el Ambiente (C1). Elaboración propia (Entorno MATLAB®).

La Fig. 9.4 muestra la relación del error a través del tiempo entre los datos de temperatura obtenidos de la predicción y los datos reales. En esta gráfica se pueden ver los instantes de tiempo donde ocurre la mayor variación. El MSE o error cuadrático medio corresponde a  $2,84 \text{ E-}03$  en la ejecución E26.

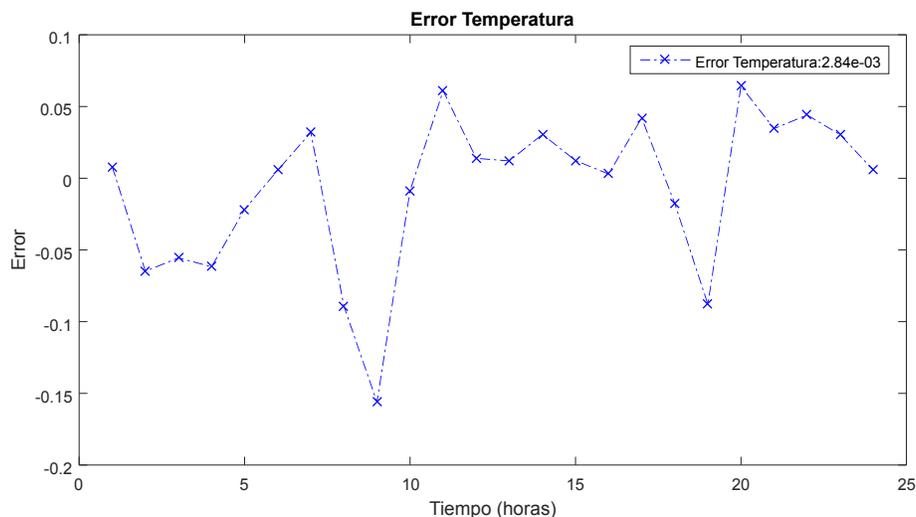


Fig. 9.4: Error Temperatura en el Ambiente (C1). Elaboración propia (Entorno MATLAB®).

### 9.1.2. ALGORITMO GENÉTICO PARA SISTEMA DE INFERENCIA DIFUSA TIPO SUGENO

La aplicación del algoritmo genético se realiza sobre conjuntos difusos para un sistema de inferencia tipo Sugeno, en el cual existen 2 entradas, subdivididas en conjuntos de tipo sigmoial (smf), gaussiano (gaussmf) y z-shaped (zmf); así como una salida de tipo constante, para cada una de las variables.

Se obtienen los errores: mínimo, máximo y MSE luego de realizar 30 ejecuciones del algoritmo genético. Se calcula un valor promedio de los MSE para humedad de  $1,15 \text{ E-}03$  y para temperatura de  $8,12 \text{ E-}03$ , presentando una desviación estándar para humedad de  $3,51 \text{ E-}04$  y para temperatura de  $1,92 \text{ E-}03$ . En la Tabla 9.2 E1, E2, ..., E30, hacen referencia a cada una de las ejecuciones del algoritmo.

Tabla 9.2: Ejecuciones Algoritmo Genético para Sistema de Inferencia tipo Sugeno (C2) en el Ambiente. Elaboración propia.

	HUMEDAD			TEMPERATURA		
	MÍNIMO	MÁXIMO	MSE	MÍNIMO	MÁXIMO	MSE
<b>E1</b>	8,51 E-04	8,24 E-02	1,40 E-03	2,60 E-03	2,01 E-01	7,42 E-03
<b>E2</b>	1,44 E-03	9,66 E-02	1,08 E-03	1,10 E-03	2,52 E-01	9,72 E-03
<b>E3</b>	1,64 E-04	6,78 E-02	8,41 E-04	1,78 E-03	2,25 E-01	8,05 E-03
<b>E4</b>	5,68 E-04	1,10 E-01	2,15 E-03	1,13 E-03	2,24 E-01	8,85 E-03

<b>E5</b>	9,52 E-04	9,62 E-02	1,59 E-03	7,42 E-04	2,31 E-01	1,02 E-02
<b>E6</b>	2,19 E-04	8,68 E-02	1,12 E-03	1,16 E-03	2,17 E-01	8,57 E-03
<b>E7</b>	3,82 E-05	6,52 E-02	7,67 E-04	1,69 E-03	2,06 E-01	7,39 E-03
<b>E8</b>	1,10 E-03	7,66 E-02	1,27 E-03	7,56 E-06	2,52 E-01	6,33 E-03
<b>E9</b>	2,27 E-06	9,06 E-02	1,37 E-03	1,27 E-03	2,14 E-01	5,70 E-03
<b>E10</b>	2,63 E-03	7,29 E-02	9,91 E-04	3,58 E-04	2,55 E-01	6,57 E-03
<b>E11</b>	4,54 E-04	7,54 E-02	1,02 E-03	2,50 E-03	2,00 E-01	8,26 E-03
<b>E12</b>	9,63 E-04	7,59 E-02	7,80 E-04	2,03 E-03	1,93 E-01	8,38 E-03
<b>E13</b>	8,38 E-05	7,82 E-02	8,13 E-04	2,77 E-03	2,42 E-01	5,74 E-03
<b>E14</b>	7,34 E-04	8,59 E-02	1,19 E-03	2,21 E-04	2,66 E-01	7,67 E-03
<b>E15</b>	2,76 E-04	8,86 E-02	1,37 E-03	2,29 E-04	2,42 E-01	6,30 E-03
<b>E16</b>	5,59 E-05	7,69 E-02	9,95 E-04	2,57 E-03	2,66 E-01	1,11 E-02
<b>E17</b>	8,63 E-04	6,10 E-02	5,91 E-04	2,88 E-03	2,47 E-01	7,73 E-03
<b>E18</b>	3,96 E-04	7,10 E-02	9,79 E-04	1,14 E-03	2,10 E-01	9,94 E-03
<b>E19</b>	8,51 E-04	7,16 E-02	1,03 E-03	1,01 E-03	2,51 E-01	9,86 E-03
<b>E20</b>	6,31 E-04	6,23 E-02	9,42 E-04	9,32 E-04	2,43 E-01	6,76 E-03
<b>E21</b>	1,34 E-04	8,32 E-02	9,60 E-04	9,19 E-04	2,24 E-01	6,80 E-03
<b>E22</b>	1,27 E-04	6,44 E-02	6,74 E-04	2,01 E-03	2,15 E-01	6,08 E-03
<b>E23</b>	1,16 E-03	1,10 E-01	1,99 E-03	5,43 E-04	2,17 E-01	6,20 E-03
<b>E24</b>	8,35 E-04	9,88 E-02	1,41 E-03	1,99 E-03	2,08 E-01	7,29 E-03
<b>E25</b>	1,17 E-04	8,25 E-02	9,43 E-04	6,52 E-03	2,47 E-01	8,79 E-03
<b>E26</b>	1,44 E-03	8,78 E-02	1,20 E-03	3,64 E-03	2,25 E-01	1,11 E-02
<b>E27</b>	9,27 E-05	8,59 E-02	1,39 E-03	2,66 E-03	2,45 E-01	1,08 E-02
<b>E28</b>	7,11 E-05	7,10 E-02	1,27 E-03	3,53 E-03	2,30 E-01	1,33 E-02
<b>E29</b>	5,32 E-04	8,98 E-02	1,41 E-03	1,72 E-03	2,32 E-01	6,16 E-03
<b>E30</b>	3,90 E-04	6,88 E-02	1,02 E-03	7,28 E-05	2,43 E-01	6,50 E-03
$\bar{x}$	<b>6,06 E-04</b>	<b>8,11 E-02</b>	<b>1,15 E-03</b>	<b>1,72 E-03</b>	<b>2,31 E-01</b>	<b>8,12 E-03</b>
	<b>DESVIACIÓN ESTÁNDAR</b>		<b>3,51 E-04</b>	<b>DESVIACIÓN ESTÁNDAR</b>		<b>1,92 E-03</b>

### Humedad

A partir de la ejecución E17, que según la Tabla 9.2 es la que presenta el mejor desempeño, se construye una gráfica que relaciona los datos de humedad obtenidos por la predicción vs la medición real y que se muestran en la Fig. 9.5. En el eje de abscisas se relaciona el periodo de tiempo analizado, que corresponde a las 24 horas del tercer día, y en el eje de ordenadas se encuentran los valores de humedad, medidos en porcentaje (%).

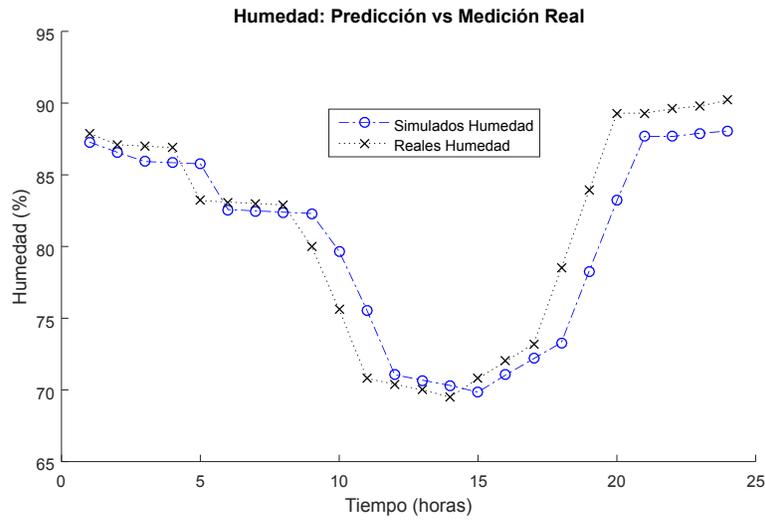


Fig. 9.5: Comparación Humedad en el Ambiente (C2). Elaboración propia (Entorno MATLAB®).

Se consigue un MSE o error cuadrático medio de  $5,91 \text{ E-}04$  en la ejecución E17, como se muestra en la Fig. 9.6, donde se puede ver la variación a través del tiempo entre los grupos de datos a analizar, en este caso, los valores de predicción vs la medición real.

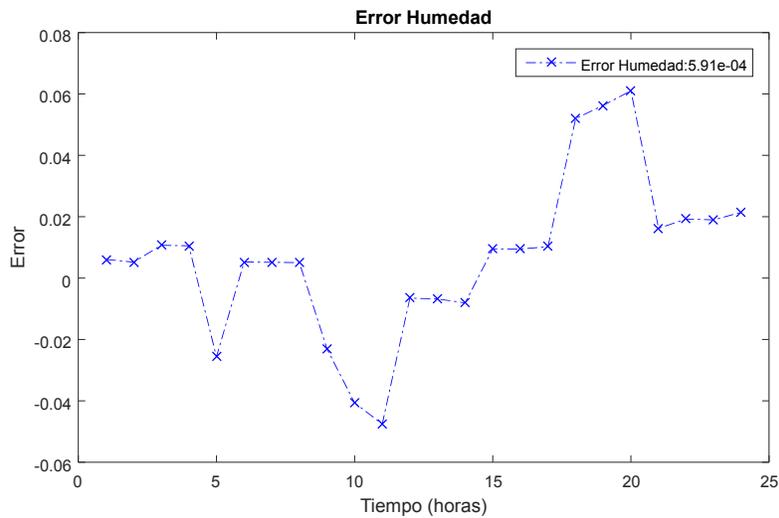


Fig. 9.6: Error Humedad en el Ambiente (C2). Elaboración propia (Entorno MATLAB®).

## Temperatura

Los datos de temperatura obtenidos por la predicción vs la medición real se muestran en la Fig. 9.7, que representa el mejor desempeño del algoritmo obtenido en la ejecución E9, como se puede evidenciar

en la Tabla 9.2. En el eje de abscisas se relaciona el periodo de tiempo analizado, medido en horas, y en el eje de ordenadas se encuentran los valores de temperatura, cuya unidad de medida corresponde a grados centígrados ( $^{\circ}\text{C}$ ).

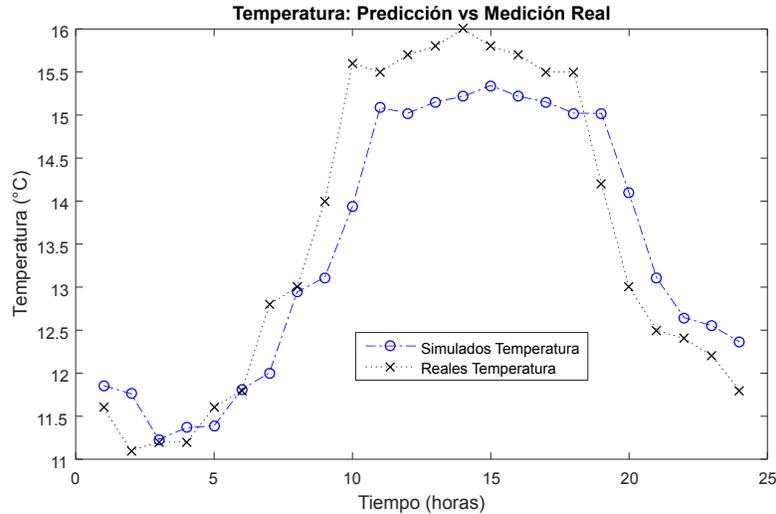


Fig. 9.7: Comparación Temperatura en el Ambiente (C2). Elaboración propia (Entorno MATLAB®).

La Fig. 9.8 muestra la variación a través del tiempo entre los grupos de datos a considerar, en este caso los datos predicción vs la medición real. Se consigue un MSE o error cuadrático medio de  $5,70 \text{ E-}03$  en la ejecución E9.

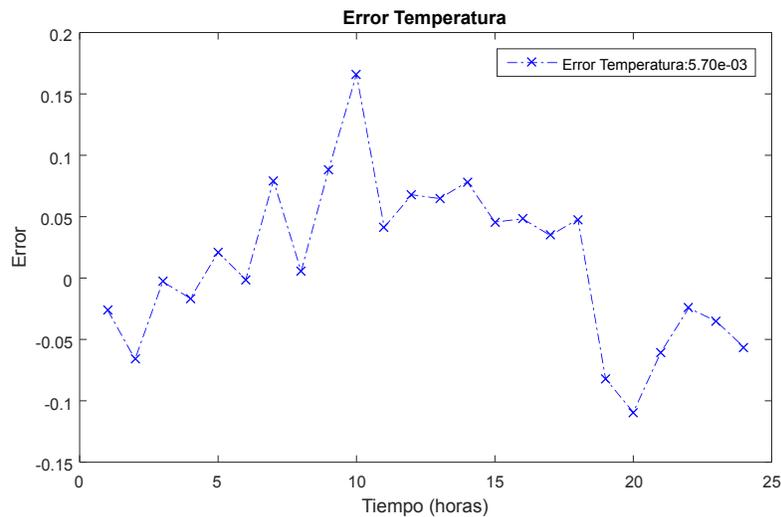


Fig. 9.8: Error Temperatura en el Ambiente (C2). Elaboración propia (Entorno MATLAB®).

### 9.1.3. CUASI-NEWTON PARA SISTEMA DE INFERENCIA DIFUSA TIPO MAMDANI

Se establece una configuración inicial de algoritmo Cuasi-Newton correspondiente a la retroalimentación obtenida por el mejor sistema de inferencia difusa tipo Mamdani, el cual fue generado mediante el algoritmo genético descrito en la Sección 9.1.1.

La función fitness para humedad y temperatura es el valor esperado de las variables menos el valor obtenido, considerando los datos normalizados. Los errores: mínimo, máximo y MSE, obtenidos por el algoritmo Cuasi-Newton para el sistema de inferencia difusa tipo Mamdani, se muestran en la Tabla 9.3.

Tabla 9.3: Cuasi-Newton para Sistema de Inferencia Difusa Tipo Mamdani (C3) en el Ambiente. Elaboración propia.

ERROR	HUMEDAD	TEMPERATURA
Mínimo	4,58E-04	1,07E-03
Máximo	2,20E-02	1,13E-01
MSE	1,21E-04	2,03E-03

## Humedad

El desempeño obtenido para humedad muestra en la Fig. 9.9, que relaciona la predicción de humedad vs la medición real. En el eje de abscisas se encuentra el periodo de tiempo analizado, correspondiente a 24 horas del tercer día, y en el eje de ordenadas se encuentran los valores de humedad medidos en porcentaje (%).

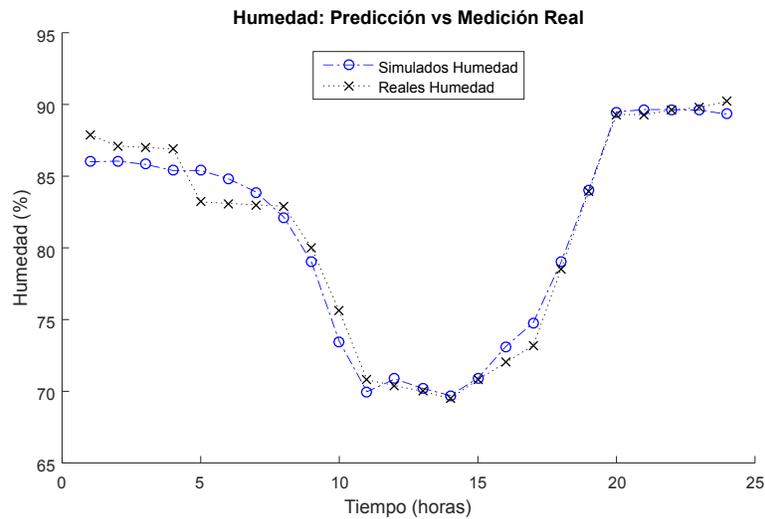


Fig. 9.9: Comparación Humedad en el Ambiente (C3). Elaboración propia (Entorno MATLAB®).

Se consigue un MSE o error cuadrático medio de  $1,21E-04$  para humedad como se muestra en la Fig. 9.10, donde de manera gráfica se muestra la relación del error a través del tiempo de los datos de predicción vs la medición real.

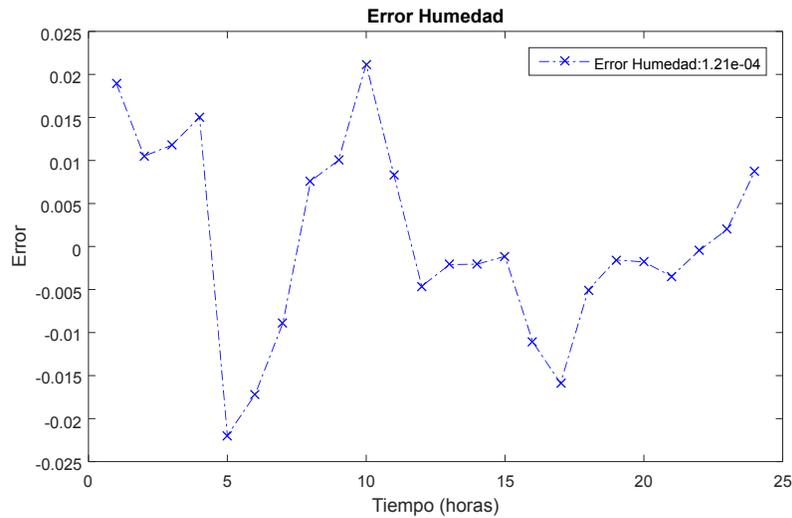


Fig. 9.10: Error Humedad en el Ambiente (C3). Elaboración propia (Entorno MATLAB®).

## Temperatura

La Fig. 9.11 muestra, de manera gráfica, la predicción de temperatura vs la medición real del tercer día. En el eje de abscisas se encuentra el periodo de tiempo analizado, medido en horas, y en el eje de ordenadas se encuentran los valores de temperatura, medidos en grados centígrados ( $^{\circ}\text{C}$ ).

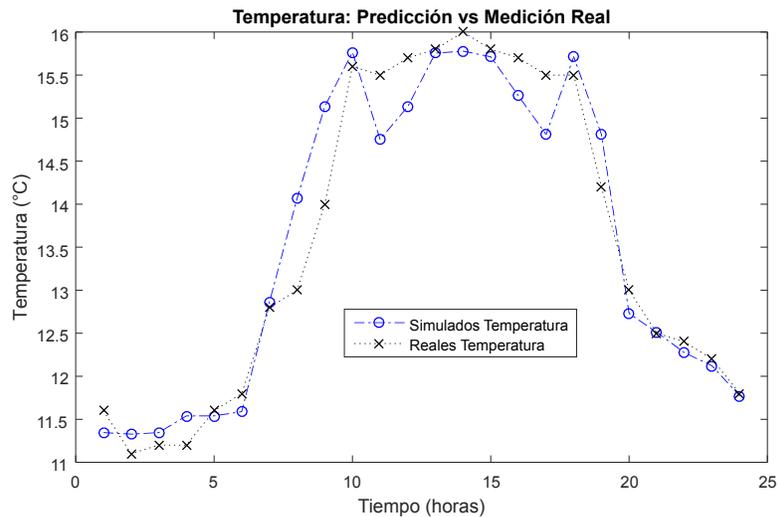


Fig. 9.11: Comparación Temperatura en el Ambiente (C3). Elaboración propia (Entorno MATLAB®).

La relación del error en el tiempo se puede observar a través de la Fig. 20, en la cual es posible distinguir los instantes en que se presenta mayor variación entre la predicción y la medición real. Se

consigue un MSE o error cuadrático medio de  $2,03E-03$ .

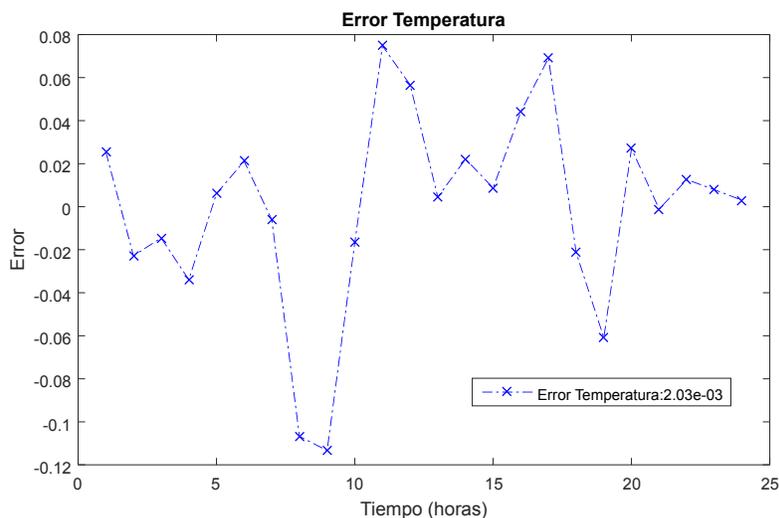


Fig. 9.12: Error Temperatura en el Ambiente (C3). Elaboración propia (Entorno MATLAB®).

#### 9.1.4. CUASI-NEWTON PARA SISTEMA DE INFERENCIA DIFUSA TIPO SUGENO

Se toma como base el mejor conjunto difuso para el sistema de inferencia de tipo Sugeno, generado mediante el algoritmo genético descrito en la Sección 9.1.2 Este se usa como configuración inicial del algoritmo Cuasi-Newton.

Se construye una función fitness para humedad y temperatura, considerando los datos normalizados, y que corresponde al valor esperado de las variables menos el valor obtenido. A partir del algoritmo se obtienen los errores: mínimo, máximo y MSE que se muestran en la Tabla 9.4.

Tabla 9.4: Cuasi-Newton para Sistema de Inferencia Difusa Tipo Sugeno (C4) en el Ambiente. Elaboración propia.

<b>ERROR</b>	<b>HUMEDAD</b>	<b>TEMPERATURA</b>
Mínimo	4,70E-04	1,19E-03
Máximo	5,48E-02	2,24E-01
MSE	5,44E-04	4,95E-03

## Humedad

La Fig. 9.13 permite evidenciar el desempeño de la predicción de humedad vs la medición real. En el eje de abscisas se relaciona el periodo de tiempo analizado, el cual corresponde a las 24 horas del tercer día, y en el eje de ordenadas se encuentran los datos de humedad, medidos en porcentaje (%).

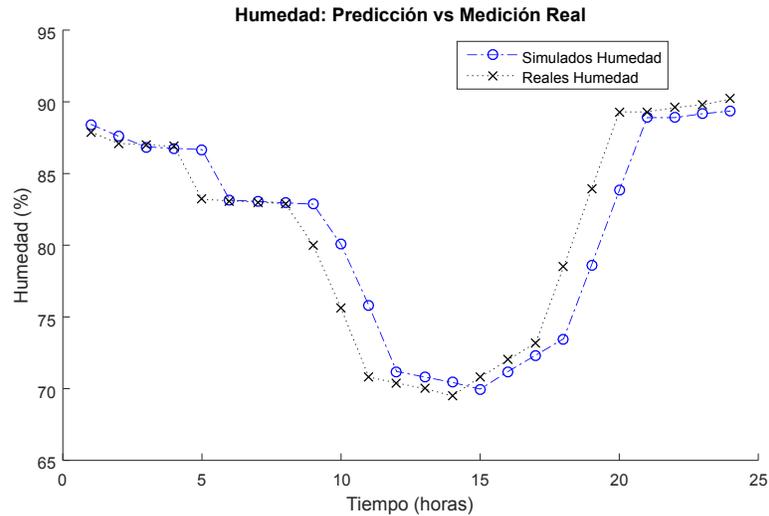


Fig. 9.13: Comparación Humedad en el Ambiente (C4). Elaboración propia (Entorno MATLAB®).

Se consigue un MSE o error cuadrático medio de  $5,44E-04$  para humedad como se muestra en la Fig. 9.14, donde de manera gráfica se muestra la relación del error a través del tiempo entre los datos de humedad obtenidos por la predicción y los datos reales, además que permite visualizar los instantes de tiempo donde se presenta mayor diferencia entre los dos grupos de datos.

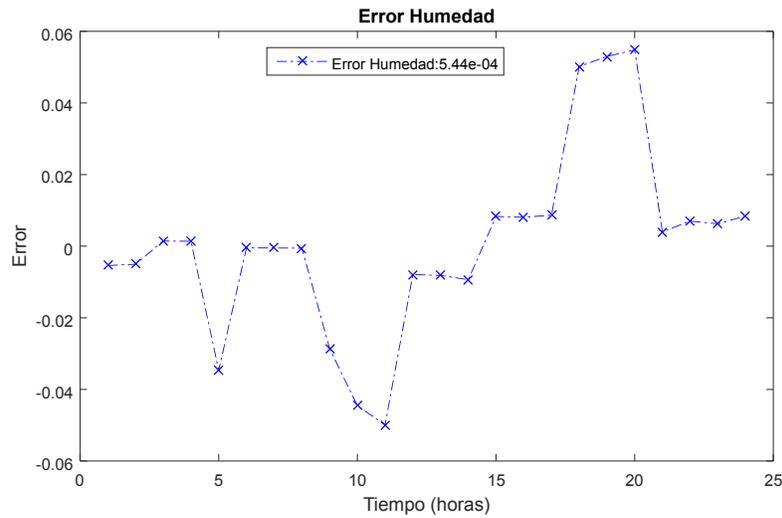


Fig. 9.14: Error Humedad en el Ambiente (C4). Elaboración propia (Entorno MATLAB®).

## Temperatura

El desempeño de la predicción de temperatura vs la medición real se puede observar en la Fig. 9.15 En el eje de abscisas se relaciona el periodo de tiempo analizado, medido en horas, y en el eje de ordenadas se encuentran los datos de humedad, medidos en grados centígrados ( $^{\circ}\text{C}$ ).

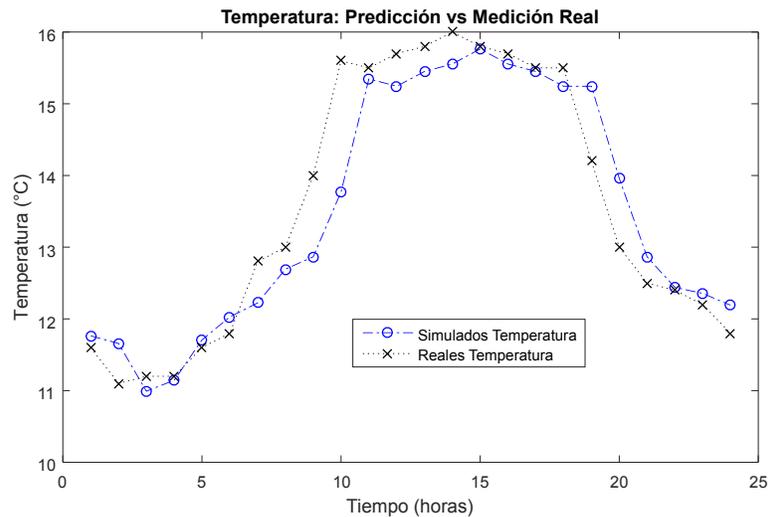


Fig. 9.15: Comparación Temperatura en el Ambiente (C4). Elaboración propia (Entorno MATLAB®).

La Fig. 9.16 muestra la relación del error a través del tiempo entre los datos de temperatura de la predicción y los reales. Se consigue un MSE o error cuadrático medio de  $4,95\text{E}-03$  para temperatura.

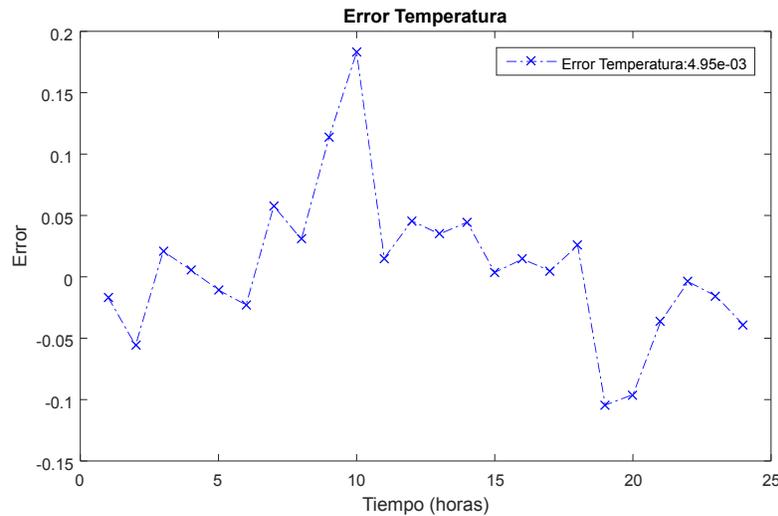


Fig. 9.16: Error Temperatura en el Ambiente (C4). Elaboración propia (Entorno MATLAB®).

### 9.1.5. ANÁLISIS DE PREDICCIÓN HUMEDAD Y TEMPERATURA EN EL AMBIENTE

Se presenta la comparación de los resultados generales obtenidos en los 4 modelos propuestos y se determina a partir del MSE y el porcentaje de efectividad el modelo que mejor se adapta para la predicción de la humedad y temperatura en el ambiente. Posteriormente, se procede a mostrar la configuración del sistema de inferencia obtenido, presentando las gráficas alusivas a los conjuntos, las reglas que controlan la relación entre las entradas y salidas del sistema, así como la superficie que se genera a partir de dichas reglas.

Finalmente, se realiza una prueba de Kruskal-Wallis para determinar la varianza de los datos obtenidos por la predicción en contraste con los reales, que en este caso corresponden a una distribución que no cumple con los criterios de normalidad.

#### Resultados generales

Se realiza una comparación de los resultados obtenidos en las cuatro configuraciones, como se evidencia en la Tabla 9.5, donde se observa que la configuración que presenta mejor desempeño es la propuesta del Algoritmo Cuasi-Newton para Sistema de inferencia difusa tipo Mamdani, con un MSE de 1,21 E-04 para humedad y 2,03 E-03 para temperatura, así como sus respectivos porcentajes de efectividad calculados a partir del valor RMSE (Raíz del Error Cuadrático Medio).

Tabla 9.5: Resultados de predicción de humedad y temperatura en el ambiente. Elaboración propia.

CONFIG.	MSE HUMEDAD	MSE TEMPERATURA	% EFECTIVIDAD HUMEDAD	% EFECTIVIDAD TEMPERATURA
Algoritmo Genético para Sistema de Inferencia Difusa Tipo Mamdani	4,24E-04	2,84E-03	97,94	94,67
Algoritmo Genético para Sistema de Inferencia Difusa Tipo Sugeno	5,91E-04	5,70E-03	97,57	92,45
Cuasi-Newton para Sistema de Inferencia Difusa Tipo Mamdani	1,21E-04	2,03E-03	98,9	95,49
Cuasi-Newton para Sistema de Inferencia Difusa Tipo Sugeno	5,44E-04	4,95E-03	97,67	92,96

### Análisis de humedad en el ambiente

La Fig. 9.17 muestra el sistema de inferencia difusa tipo Mamdani para humedad, obtenido a partir de la corrección realizada por el algoritmo Cuasi-Newton, donde Fig. 9.17(a) corresponde a los conjuntos de entrada del primer día, Fig. 9.17(b) a los conjuntos de entrada del segundo día y Fig. 9.17(c) a los conjuntos de salida que reflejan la predicción proporcionada para el tercer día. Estos conjuntos se encuentran definidos por funciones de pertenencia de tipo triangular (trimf) y relacionan clasificaciones de humedad en rangos cualitativos correspondientes a las categorías Alta, Media y Baja.

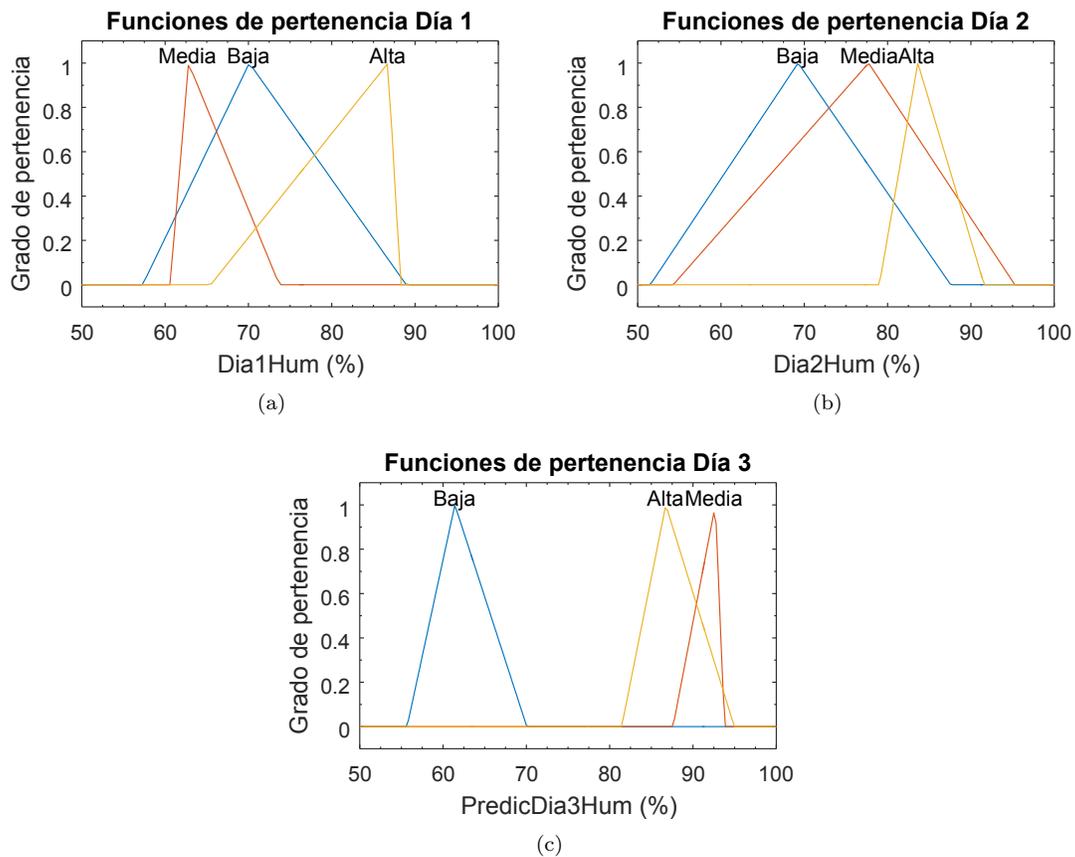


Fig. 9.17: Funciones de pertenencia para humedad en el ambiente: (a) funciones de pertenencia día 1; (b) funciones de pertenencia día 2; (c) funciones de pertenencia día 3. Elaboración propia. (Entorno MATLAB®).

En la Fig. 9.18, se puede observar gráficamente la correspondencia obtenida a partir de las reglas definidas en la Sección 8.1.1 y su interacción con los conjuntos difusos generados por el algoritmo.

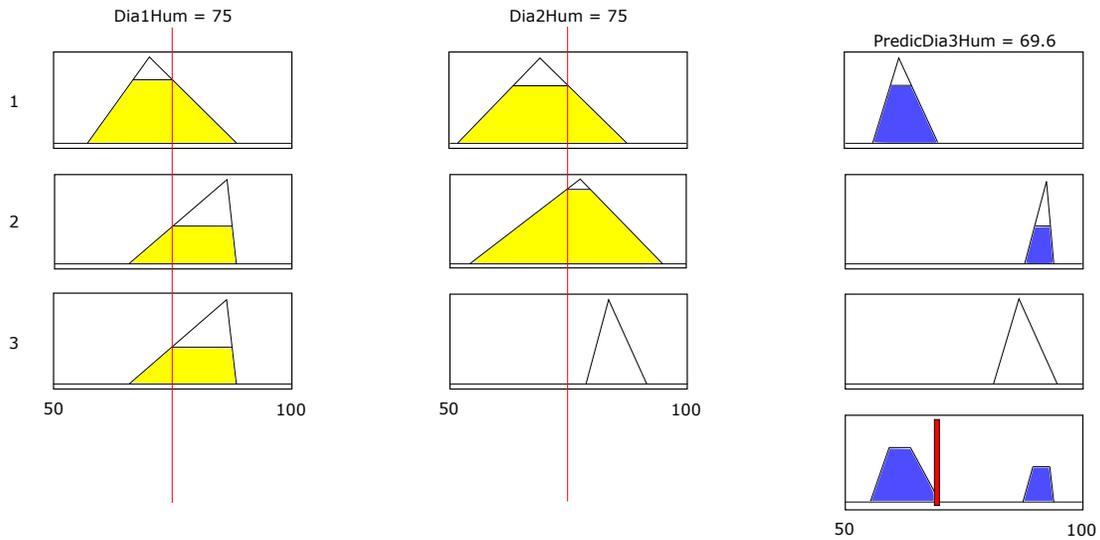


Fig. 9.18: Reglas del sistema de inferencia para humedad en el ambiente. Elaboración propia. (Entorno MATLAB®)

La aplicación de las reglas sobre los conjuntos de entrada determina el comportamiento de los conjuntos de salida lo cual, por ende, define la predicción realizada para los datos de humedad del tercer día. La Fig. 9.19 provee una superficie que refleja la forma en que actúan la delimitación de los conjuntos y las reglas para definir la predicción del tercer día, a partir de la medición realizada de 2 días anteriores.

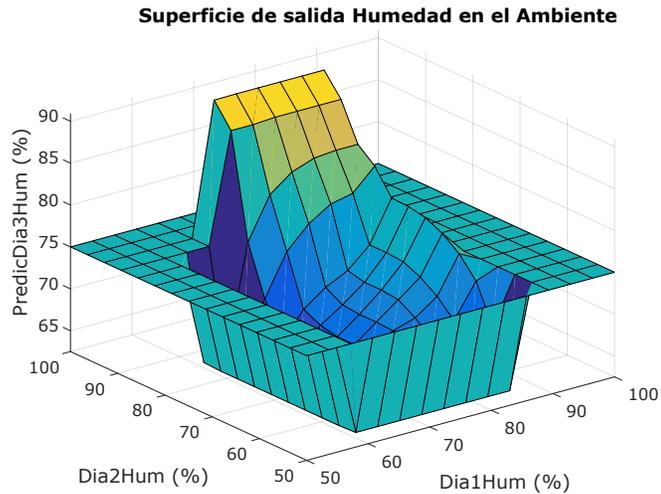


Fig. 9.19: Superficie de salida humedad en el ambiente. Elaboración propia. (Entorno MATLAB®)

Se realiza una prueba de Kruskal-Wallis para determinar la varianza de los datos obtenidos por la predicción en contraste con los datos reales. Se plantea la hipótesis nula de que los datos de ambos

grupos provienen de la misma distribución, es decir, que no existe variación relativamente significativa entre ambos conjuntos de datos. La Fig. 9.20 muestra la tabla de resultados que arrojó la prueba, elaborada mediante el software MATLAB, y la Fig. 9.21 muestra el análisis gráfico de la distribución de ambos conjuntos de datos.

Kruskal-Wallis ANOVA Table					
Source	SS	df	MS	Chi-sq	Prob>Chi-sq
Columns	0.08	1	0.083	0	0.9835
Error	9209.92	46	200.216		
Total	9210	47			

Fig. 9.20: Tabla de análisis de la varianza de la humedad en el ambiente mediante la prueba de Kruskal-Wallis. Elaboración propia. (Entorno MATLAB®)

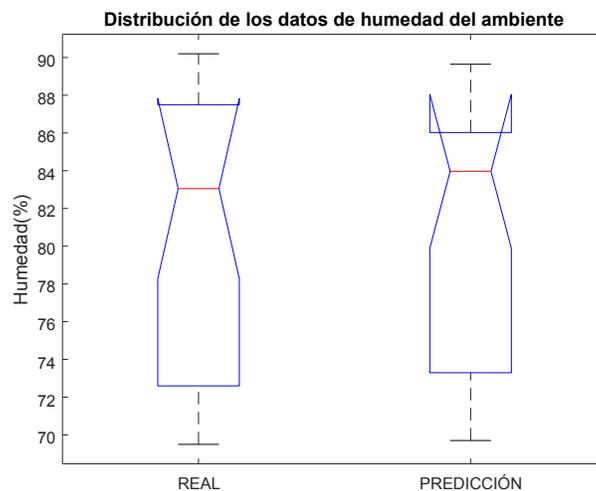


Fig. 9.21: Distribución de los datos de humedad del ambiente obtenidos mediante la prueba de Kruskal-Wallis. Elaboración propia. (Entorno MATLAB®)

Al tomar un intervalo de confianza de  $\alpha = 0,05$  y con un p-value de 0.9835 obtenido por la prueba de Kruskal-Wallis, ya que el p-value es mucho mayor en comparación con  $\alpha$ , no se puede negar la hipótesis nula, por tanto, a partir del análisis del diagrama de distribución de los datos se puede afirmar que no hay mayor variación entre la medición real y los datos obtenidos por la predicción en la variable de humedad.

### Análisis de temperatura en el ambiente

El algoritmo Cuasi-Newton otorga una corrección realizada para el sistema de inferencia difusa tipo Mamdani, los cuales relacionan clasificaciones de temperatura en rangos cualitativos correspondientes a las categorías Alta, Media y Baja. Estos conjuntos se encuentran definidos por funciones de pertenencia de tipo triangular (trimf). La Fig. 9.22 muestra la distribución resultante de dichos conjuntos donde Fig. 9.22(a) corresponde a los conjuntos de entrada del primer día, Fig. 9.22(b) a los conjuntos de entrada del segundo día y Fig. 9.22(c) a los conjuntos de salida que reflejan la predicción proporcionada para el tercer día.

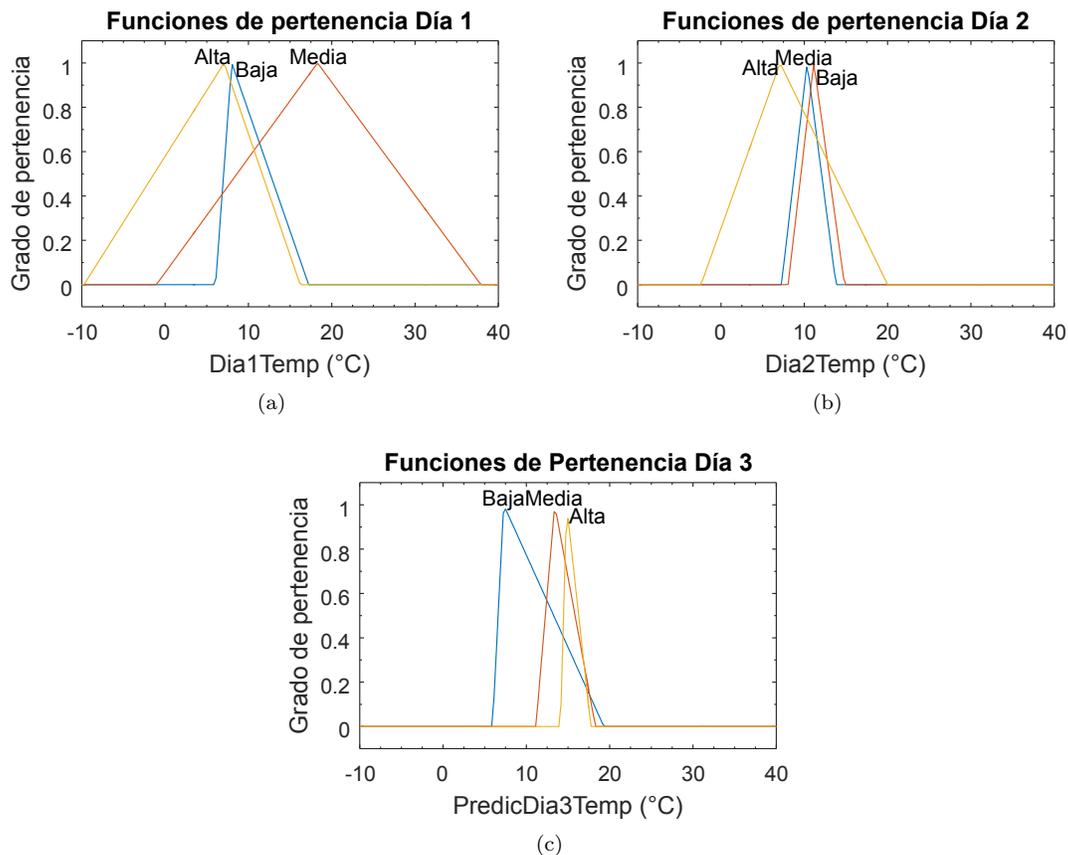


Fig. 9.22: Funciones de pertenencia para temperatura en el ambiente: (a) funciones de pertenencia día 1; (b) funciones de pertenencia día 2; (c) funciones de pertenencia día 3. Elaboración propia. (Entorno MATLAB®).

En la Fig. 9.23, se puede observar gráficamente la correspondencia obtenida a partir de las reglas definidas en la Sección 8.1.2 y su interacción con los conjuntos difusos generados por el algoritmo.

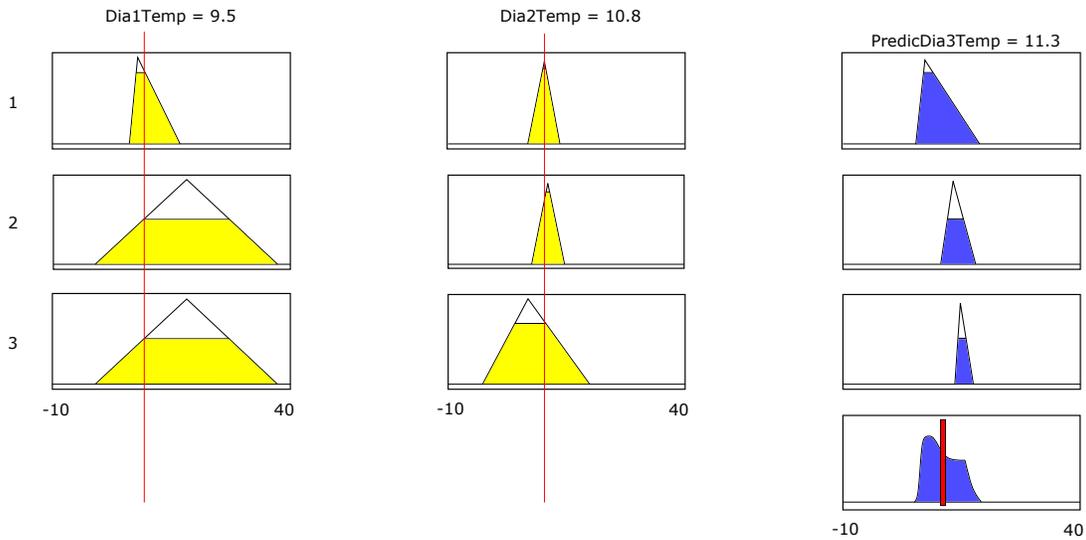


Fig. 9.23: Reglas del sistema de inferencia para temperatura en el ambiente. Elaboración propia (Entorno MATLAB®)

La forma en que actúan la delimitación de los conjuntos y las reglas definen la predicción del tercer día, a partir de la medición realizada de 2 días anteriores. La Fig. 9.24 provee una superficie que refleja este comportamiento.

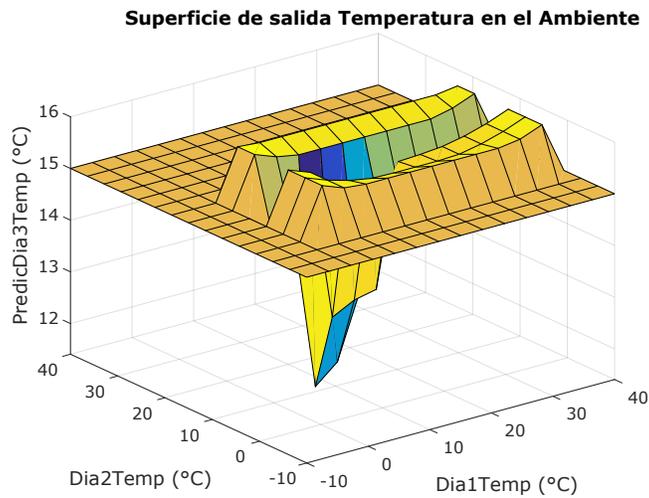


Fig. 9.24: Superficie de salida para temperatura en el ambiente. Elaboración propia (Entorno MATLAB®)

Para determinar la varianza de los datos obtenidos por la predicción en contraste con los datos reales, para la variable de temperatura, se realiza una prueba de Kruskal-Wallis. La Fig. 9.25 muestra la tabla de resultados que arrojó la prueba, elaborada mediante el software MATLAB, y la Fig. 9.26

muestra el análisis gráfico de la distribución de ambos conjuntos de datos.

Kruskal-Wallis ANOVA Table					
Source	SS	df	MS	Chi-sq	Prob>Chi-sq
Columns	8.33	1	8.333	0.04	0.8366
Error	9196.17	46	199.917		
Total	9204.5	47			

Fig. 9.25: Tabla de análisis de la varianza de la temperatura en el ambiente mediante la prueba de Kruskal-Wallis. Elaboración propia. (Entorno MATLAB®)

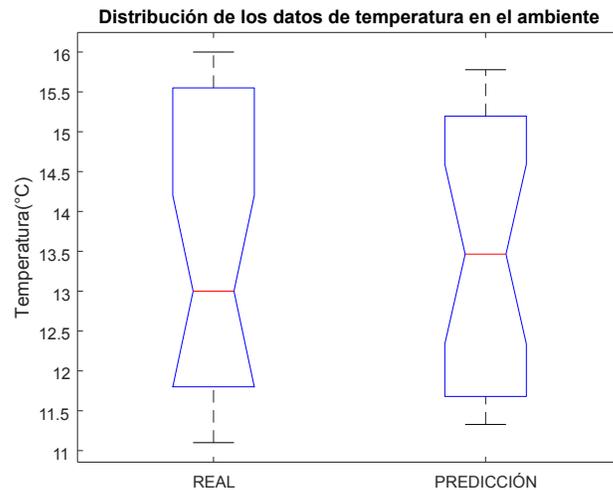


Fig. 9.26: Distribución de los datos de temperatura del ambiente obtenidos mediante la prueba de Kruskal-Wallis. Elaboración propia. (Entorno MATLAB®)

Se plantea la hipótesis nula de que los datos de ambos grupos provienen de la misma distribución, es decir, que no existe variación relativamente significativa entre ambos conjuntos de datos. Con un p-value de 0.8366 obtenido por la prueba de Kruskal-Wallis y al tomar un intervalo de confianza de  $\alpha = 0,05$ , no es posible negar la hipótesis nula, ya que el p-value es mucho mayor en comparación con  $\alpha$ , sin embargo, al analizar el gráfico de distribución de los datos se concluye que no existe mayor variación entre ambos conjuntos de datos.

## 9.2. PREDICCIÓN DE HUMEDAD Y TEMPERATURA EN INVERNADEROS

En este apartado se mide el desempeño de los 4 modelos propuestos frente al caso de análisis del microclima del invernadero, considerando las variables de humedad y temperatura. El análisis se lleva a cabo mediante un conjunto de herramientas estadísticas, como el error cuadrático medio, y el uso de gráficos para evaluar el comportamiento de los modelos.

### 9.2.1. ALGORITMO GENÉTICO PARA SISTEMA DE INFERENCIA DIFUSA TIPO MAMDANI

El algoritmo genético propuesto hace uso de un sistema de inferencia difusa tipo Mamdani, que posee dos entradas subdivididas en conjuntos de tipo triangular (trimf) y una salida del mismo tipo, para cada una de las variables.

Se calcula un promedio de MSE para humedad de 6,66 E-04 y para temperatura de 5,91 E-04, presentando una desviación estándar para humedad de 3,03 E-04 y para temperatura de 5,51 E-04. En la Tabla 9.6 E1, E2, ..., E30, hacen referencia a cada una de las ejecuciones del algoritmo.

Tabla 9.6: Ejecuciones Algoritmo Genético para Sistema de Inferencia Difusa Tipo Mamdani (C1) en Invernadero. Elaboración propia.

	HUMEDAD			TEMPERATURA		
	MÍNIMO	MÁXIMO	PROMEDIO	MÍNIMO	MÁXIMO	PROMEDIO
<b>E1</b>	5,05 E-04	4,92 E-02	5,15 E-04	3,36 E-04	4,62 E-02	3,25 E-04
<b>E2</b>	6,65 E-04	4,11 E-02	3,45 E-04	1,30 E-03	4,52 E-02	2,83 E-04
<b>E3</b>	7,94 E-04	4,07 E-02	4,04 E-04	6,25 E-06	5,72 E-02	5,31 E-04
<b>E4</b>	3,47 E-04	6,22 E-02	7,47 E-04	1,30 E-03	2,54 E-02	6,81 E-05
<b>E5</b>	1,02 E-03	4,96 E-02	5,05 E-04	9,16 E-04	4,18 E-02	4,43 E-04
<b>E6</b>	5,89 E-04	4,61 E-02	4,51 E-04	4,15 E-04	5,03 E-02	2,10 E-04
<b>E7</b>	4,40 E-04	7,39 E-02	7,68 E-04	2,23 E-04	7,78 E-02	6,15 E-04
<b>E8</b>	1,44 E-03	5,45 E-02	5,72 E-04	5,58 E-05	6,97 E-02	3,45 E-04
<b>E9</b>	1,47 E-03	5,94 E-02	6,14 E-04	7,94 E-05	3,44 E-02	2,08 E-04
<b>E10</b>	4,56 E-04	5,74 E-02	4,70 E-04	3,11 E-03	5,55 E-02	8,02 E-04
<b>E11</b>	4,97 E-03	6,04 E-02	5,48 E-04	6,04 E-04	3,93 E-02	4,22 E-04
<b>E12</b>	8,73 E-04	4,37 E-02	3,57 E-04	1,10 E-03	3,73 E-02	3,56 E-04
<b>E13</b>	1,06 E-03	8,15 E-02	6,14 E-04	3,43 E-03	7,60 E-02	1,94 E-03
<b>E14</b>	7,08 E-04	4,81 E-02	4,93 E-04	3,72 E-04	3,74 E-02	3,67 E-04
<b>E15</b>	2,29 E-04	4,48 E-02	3,99 E-04	6,75 E-04	7,25 E-02	6,05 E-04

<b>E16</b>	1,29 E-04	6,75 E-02	6,03 E-04	1,51 E-03	5,93 E-02	1,12 E-03
<b>E17</b>	5,66 E-04	6,40 E-02	5,73 E-04	3,41 E-04	4,92 E-02	7,93 E-04
<b>E18</b>	7,83 E-04	7,53 E-02	1,47 E-03	1,10 E-03	5,18 E-02	3,59 E-04
<b>E19</b>	4,21 E-04	5,53 E-02	6,19 E-04	4,91 E-05	6,69 E-02	6,93 E-04
<b>E20</b>	3,37 E-04	6,21 E-02	6,78 E-04	2,98 E-04	3,47 E-02	2,57 E-04
<b>E21</b>	1,34 E-04	5,44 E-02	5,95 E-04	5,11 E-05	7,20 E-02	4,73 E-04
<b>E22</b>	1,04 E-03	1,00 E-01	1,54 E-03	9,07 E-04	1,79 E-02	7,03 E-05
<b>E23</b>	1,09 E-03	6,78 E-02	1,06 E-03	1,55 E-03	1,55 E-01	2,41 E-03
<b>E24</b>	2,77 E-03	4,23 E-02	3,88 E-04	5,72 E-05	5,69 E-02	3,02 E-04
<b>E25</b>	2,20 E-03	1,01 E-01	1,15 E-03	2,41 E-04	7,76 E-02	1,85 E-03
<b>E26</b>	1,60 E-03	6,73 E-02	9,07 E-04	1,43 E-03	3,85 E-02	4,13 E-04
<b>E27</b>	8,84 E-04	7,45 E-02	7,30 E-04	1,50 E-03	5,08 E-02	4,10 E-04
<b>E28</b>	4,95 E-04	5,31 E-02	5,31 E-04	5,19 E-04	6,22 E-02	3,99 E-04
<b>E29</b>	1,52 E-04	4,15 E-02	4,06 E-04	2,90 E-04	4,57 E-02	3,80 E-04
<b>E30</b>	2,24 E-03	9,20 E-02	9,34 E-04	8,10 E-04	6,20 E-02	2,77 E-04
	<b>1,01 E-03</b>	<b>6,10 E-02</b>	<b>6,66 E-04</b>	<b>8,19 E-04</b>	<b>5,56 E-02</b>	<b>5,91 E-04</b>
	<b>DESVIACIÓN ESTANDAR</b>		<b>3,03 E-04</b>	<b>DESVIACIÓN ESTANDAR</b>		<b>5,51 E-04</b>

### Humedad

Los datos de humedad obtenidos por la predicción vs la medición real se muestran en la Fig. 9.27 donde de manera gráfica se evidencia la ejecución E2, que según los datos de la Tabla 9.6 presenta el mejor desempeño. En el eje de abscisas se relaciona el periodo de tiempo analizado, que en este caso fue de 24 horas y en el eje de ordenadas se encuentran los valores de humedad, medidos en porcentaje (%).

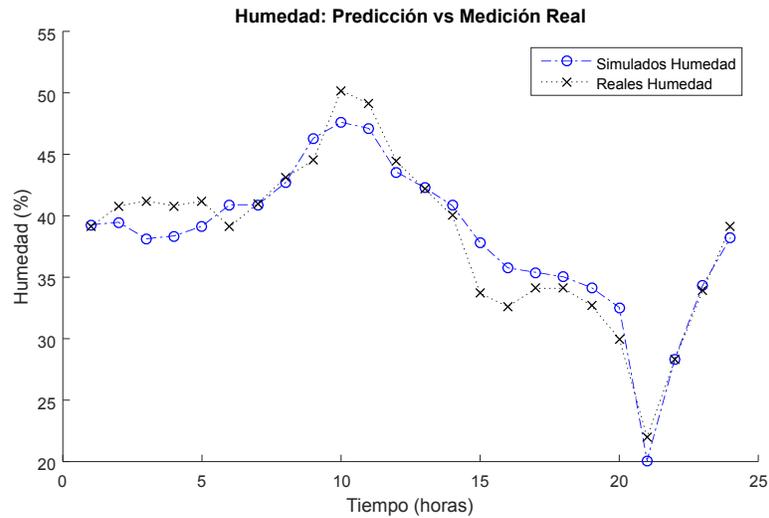


Fig. 9.27: Comparación Humedad en Invernadero (C1). Elaboración propia (Entorno MATLAB®).

Se consigue un MSE o error cuadrático medio de  $3,45 \text{ E-}04$  en la ejecución E2 como se muestra en la Fig. 9.28 donde de manera gráfica se muestra la relación del error a través del tiempo entre los datos de humedad de la predicción con los datos reales. Además, se pueden visualizar los instantes de tiempo en donde se presenta mayor diferencia entre los dos grupos de datos.

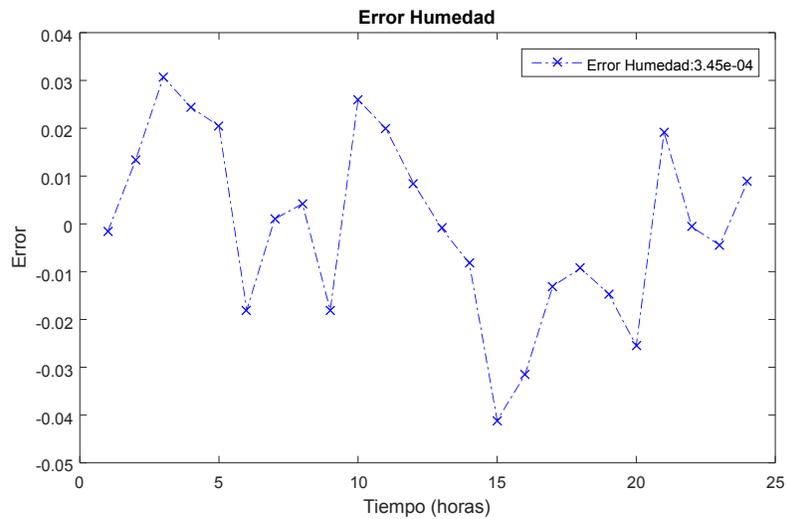


Fig. 9.28: Error Humedad en Invernadero (C1). Elaboración propia (Entorno MATLAB®).

## Temperatura

En la Fig. 9.29 se pueden evidenciar los resultados de la ejecución E4, que de acuerdo a la Tabla 9.6 es la que presenta el mejor desempeño. En la gráfica se muestran los datos de temperatura obtenidos por la predicción vs la medición real. En el eje de abscisas se relaciona el periodo de tiempo analizado, medido en horas, y en el eje de ordenadas se encuentran los valores de temperatura, medidos en grados centígrados ( $^{\circ}\text{C}$ ).

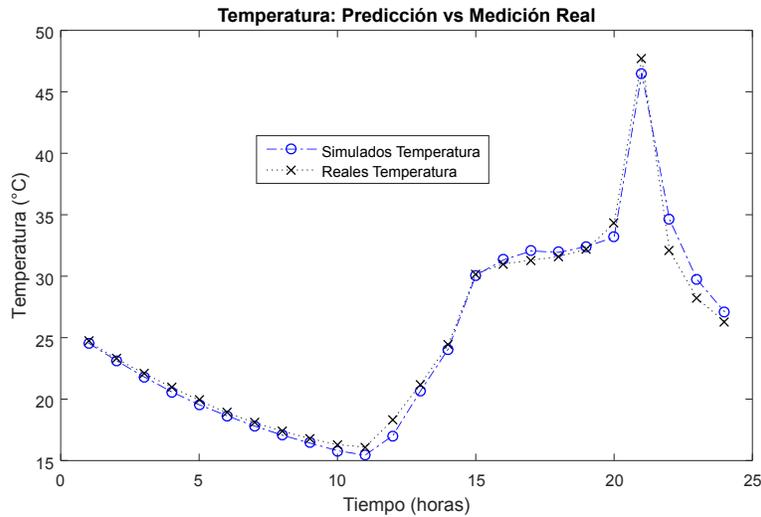


Fig. 9.29: Comparación Temperatura en Invernadero (C1). Elaboración propia (Entorno MATLAB®).

La Fig. 9.30 muestra la relación del error a través del tiempo entre los datos de temperatura obtenidos de la predicción y los datos reales. En esta gráfica se pueden ver los instantes de tiempo donde ocurre la mayor variación. El MSE o error cuadrático medio corresponde a  $6,81 \text{ E-}05$  en la ejecución E4.

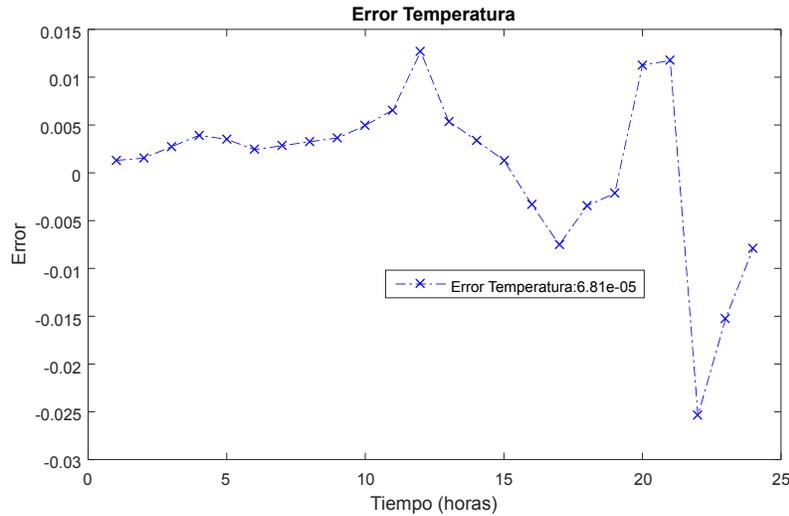


Fig. 9.30: Error Temperatura en Invernadero (C1). Elaboración propia (Entorno MATLAB®).

### 9.2.2. ALGORITMO GENÉTICO PARA SISTEMA DE INFERENCIA DIFUSA TIPO SUGENO

El algoritmo genético utilizado se realiza teniendo como base un sistema de inferencia difusa tipo Sugeno, en el cual existen 2 entradas, que se encuentran representadas por conjuntos difusos de tipo sigmoidal (smf), gaussiano (gaussmf) y z-shaped (zmf); y presenta una salida de tipo constante, para cada una de las variables.

Se realizan 30 ejecuciones del algoritmo genético obteniendo los errores mínimo, máximo y MSE de cada ejecución. El promedio de los MSE calculados para humedad es de 2,02 E-03 y para temperatura es de 2,57 E-03, presentando una desviación estándar para humedad de 5,70 E-04 y para temperatura de 5,54 E-04. En la Tabla 9.7 E1, E2,..., E30, hacen referencia a las configuraciones aleatorias en cada ejecución.

Tabla 9.7: Ejecuciones Algoritmo Genético para Sistema de Inferencia Difusa Tipo Sugeno (C2) en Invernadero. Elaboración propia.

	HUMEDAD			TEMPERATURA		
	MÍNIMO	MÁXIMO	PROMEDIO	MÍNIMO	MÁXIMO	PROMEDIO
<b>E1</b>	2,39 E-04	1,13 E-01	1,62 E-03	5,20 E-04	1,89 E-01	3,10 E-03
<b>E2</b>	5,96 E-04	1,37 E-01	2,81 E-03	7,29 E-03	1,86 E-01	4,03 E-03
<b>E3</b>	1,46 E-03	1,39 E-01	2,46 E-03	2,29 E-04	1,87 E-01	1,68 E-03
<b>E4</b>	3,07 E-03	1,34 E-01	1,91 E-03	1,91 E-04	1,64 E-01	2,34 E-03
<b>E5</b>	2,71 E-04	1,34 E-01	1,24 E-03	1,44 E-04	1,90 E-01	1,90 E-03
<b>E6</b>	1,47 E-05	1,08 E-01	1,99 E-03	4,62 E-05	1,97 E-01	2,30 E-03

<b>E7</b>	2,31 E-04	1,40 E-01	2,90 E-03	2,59 E-03	1,89 E-01	2,69 E-03
<b>E8</b>	1,24 E-05	1,28 E-01	1,51 E-03	9,49 E-04	1,83 E-01	1,79 E-03
<b>E9</b>	1,73 E-04	9,96 E-02	2,08 E-03	1,01 E-03	2,00 E-01	2,11 E-03
<b>E10</b>	7,17 E-04	1,09 E-01	1,22 E-03	1,39 E-03	1,68 E-01	1,47 E-03
<b>E11</b>	2,45 E-04	1,47 E-01	2,27 E-03	7,76 E-04	1,96 E-01	3,17 E-03
<b>E12</b>	1,31 E-04	1,18 E-01	1,01 E-03	9,98 E-04	2,11 E-01	2,98 E-03
<b>E13</b>	1,28 E-04	1,67 E-01	2,34 E-03	3,25 E-04	2,03 E-01	2,54 E-03
<b>E14</b>	4,50 E-04	1,16 E-01	1,53 E-03	5,14 E-04	1,47 E-01	2,98 E-03
<b>E15</b>	7,41 E-05	1,59 E-01	1,76 E-03	2,81 E-03	2,02 E-01	2,59 E-03
<b>E16</b>	5,82 E-03	1,15 E-01	2,91 E-03	6,05 E-04	2,10 E-01	2,94 E-03
<b>E17</b>	4,65 E-05	1,47 E-01	2,11 E-03	7,66 E-06	2,06 E-01	2,36 E-03
<b>E18</b>	4,20 E-04	1,63 E-01	2,54 E-03	4,12 E-04	2,04 E-01	1,83 E-03
<b>E19</b>	7,21 E-04	1,84 E-01	3,22 E-03	1,02 E-03	1,89 E-01	2,04 E-03
<b>E20</b>	2,10 E-03	1,07 E-01	1,43 E-03	1,95 E-04	2,21 E-01	3,11 E-03
<b>E21</b>	1,19 E-03	1,75 E-01	2,70 E-03	2,96 E-04	2,05 E-01	2,50 E-03
<b>E22</b>	1,90 E-03	1,51 E-01	1,63 E-03	1,21 E-03	1,86 E-01	2,60 E-03
<b>E23</b>	1,33 E-03	1,60 E-01	2,19 E-03	5,79 E-04	2,18 E-01	3,16 E-03
<b>E24</b>	1,73 E-04	1,14 E-01	1,32 E-03	4,40 E-04	2,23 E-01	2,92 E-03
<b>E25</b>	4,46 E-04	1,39 E-01	1,58 E-03	4,79 E-04	2,19 E-01	2,42 E-03
<b>E26</b>	1,64 E-03	1,46 E-01	2,11 E-03	1,26 E-03	2,09 E-01	2,99 E-03
<b>E27</b>	4,13 E-03	1,39 E-01	2,48 E-03	1,68 E-03	2,03 E-01	2,85 E-03
<b>E28</b>	2,31 E-04	1,48 E-01	1,99 E-03	6,98 E-04	1,99 E-01	3,02 E-03
<b>E29</b>	9,90 E-04	1,25 E-01	1,55 E-03	1,99 E-03	1,97 E-01	2,24 E-03
<b>E30</b>	6,96 E-04	1,40 E-01	2,18 E-03	1,05 E-03	1,38 E-01	2,58 E-03
	<b>9,88 E-04</b>	<b>1,37 E-01</b>	<b>2,02 E-03</b>	<b>1,06 E-03</b>	<b>1,95 E-01</b>	<b>2,57 E-03</b>
	<b>DESVIACIÓN ESTANDAR</b>		<b>5,70 E-04</b>	<b>DESVIACIÓN ESTANDAR</b>		<b>5,54 E-04</b>

### Humedad

A partir de la ejecución E12, que según la Tabla 9.7 es la que presenta el mejor desempeño, se construye una gráfica que relaciona los datos de humedad obtenidos por la predicción vs la medición real y que se muestran en la Fig. 9.31. En el eje de abscisas se relaciona el periodo de tiempo analizado, que corresponde a las 24 horas del tercer día, y en el eje de ordenadas se encuentran los valores de humedad, medidos en porcentaje (%).

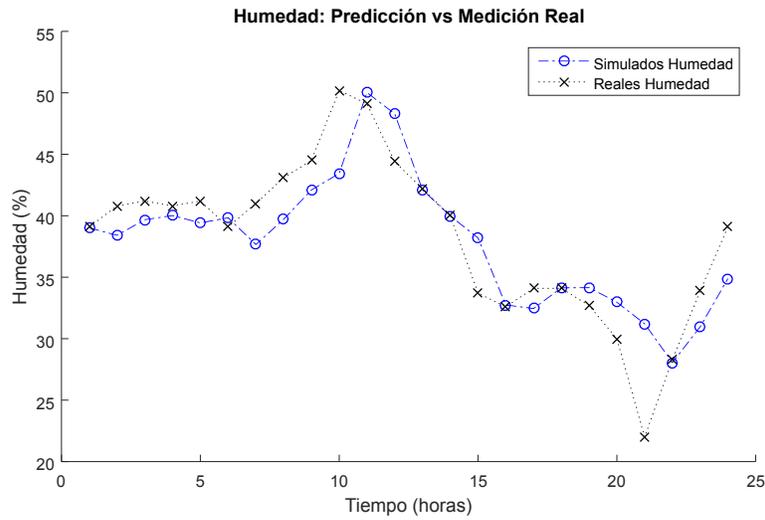


Fig. 9.31: Comparación Humedad en Invernadero (C2). Elaboración propia (Entorno MATLAB®).

Se consigue un MSE o error cuadrático medio de  $1,01 \text{ E-}03$  en la ejecución E12 como se muestra en la Fig. 9.32, donde se puede ver la variación a través del tiempo entre los grupos de datos a analizar, en este caso, los valores de predicción vs la medición real.

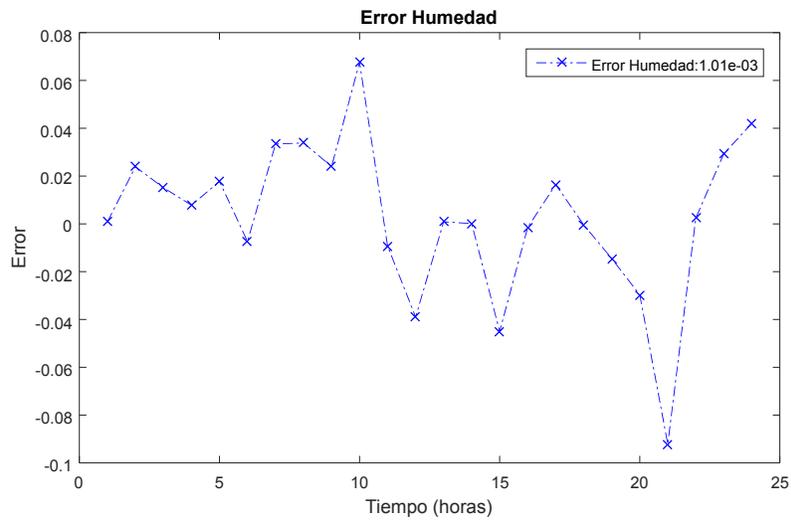


Fig. 9.32: Error Humedad en Invernadero (C2). Elaboración propia (Entorno MATLAB®).

### Temperatura

Los datos de temperatura obtenidos por la predicción vs la medición real se muestran en la Fig. 9.33 donde de manera gráfica se evidencia la ejecución E10, que según los datos de la Tabla 9.7 presenta el

mejor desempeño. En el eje de abscisas se relaciona el periodo de tiempo analizado, que en este caso fue de 24 horas y en el eje de ordenadas se encuentran los valores de temperatura, medidos en grados centígrados.

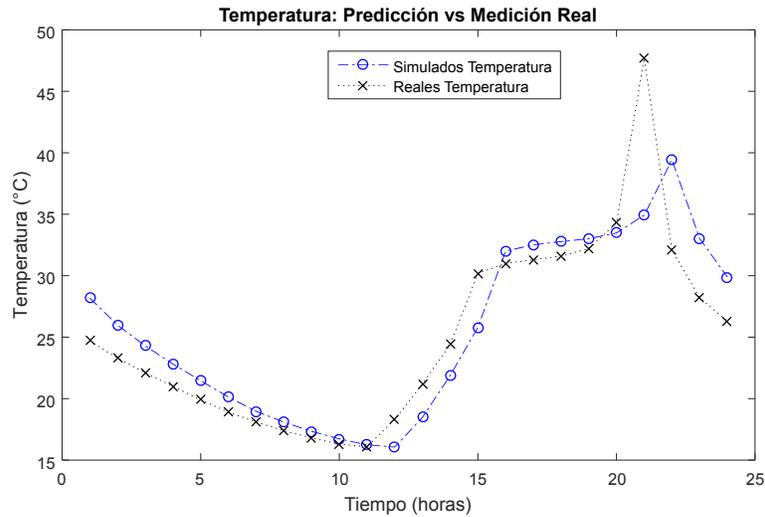


Fig. 9.33: Comparación Temperatura en Invernadero (C2). Elaboración propia (Entorno MATLAB®).

La relación del error en el tiempo se puede observar a través de la Fig. 9.34, en la cual es posible distinguir los instantes en que se presenta mayor variación entre la predicción y la medición real. Se consigue un MSE o error cuadrático medio de  $1,47 \text{ E-}03$ .

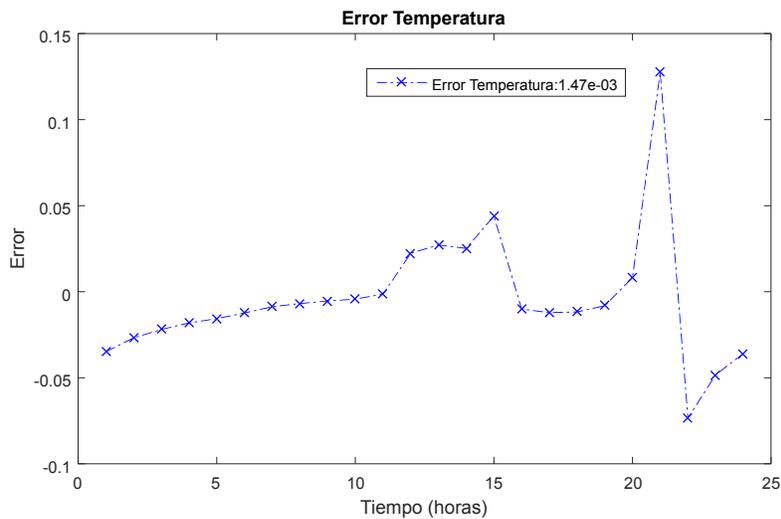


Fig. 9.34: Error Temperatura en Invernadero (C2). Elaboración propia (Entorno MATLAB®).

### 9.2.3. CUASI-NEWTON PARA SISTEMA DE INFERENCIA DIFUSA TIPO MAMDANI

Se establece una configuración inicial de algoritmo Cuasi-Newton correspondiente a la retroalimentación obtenida por el mejor sistema de inferencia difusa tipo Mamdani, el cual fue generado mediante el algoritmo genético descrito en la Sección 9.2.1.

La función fitness para humedad y temperatura es el valor esperado de las variables menos el valor obtenido, considerando los datos normalizados. Los errores: mínimo, máximo y MSE, obtenidos por el algoritmo Cuasi-Newton para el sistema de inferencia difusa tipo Mamdani, se muestran en la Tabla 9.8.

Tabla 9.8: Cuasi-Newton para Sistema de Inferencia Difusa Tipo Mamdani (C3) en Invernadero. Elaboración propia.

ERROR	HUMEDAD	TEMPERATURA
Mínimo	2,15E-04	1,63E-04
Máximo	3,85E-02	1,97E-02
MSE	3,06E-04	3,98E-05

#### Humedad

El desempeño obtenido para humedad muestra en la Fig. 9.35, que relaciona la predicción de humedad vs la medición real. En el eje de abscisas se encuentra el periodo de tiempo analizado, correspondiente a 24 horas del tercer día, y en el eje de ordenadas se encuentran los valores de humedad medidos en porcentaje (%).

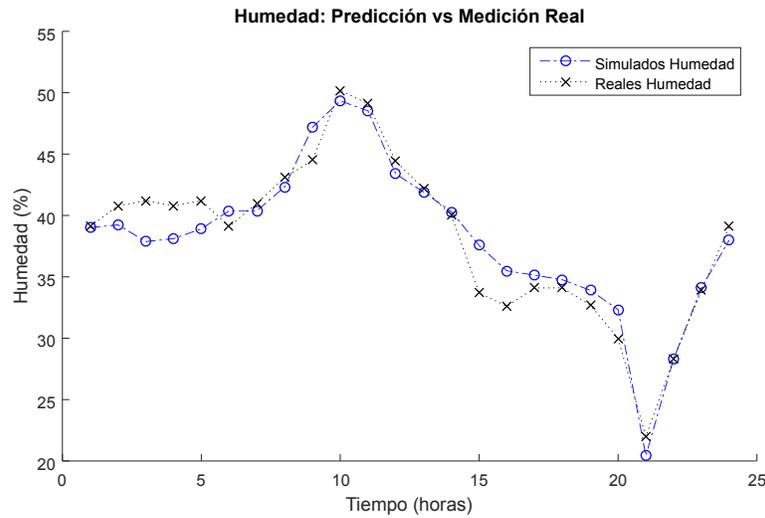


Fig. 9.35: Comparación Humedad en Invernadero (C3). Elaboración propia (Entorno MATLAB®).

Se consigue un MSE o error cuadrático medio de  $3,06E-04$  para humedad como se muestra en la Fig. 9.36, donde de manera gráfica se muestra la relación del error a través del tiempo de los datos de predicción vs la medición real.

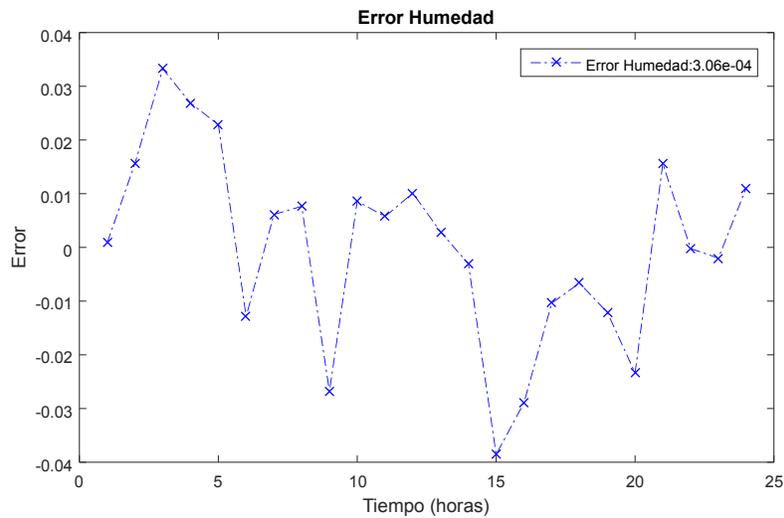


Fig. 9.36: Error Humedad en Invernadero (C3). Elaboración propia (Entorno MATLAB®).

## Temperatura

La Fig. 9.37 muestra, de manera gráfica, la predicción de temperatura vs la medición real del tercer día. En el eje de abscisas se encuentra el periodo de tiempo analizado, medido en horas, y en el eje de

ordenadas se encuentran los valores de temperatura, medidos en grados centígrados ( $^{\circ}\text{C}$ ).

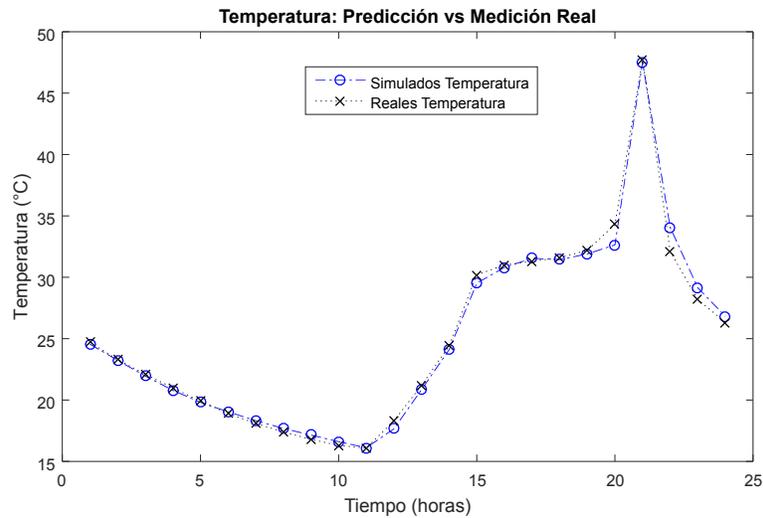


Fig. 9.37: Comparación Temperatura en Invernadero (C3). Elaboración propia (Entorno MATLAB $^{\circ}$ ).

La relación del error en el tiempo se puede observar a través de la Fig. 9.38, en la cual es posible distinguir los instantes en que se presenta mayor variación entre la predicción y la medición real. Se consigue un MSE o error cuadrático medio de  $3,98\text{E}-05$ .

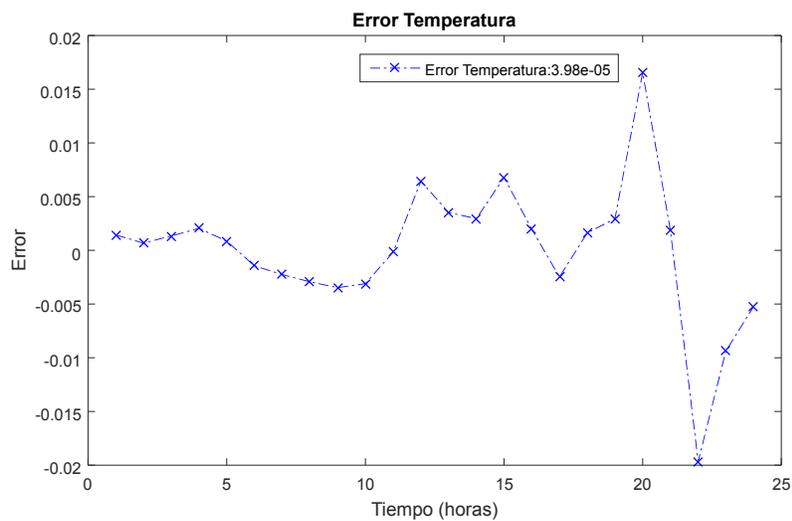


Fig. 9.38: Error Temperatura en Invernadero (C3). Elaboración propia (Entorno MATLAB $^{\circ}$ ).

### 9.2.4. CUASI-NEWTON PARA SISTEMA DE INFERENCIA DIFUSA TIPO SUGENO

Se toma como base el mejor sistema de inferencia tipo Sugeno, generado mediante el algoritmo genético descrito en la Sección 9.2.2. Este se usa como configuración inicial del algoritmo Cuasi-Newton.

Se construye una función fitness para humedad y temperatura, considerando los datos normalizados, y que corresponde al valor esperado de las variables menos el valor obtenido. A partir del algoritmo se obtienen los errores: mínimo, máximo y MSE que se muestran en la Tabla 9.9.

Tabla 9.9: Cuasi-Newton para Sistema de Inferencia Difusa Tipo Sugeno (C4) en Invernadero. Elaboración propia.

ERROR	HUMEDAD	TEMPERATURA
Mínimo	1,48E-04	1,64E-05
Máximo	1,12E-01	1,31E-01
MSE	8,40E-04	7,95E-04

#### Humedad

La Fig. 9.39 permite evidenciar el desempeño de la predicción de humedad vs la medición real. En el eje de abscisas se relaciona el periodo de tiempo analizado, el cual corresponde a las 24 horas del tercer día, y en el eje de ordenadas se encuentran los datos de humedad, medidos en porcentaje (%).

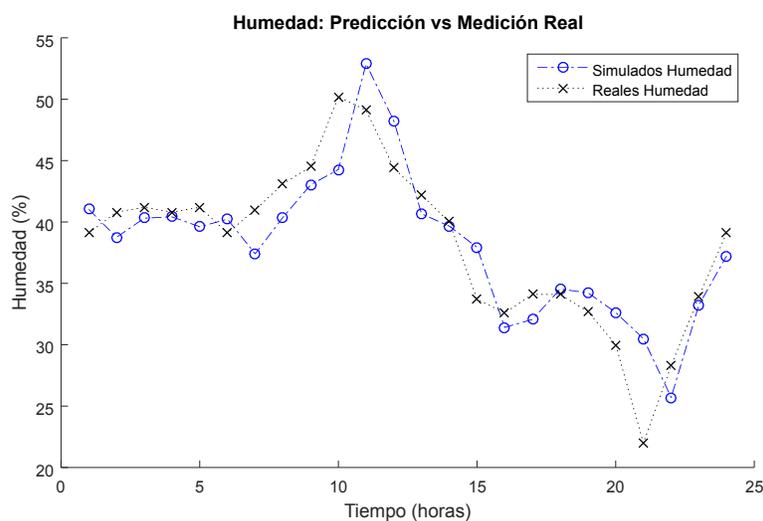


Fig. 9.39: Comparación Humedad en Invernadero (C4). Elaboración propia (Entorno MATLAB®).

Se consigue un MSE o error cuadrático medio de 8,40E-04 para humedad como se muestra en la

Fig. 9.40, donde de manera gráfica se muestra la relación del error a través del tiempo entre los datos de humedad obtenidos por la predicción y los datos reales, además que permite visualizar los instantes de tiempo donde se presenta mayor diferencia entre los dos grupos de datos.

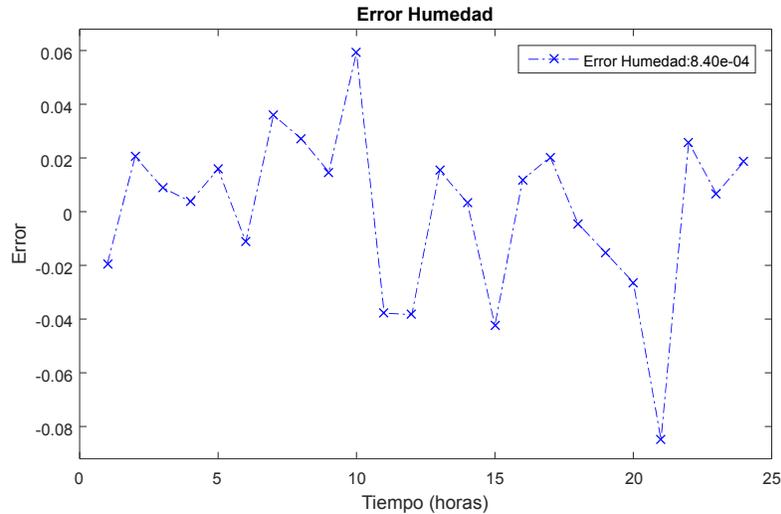


Fig. 9.40: Error Humedad en Invernadero (C4). Elaboración propia (Entorno MATLAB®).

## Temperatura

El desempeño de la predicción de temperatura vs la medición real se puede observar en la Fig. 9.41. En el eje de abscisas se relaciona el periodo de tiempo analizado, medido en horas, y en el eje de ordenadas se encuentran los datos de humedad, medidos en grados centígrados ( $^{\circ}\text{C}$ ).

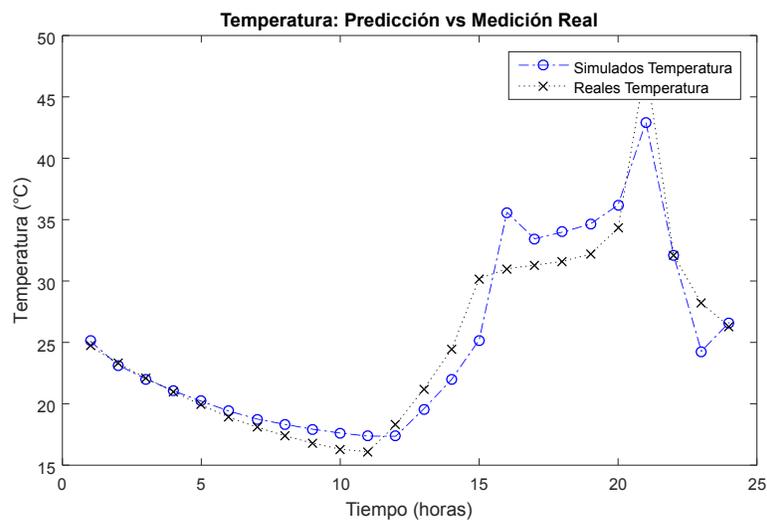


Fig. 9.41: Comparación Temperatura en Invernadero (C4). Elaboración propia (Entorno MATLAB®).

La Fig. 9.42 muestra la relación del error a través del tiempo entre los datos de temperatura de la predicción y los reales. Se consigue un MSE o error cuadrático medio de  $7,95E-04$  para temperatura.

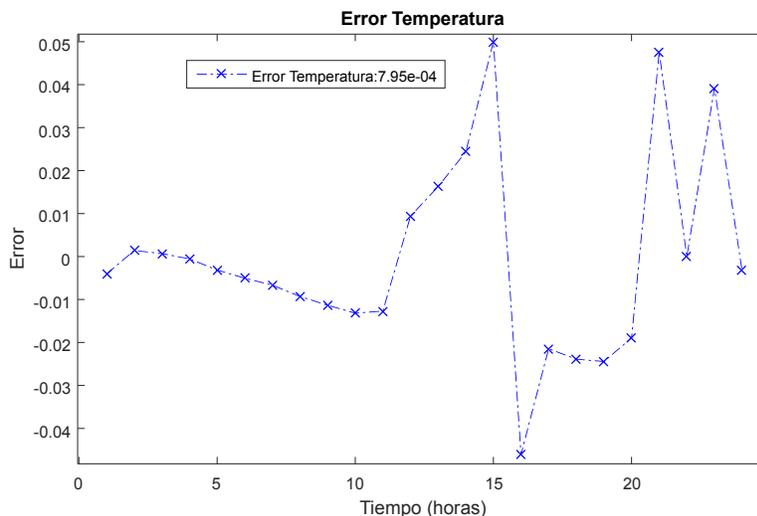


Fig. 9.42: Error Temperatura en Invernadero (C4). Elaboración propia (Entorno MATLAB®).

### 9.2.5. ANÁLISIS INVERNADERO

Se presenta la comparación de los resultados generales obtenidos en los 4 modelos propuestos y se determina a partir del MSE y el porcentaje de efectividad el modelo que mejor se adapta para la predicción de la humedad y temperatura en invernadero. Posteriormente, se procede a mostrar la configuración del sistema de inferencia obtenido, presentando las gráficas alusivas a los conjuntos, las reglas que controlan la relación entre las entradas y salidas del sistema, así como la superficie que se genera a partir de dichas reglas.

Finalmente, se realiza una prueba de Kruskal-Wallis para determinar la varianza de los datos obtenidos por la predicción en contraste con los reales, que en este caso corresponden a una distribución que no cumple con los criterios de normalidad.

#### Resultados Generales

Se realiza una comparación de los resultados obtenidos en las cuatro configuraciones, como se evidencia en la Tabla 9.10, donde se observa que la configuración que presenta mejor desempeño es la propuesta del Algoritmo Cuasi-Newton para Sistema de inferencia difusa tipo Mamdani, con un MSE de  $3,06E-04$  para humedad y  $3,98E-05$  para temperatura, así como sus respectivos porcentajes de efectividad calculados a partir del RMSE (Raíz del Error Cuadrático Medio).

Tabla 9.10: Resultados de predicción de humedad y temperatura en invernadero. Elaboración propia.

CONFIG.	MSE HUMEDAD	MSE TEMPERATURA	% EFECTIVIDAD HUMEDAD	% EFECTIVIDAD TEMPERATURA
Algoritmo Genético para Sistema de Inferencia Difusa Tipo Mamdani	3,45E-04	6,81E-05	98,14	99,17
Algoritmo Genético para Sistema de Inferencia Difusa Tipo Sugeno	1,01E-03	1,47E-03	96,81	96,17
Cuasi-Newton para Sistema de Inferencia Difusa Tipo Mamdani	3,06E-04	3,98E-05	98,25	99,37
Cuasi-Newton para Sistema de Inferencia Difusa Tipo Sugeno	8,40E-04	7,95E-04	97,1	97,18

### Humedad

El algoritmo Cuasi-Newton otorga una corrección realizada para el sistema de inferencia difusa tipo Mamdani, en donde se relacionan clasificaciones de humedad en rangos cualitativos correspondientes a las categorías Alta, Media y Baja. Estos conjuntos se encuentran definidos por funciones de pertenencia de tipo triangular (trimf). La Fig. 9.43 muestra la distribución resultante de dichos conjuntos donde Fig. 9.43(a) corresponde a los conjuntos de entrada del primer día, Fig. 9.43(b) a los conjuntos de entrada del segundo día y 9.43(c) a los conjuntos de salida que reflejan la predicción proporcionada para el tercer día.

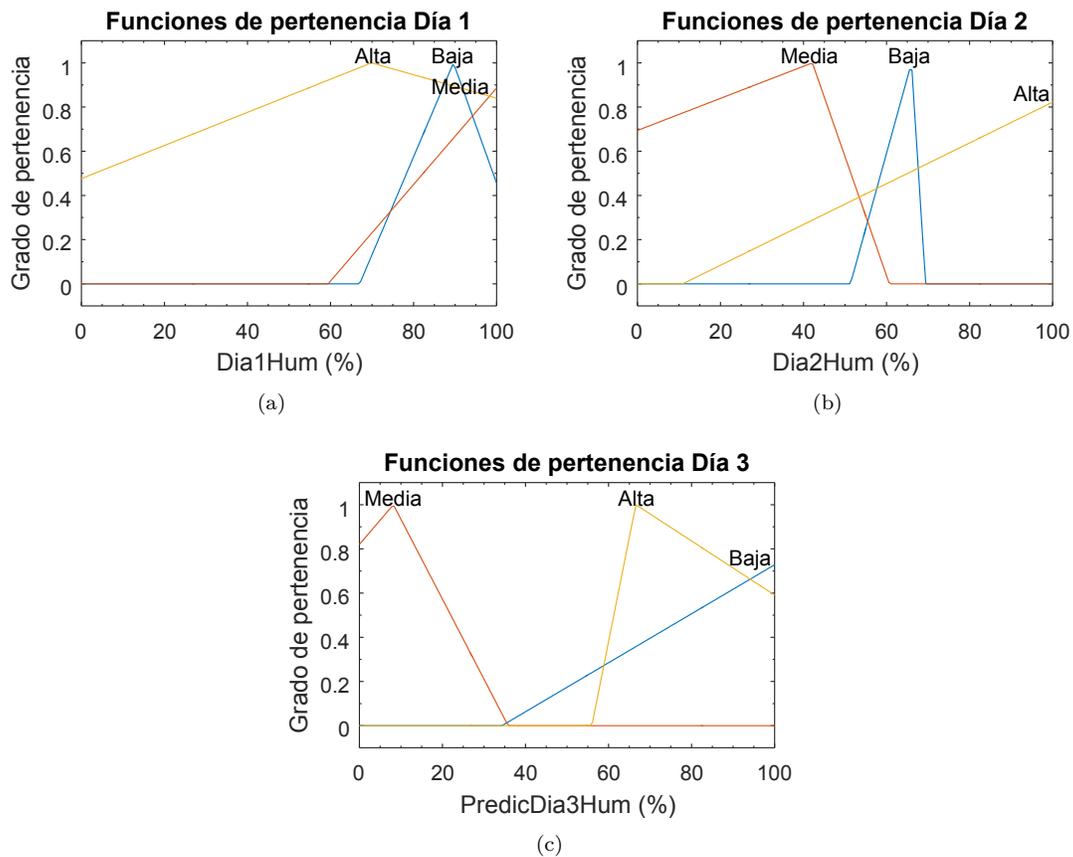


Fig. 9.43: Funciones de pertenencia para humedad en invernadero: (a) funciones de pertenencia día 1; (b) funciones de pertenencia día 2; (c) funciones de pertenencia día 3. Elaboración propia. (Entorno MATLAB®).

En la Fig. 9.44, se puede observar gráficamente la correspondencia obtenida a partir de las reglas definidas en la Sección 8.1.1 y su interacción con los conjuntos difusos generados por el algoritmo.

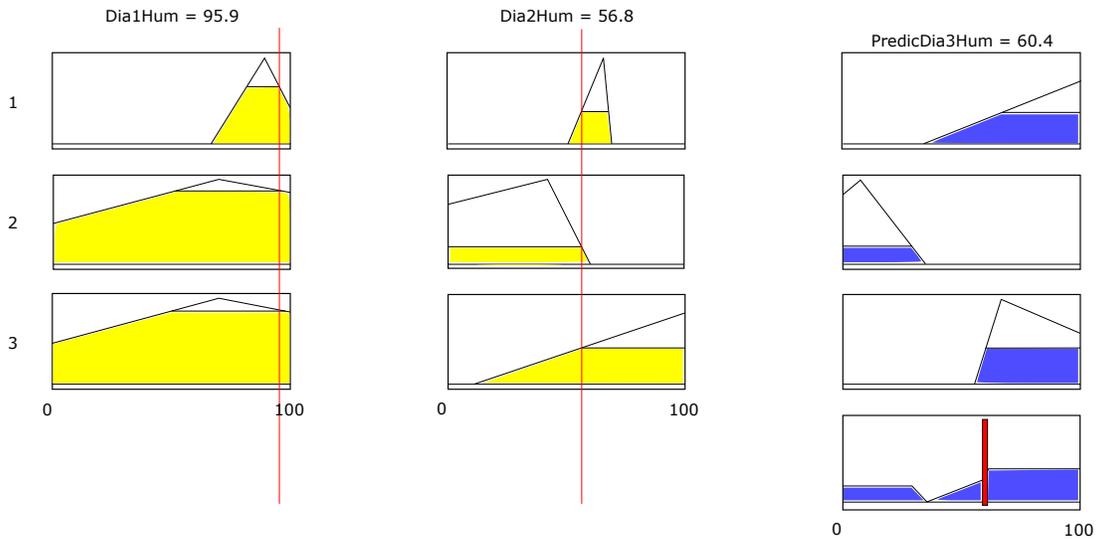


Fig. 9.44: Reglas del sistema de inferencia para humedad en invernadero. Elaboración propia. (Entorno MATLAB®)

La forma en que actúan la delimitación de los conjuntos y las reglas definen la predicción de humedad del tercer día, a partir de la medición realizada de 2 días anteriores. La Fig. 9.45 provee una superficie que refleja este comportamiento.

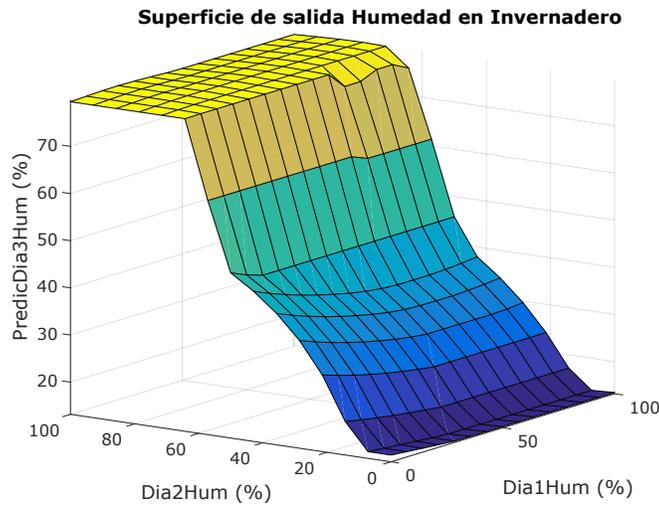


Fig. 9.45: Superficie de salida humedad en invernadero. Elaboración propia. (Entorno MATLAB®)

Se realiza una prueba de Kruskal-Wallis para determinar la varianza de los datos obtenidos por la predicción en contraste con los datos reales. Se plantea la hipótesis nula de que los datos de ambos grupos provienen de la misma distribución, es decir, que no existe variación relativamente significativa entre ambos conjuntos de datos. La Fig. 9.46 muestra la tabla de resultados que arrojó la prueba,

elaborada mediante el software MATLAB, y la Fig. 9.47 muestra el análisis gráfico de la distribución de ambos conjuntos de datos.

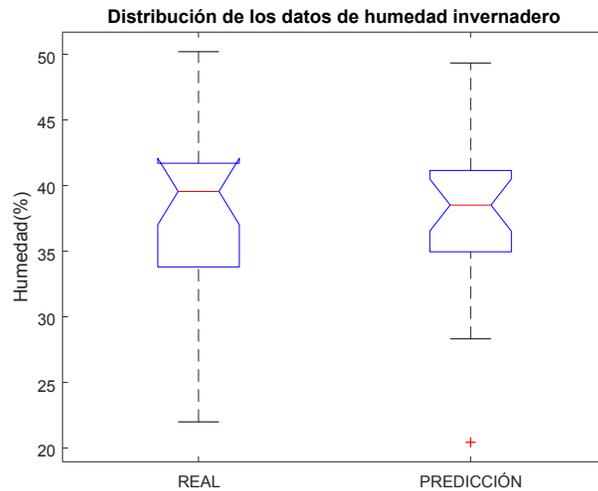


Fig. 9.46: Tabla de análisis de la varianza de la humedad en invernadero mediante la prueba de Kruskal-Wallis. Elaboración propia. (Entorno MATLAB®)

Kruskal-Wallis ANOVA Table					
Source	SS	df	MS	Chi-sq	Prob>Chi-sq
Columns	14.08	1	14.083	0.07	0.7886
Error	9193.92	46	199.868		
Total	9208	47			

Fig. 9.47: Distribución de los datos de humedad en invernadero obtenidos mediante la prueba de Kruskal-Wallis. Elaboración propia. (Entorno MATLAB®)

Al tomar un intervalo de confianza de  $\alpha = 0,05$  y con un p-value de 0.7886 obtenido por la prueba de Kruskal-Wallis, ya que el p-value es mucho mayor en comparación con  $\alpha$ , no se puede negar la hipótesis nula, por tanto, a partir del análisis del diagrama de distribución de los datos se puede afirmar que no hay mayor variación entre la medición real y los datos obtenidos por la predicción en la variable de humedad.

### Temperatura

La Fig. 9.48 muestra el sistema de inferencia difusa tipo Mamdani para temperatura obtenido a partir de la corrección realizada por el algoritmo Cuasi-Newton, donde Fig. 9.48(a) corresponde a los conjuntos de entrada del primer día, Fig. 9.48(b) a los conjuntos de entrada del segundo día y Fig. 9.48(c) a los conjuntos de salida que reflejan la predicción proporcionada para el tercer día. Estos conjuntos se encuentran definidos por funciones de pertenencia de tipo triangular (trimf) y relacionan clasificaciones de temperatura en rangos cualitativos correspondientes a las categorías Alta, Media y Baja.

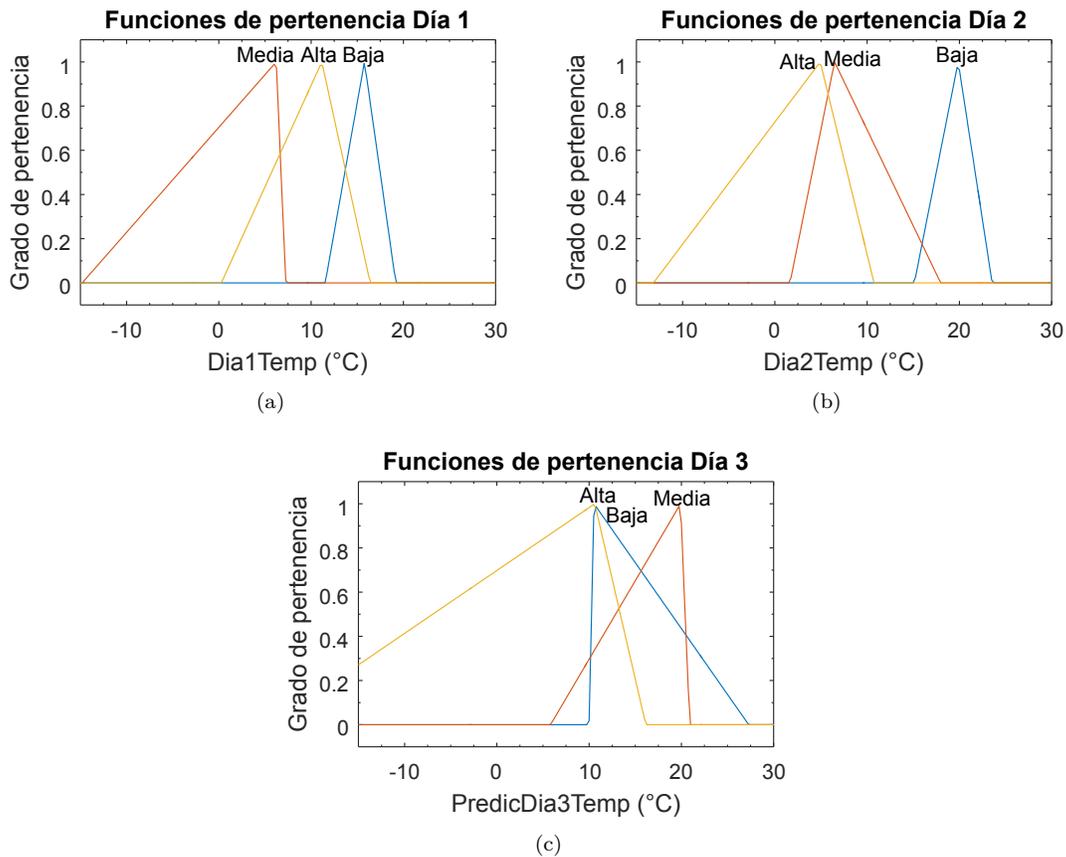


Fig. 9.48: Funciones de pertenencia para temperatura en invernadero: (a) funciones de pertenencia día 1; (b) funciones de pertenencia día 2; (c) funciones de pertenencia día 3. Elaboración propia. (Entorno MATLAB®).

En la Fig. 9.49, se puede observar gráficamente la correspondencia obtenida a partir de las reglas definidas en la Sección 8.1.2 y su interacción con los conjuntos difusos generados por el algoritmo.

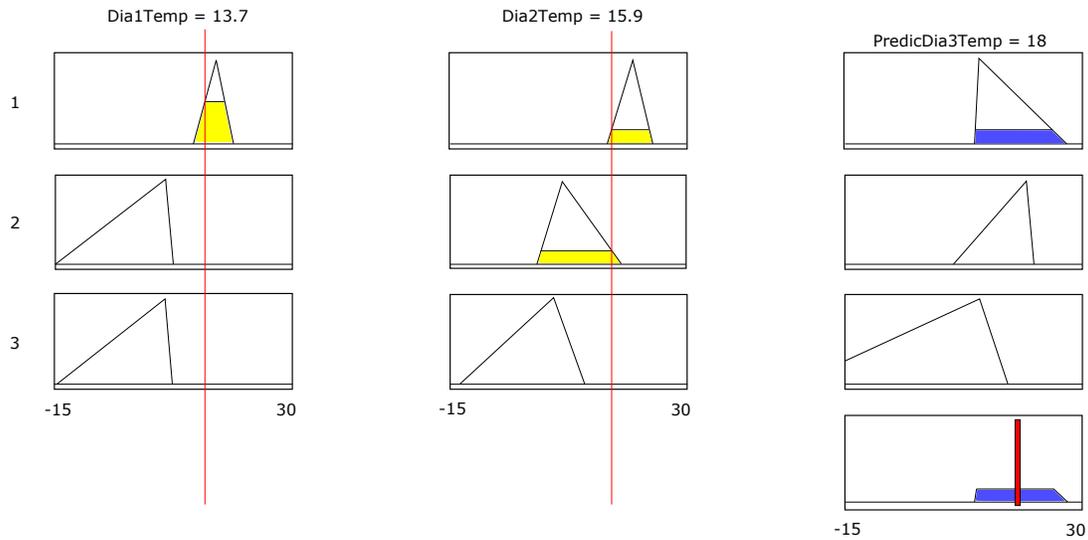


Fig. 9.49: Reglas del sistema de inferencia para temperatura en invernadero. Elaboración propia (Entorno MATLAB®)

La aplicación de las reglas sobre los conjuntos de entrada determina el comportamiento de los conjuntos de salida lo cual, por ende, define la predicción realizada para los datos de temperatura del tercer día. La Fig. 9.50 provee una superficie que refleja la forma en que actúan la delimitación de los conjuntos y las reglas para definir la predicción de temperatura del tercer día, a partir de la medición realizada de 2 días anteriores.

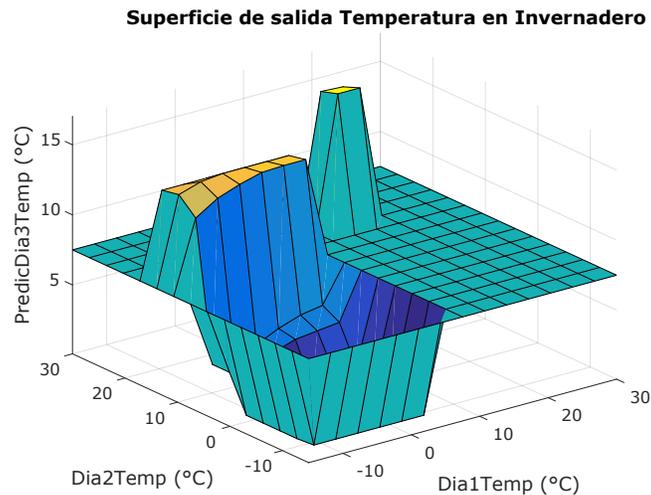


Fig. 9.50: Superficie de salida para temperatura en invernadero. Elaboración propia (Entorno MATLAB®)

Para determinar la varianza de los datos obtenidos por la predicción en contraste con los datos

reales, para la variable de temperatura, se realiza una prueba de Kruskal-Wallis. La Fig. 9.51 muestra la tabla de resultados que arrojó la prueba, elaborada mediante el software MATLAB, y la Fig. 9.52 muestra el análisis gráfico de la distribución de ambos conjuntos de datos.

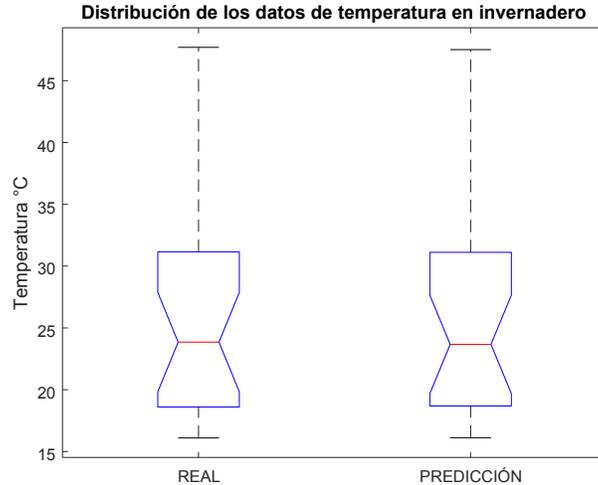


Fig. 9.51: Tabla de análisis de la varianza de la temperatura en invernadero mediante la prueba de Kruskal-Wallis. Elaboración propia. (Entorno MATLAB®)

Kruskal-Wallis ANOVA Table					
Source	SS	df	MS	Chi-sq	Prob>Chi-sq
Columns	0.75	1	0.75	0	0.9507
Error	9211.25	46	200.245		
Total	9212	47			

Fig. 9.52: Distribución de los datos de temperatura en invernadero obtenidos mediante la prueba de Kruskal-Wallis. Elaboración propia. (Entorno MATLAB®)

Se plantea la hipótesis nula de que los datos de ambos grupos provienen de la misma distribución, es decir, que no existe variación relativamente significativa entre ambos conjuntos de datos. Con un p-value de 0.9507 obtenido por la prueba de Kruskal-Wallis y al tomar un intervalo de confianza de  $\alpha = 0,05$ , no es posible negar la hipótesis nula, ya que el p-value es mucho mayor en comparación con  $\alpha$ , sin embargo, al analizar el gráfico de distribución de los datos se concluye que no existe mayor variación entre ambos conjuntos de datos.



## Capítulo 10

# PROTOTIPO DE VISUALIZACIÓN

A partir del mejor modelo de predicción, basado en el error cuadrático medio obtenido, se almacena el conjunto difuso y su configuración tanto para humedad y temperatura en el ambiente y en un invernadero. Dependiendo el tipo de predicción obtenida y basado en un archivo con los datos de las 48 horas anteriores, se elabora un prototipo software que permite visualizar de manera gráfica la predicción de humedad y temperatura de las 24 horas posteriores a la obtención de datos.

### 10.1. FUNCIONAMIENTO DEL PROTOTIPO

Los resultados del funcionamiento del prototipo, se establecen a partir de un conjunto de datos de prueba, y se muestra ejemplificado para la variable de humedad en un invernadero, teniéndose en cuenta que la forma de funcionamiento es igual para los otros tres escenarios. El archivo que contiene los datos de las 48 horas anteriores debe estar en formato csv, y puede ser importado desde cualquier entorno que lo permita, como un formulario web o directamente de un microcontrolador, el archivo de datos se muestra en la Fig. 10.1, donde contiene por cada hora los siguientes datos en este orden:

- Marca temporal.
- Humedad ambiente.
- Temperatura ambiente.
- Humedad en el invernadero.
- Temperatura en el invernadero.

Predicción de humedad y temperatura en invernaderos usando métodos de optimización para conjuntos difusos (respuestas)

Archivo Editar Ver Insertar Formato Datos Herramientas Formulario Complementos Ayuda [Todos los cambios se han guardado en Drive](#)

100% € % .0 .00 123 Predetermi... 10 B I S A

	A	B	C	D	E	F	G	H
1	Marca temporal	Humedad en el ambiente (0%-100%)	Temperatura en el ambiente (-30°C...60°C)	Humedad en el invernadero (0%-100%)	Temperatura en el invernadero (-30°C...60°C)			
2	3/02/2020 9:30:00	87.2	9.6	49.4	23.8			
3	3/02/2020 10:30:00	87.1	9.5	50.5	22.4			
4	3/02/2020 11:30:00	87.2	9.6	51.7	21.3			
5	3/02/2020 12:30:00	87.3	10.5	53.3	20.4			
6	3/02/2020 13:30:00	87.3	10.5	54.2	19.6			
7	3/02/2020 14:30:00	87.5	10.7	54.8	18.8			
8	3/02/2020 15:30:00	87.7	12.4	56.2	18.2			
9	3/02/2020 16:30:00	87.9	12.5	56.5	17.6			
10	3/02/2020 17:30:00	83.6	13.5	57.3	17			
11	3/02/2020 18:30:00	79.3	14.4	58.1	16.5			
12	3/02/2020 19:30:00	75	12.3	59.6	16			
13	3/02/2020 20:30:00	77.7	12	57.7	17.3			
14	3/02/2020 21:30:00	76.6	12.3	55.5	20			
15	3/02/2020 22:30:00	75.6	12.6	53.2	22.7			
16	3/02/2020 23:30:00	76.6	12.3	50.5	26.2			
17	4/02/2020 0:30:00	79	12.1	45.1	29.7			
18	4/02/2020 1:30:00	80.3	11.8	43.8	31.3			
19	4/02/2020 2:30:00	82.3	14.1	42.7	31			
20	4/02/2020 3:30:00	84.4	13.5	40.7	31.4			
21	4/02/2020 4:30:00	86.4	12.3	37.6	32			
22	4/02/2020 5:30:00	86	12.1	25.7	45.4			
23	4/02/2020 6:30:00	85.5	12	28.2	35.3			
24	4/02/2020 7:30:00	84.5	11.5	34	29.1			
25	4/02/2020 8:30:00	84	10.7	38.5	26.2			
26	4/02/2020 9:30:00	82.9	10.8	41.6	24.3			

Fig. 10.1: Datos de humedad y temperatura del ambiente e invernadero. Elaboración propia.

Al abrir el aplicativo en la parte superior, se encontrara un menú de tres opciones: “Aplicación”, “Interpretación” y “Acerca de nosotros”, en la opción “Aplicación”, en la parte superior se habilitara la opción de carga del archivo de datos de 48 horas, al dar clic a esta opción como se muestra en la Fig. 10.2, se desplegara el explorador de archivos donde escogeremos el archivo con los datos.

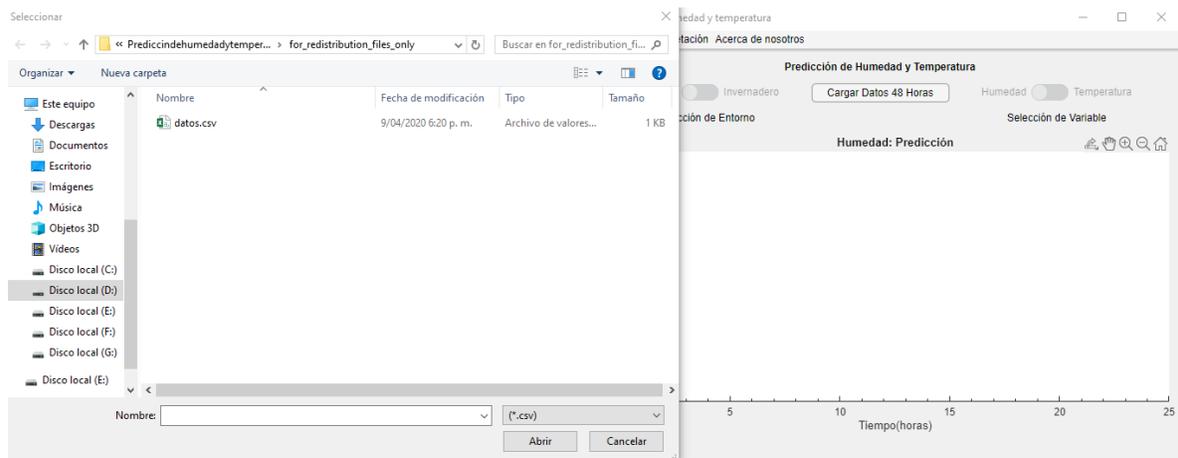


Fig. 10.2: Carga de datos 48 horas. Elaboración propia. (Entorno MATLAB®)

Al cargar el archivo con los datos se habilitaran las opciones de predicción, como se muestra en la Fig. 10.3, donde se puede cambiar la selección del entorno teniendo fija la variable de predicción o seleccionando la variable y dejando fijo el entorno de medición.

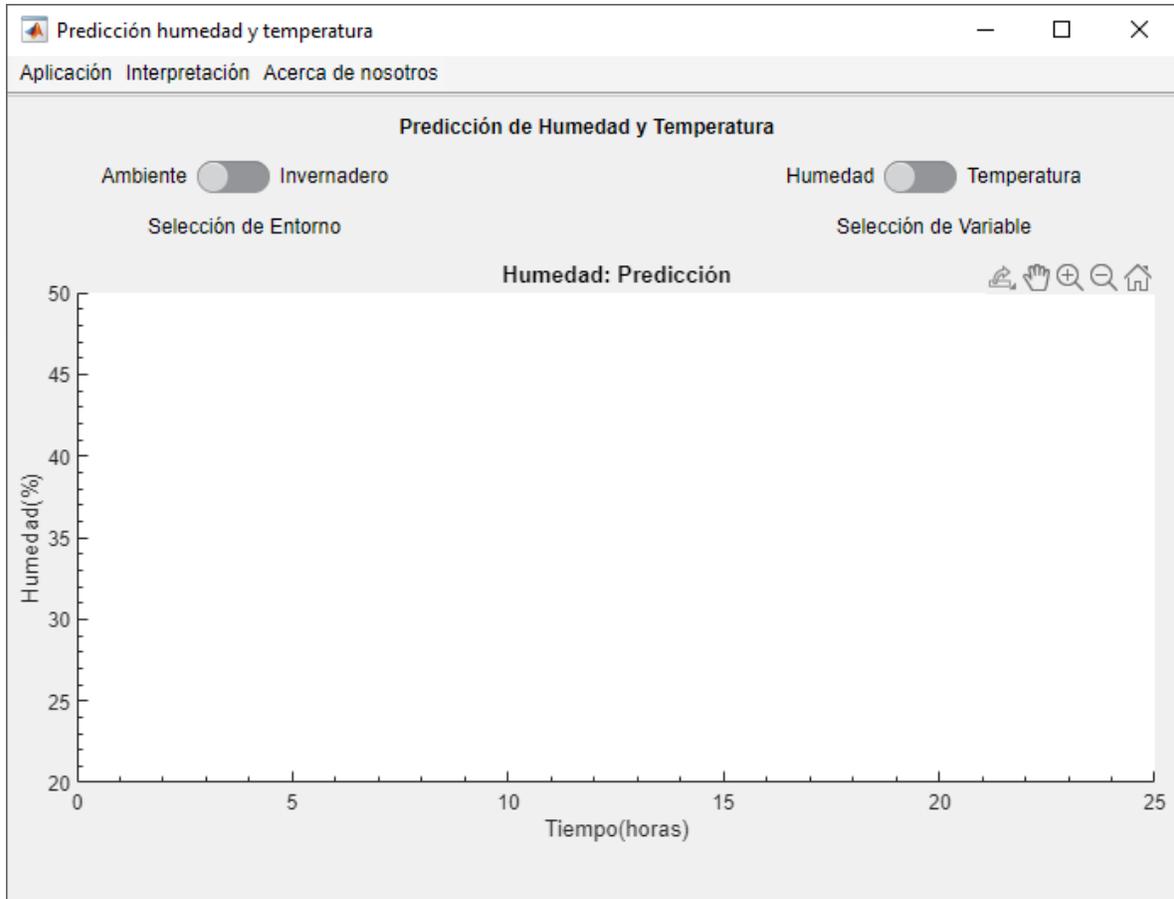


Fig. 10.3: Interfaz prototipo de visualización. Elaboración propia. (Entorno MATLAB®)

Al seleccionar el entorno o la variable deseada, se realizara la predicción de las próximas 24 horas como se muestra en la Fig. 10.4, donde en la parte inferior de manera gráfica se desplegara la predicción de las 24 horas siguientes a los datos suministrados, acompañada del error de predicción que nos produjo este modelo después de la optimización de los valores de los conjuntos difusos para la variable y entorno seleccionados.

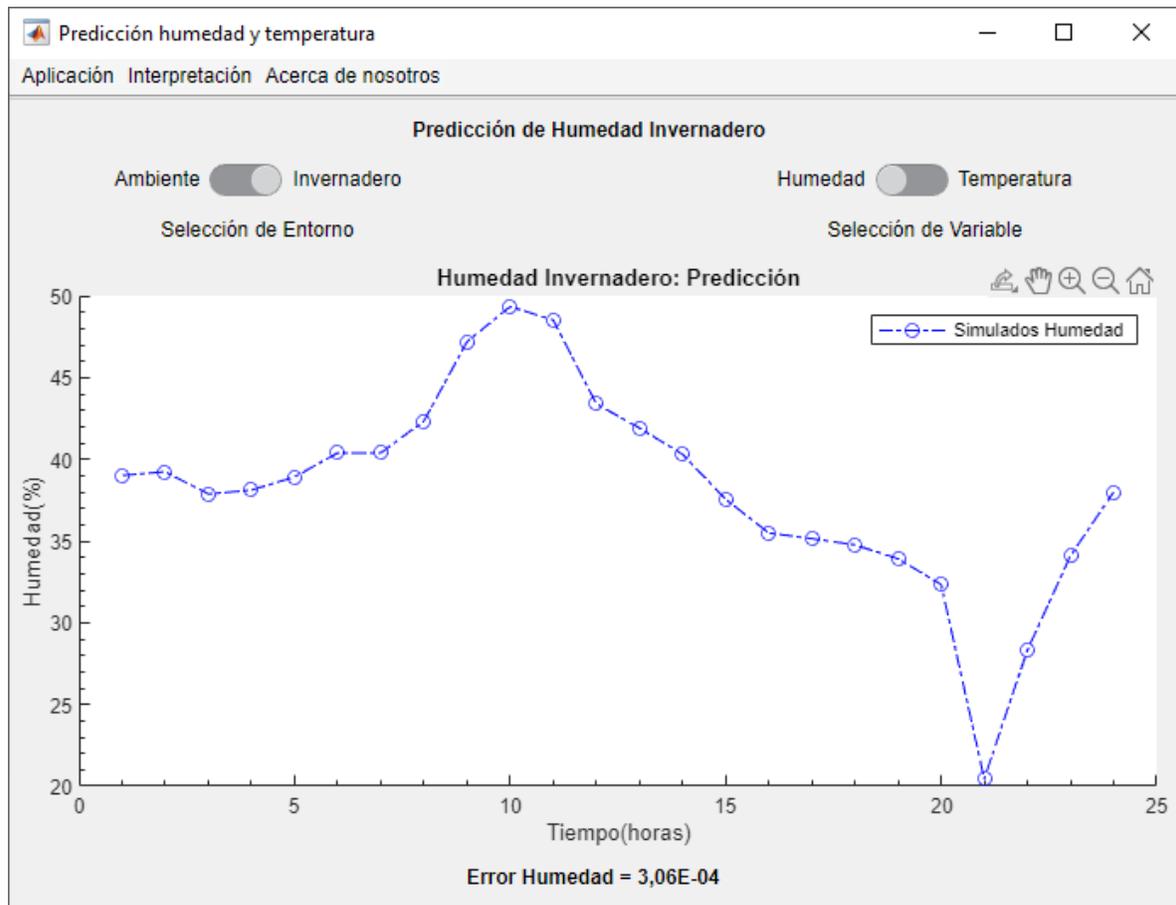


Fig. 10.4: Prototipo de visualización, predicción de humedad en un invernadero. Elaboración propia. (Entorno MATLAB®)

La interpretación de los resultados se muestra en la opción "Interpretación", como se evidencia en la Fig. 10.5, se encuentra de manera gráfica los conjuntos difusos obtenidos, con sus funciones de pertinencia de valores alto, medio y bajo, para los dos días anteriores a la predicción y el perteneciente al día de la misma en cada uno de los dos escenarios propuestos: ambiente e invernadero. En la parte superior izquierda se encuentra un dial con las opciones cualitativas para la variable en el día de predicción, con el cual se mostrarán las reglas del sistema de inferencia difuso y que valores cualitativos se tienen en los dos días anteriores para obtener este valor en el día de predicción.

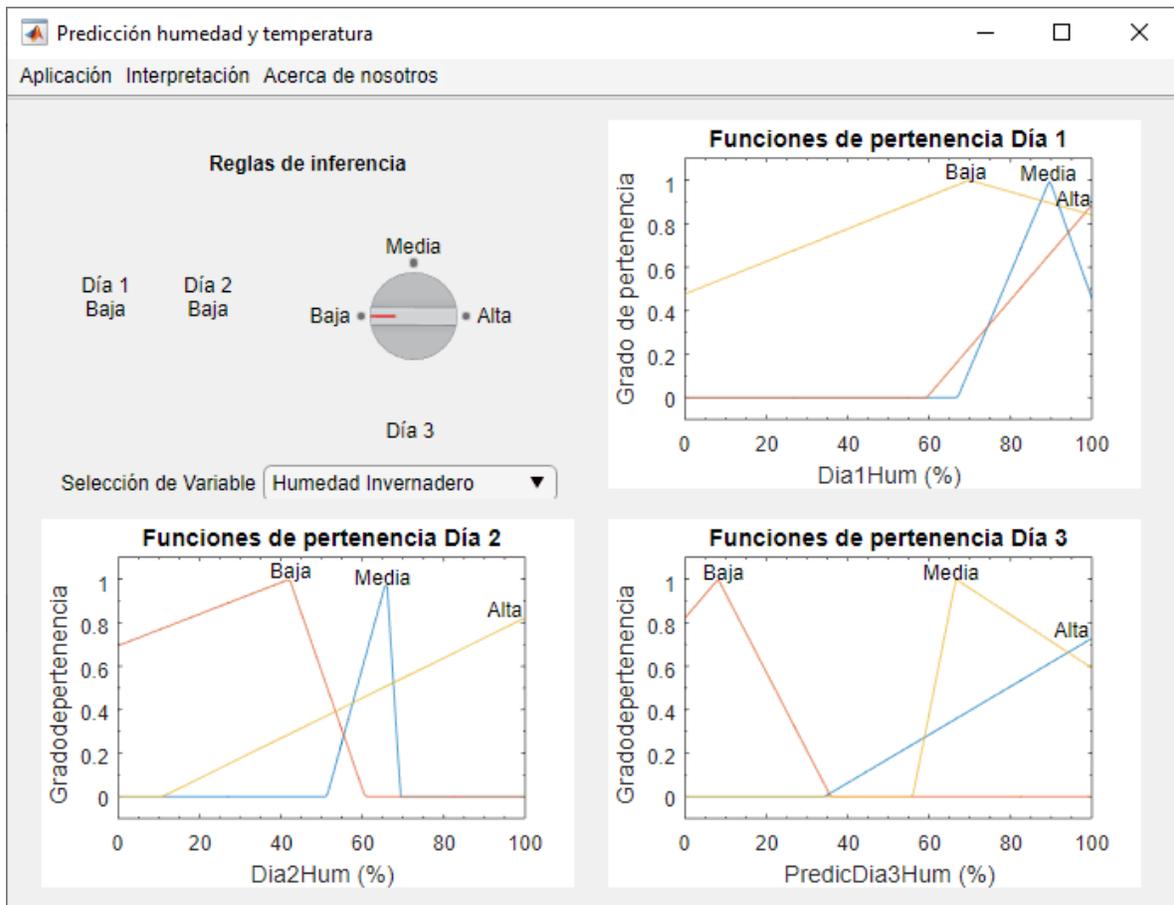


Fig. 10.5: Prototipo de visualización, conjuntos difusos humedad en un invernadero. Elaboración propia. (Entorno MATLAB®)

## 10.2. DESPLIEGUE DEL PROTOTIPO

El prototipo desarrollado posee un alto grado de usabilidad y portabilidad, es por ello que se desarrollan dos propuestas de despliegue, detalladas en esta sección, una aplicación de escritorio y el prototipo como una aplicación web.

### 10.2.1. Aplicación de escritorio

El prototipo de visualización, como se muestra en la Fig. 10.6, se desplegará como un ejecutable "Prediccion\_humedad\_y\_temperatura.exe", acompañado de: una imagen de icono "splash.png", un archivo con los requisitos para su ejecución "readme.txt" y el archivo que contiene los datos de prueba utilizados "datos.csv".

 <b>datos.csv</b>	Archivo de valores...	1 KB
 <b>Prediccion_humedad_y_temperatura.exe</b>	Aplicación	2.796 KB
 <b>readme.txt</b>	Documento de te...	2 KB
 <b>splash.png</b>	Archivo PNG	38 KB

Fig. 10.6: Archivos de despliegue prototipo de visualización. Elaboración propia.

Si no se dispone de estos requisitos, se incluirá un archivo denominado “MyAppInstaller\_mcr.zip”, que permitirá instalar el entorno de ejecución del aplicativo.

### 10.2.2. Aplicación Web

Para acceder a la aplicación web se accederá a la url del servidor, como se muestra en la Fig. 10.7, allí se mostrara el menú principal donde se verán los detalles de la aplicación entre los que se encuentran el nombre, los autores, una breve descripción y la versión del aplicativo.



Fig. 10.7: Servidor de aplicaciones Web. Elaboración propia. (Entorno MATLAB®)

Al acceder a la aplicación web, como se detalla en la Fig. 10.8, se mostrara la interfaz del aplicativo, y se podrá re-dimensionar con la opción de la parte inferior derecha, la cual se debe accionar si posee problemas de visualización o ausencia de contenido para que se adapte a su resolución de pantalla.

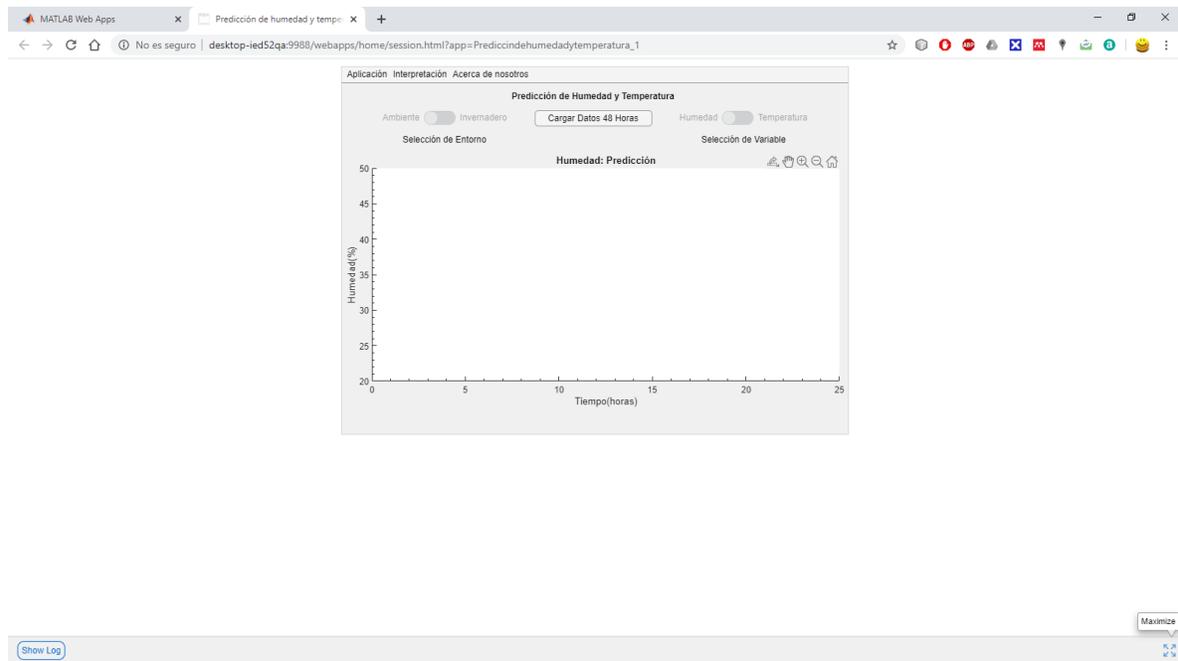


Fig. 10.8: Prototipo como aplicación Web. Elaboración propia. (Entorno MATLAB®)



## Capítulo 11

# CONCLUSIONES

Partiendo del diseño de dos propuestas de conjuntos difusos para humedad y temperatura, de sistemas de inferencia difusa tipo Mamdani y Sugeno, con 3 curvas respectivamente en su entrada que representan los valores bajo, medio y alto, se generan 8 modelos con alto nivel de interpretabilidad y precisión, que permiten predecir los valores de humedad y temperatura tanto para el ambiente como para un entorno cerrado, en este caso un invernadero.

Según los resultados obtenidos, la mejor predicción de las variables de humedad y temperatura para el ambiente como en un invernadero se realiza mediante una configuración de sistema de inferencia difusa tipo Mamdani optimizado mediante método de Cuasi-Newton, con un valor de MSE, en el ambiente, de  $1,21E-04$  para humedad y  $2,03E-03$  para temperatura, y en un invernadero, de  $3,06E-04$  para humedad y  $3,98E-05$  para temperatura. Es importante destacar que los valores iniciales para el conjunto difuso utilizados en optimización Cuasi-Newton son obtenidos a través de optimización por algoritmo genético, lo cual relaciona la búsqueda de una solución global mediante algoritmo genético como base para un mejoramiento en la misma con una búsqueda local mediante métodos exactos como Cuasi-Newton.

El método de predicción propuesto presenta una alta fiabilidad, al brindar mayor precisión en el cálculo, permitiendo que los valores obtenidos puedan ser usados posteriormente en técnicas de control o prevención de daños en cultivos, ocasionados por cambios en la humedad y temperatura. Esto se encuentra sustentado en los resultados alcanzados, donde se establece un porcentaje de efectividad, en el ambiente, de 98.9% para humedad y 95,49% para temperatura, y en un invernadero, de 98.25% para humedad y 99,37% para temperatura. Se evidencia que la predicción de valores de temperatura en los invernaderos mejora respecto a la obtenida mediante el ambiente, esto se explica por las pocas variaciones que la temperatura sufre en ambientes cerrados.

Al presentar una solución usando conjuntos difusos se mantiene gran interpretabilidad del sistema, relacionando valores de humedad y temperatura con significados cualitativos altos, medios y bajos. La característica cualitativa de los datos permite, a las personas que no tienen conocimientos espe-

cializados, entender de manera clara la dinámica del sistema, facilitando la configuración y gestión correcta de posibles actuadores que cambien los parámetros de humedad y temperatura interna en los invernaderos para mantener las condiciones adecuadas en el entorno del cultivo.

## Capítulo 12

# PROSPECTIVA DEL TRABAJO DE GRADO

En este apartado se realiza un análisis de la proyección e impacto alcanzados con los resultados obtenidos del proceso de investigación realizado para el proyecto de grado, señalando productos obtenidos, líneas de investigación y trabajos futuros, con el objeto de establecer nuevas rutas de trabajo que permitan enriquecer, desde otros enfoques, el conocimiento que se tiene sobre la problemática abordada.

### 12.1. PRODUCTOS

En este apartado se muestran los productos resultado del proceso investigativo acerca de la temática trabajada en el proyecto de investigación, dividiendo los mismos en productos alcanzados, en desarrollo y aprobados.

#### 12.1.1. ARTÍCULOS

- Análisis temático de principios de automatización en el desarrollo de cultivos hidropónicos. Boletín Semillas Ambientales. ISSN: 2463-0691.
- Ambiente para el cultivo de vegetales gestionado por un microcontrolador. Revista Espacios. ISSN: 0798-1015, aprobado para publicación.
- Predicción de humedad y temperatura en invernaderos usando métodos de optimización para conjuntos difusos, en elaboración.

### 12.1.2. PONENCIAS EN EVENTOS CIENTÍFICOS

- Ponencia y artículo en memoria: Ambiente controlado mediante Arduino para el cultivo de hortalizas. *VI Congreso Internacional del Medio Ambiente y Desarrollo Sostenible.*
- Ponencia y poster: Aspectos de Automatización Aplicados a Cultivos Hidropónicos. *XVI Encuentro Regional de Semilleros de Investigación - Nodo Bogotá Cundinamarca.*
- Prototipo de control térmico aplicado a cultivos hidropónicos. *III Congreso Internacional de Tecnologías Limpias, IV Seminario Internacional de Saneamiento, Ambiente y Desarrollo y III Seminario Nacional de Gestión y Control de la Contaminación Ambiental.*
- Análisis Temático de Principios de Automatización en el Desarrollo de Cultivos Hidropónicos. *VIII Encuentro de Semilleros de Investigación.*

### 12.1.3. REGISTRO DE SOFTWARE Y PROPIEDAD INTELECTUAL

- “Prediccion\_humedad\_y\_temperatura”. Registro de derechos de autor del prototipo de software elaborado para este proyecto.
- Prototipo de invernadero para el cultivo de vegetales gestionado por un microcontrolador, en estudio con la Oficina de Transferencias de Resultados de Investigación (OTRI) como producto para la explotación industrial.

## 12.2. LÍNEAS DE INVESTIGACIÓN FUTURAS

Actualmente debido a los efectos del cambio climático y las acciones del hombre para enfrentarlo, son muchas las aplicaciones tecnológicas que se están implementando o diseñando para mejorar los procesos de siembra y recolección de alimentos. Dentro del campo de las aplicaciones tecnológicas, se encuentra el enfoque de la inteligencia artificial, desde donde se pueden abordar diversos problemas de alta complejidad inherentes a la siembra y que permitan un alto grado de desarrollo de esta, desde la predicción de las condiciones ambientales para acciones de control, como la detección y prevención de enfermedades, la planeación de las condiciones ideales del terreno y los tiempos de siembra más adecuados, la vigilancia del cultivo, y terminar en una automatización de todas las tareas relacionadas a la misma.

## 12.3. TRABAJOS DE INVESTIGACIÓN FUTUROS

Dentro de los trabajos de investigación futuros, el modelo existente está configurado para las condiciones climáticas de un invernadero de la ciudad de Bogotá D.C. en condiciones ambientales neutras, este

puede ser reconfigurado o adaptado para funcionamiento en condiciones climáticas de cualquier tipo y sin depender del fenómeno climático que atraviese el territorio. Para esto se proponen dos alternativas el uso de periodos de entrenamiento según se atraviese el fenómeno climático, y así tener un conjunto de modelos funcionales dependiendo del fenómeno atravesado o la reconfiguración autónoma del modelo, a partir de datos almacenados previamente, mediante un proceso de optimización cada vez que se detecte un error creciente en la predicción. Posteriormente se puede realizar una vinculación entre el método de predicción con estrategias de control para automatizar ciertas tareas de riego, o disipación de calor, mediante un conjunto de sensores y actuadores en el invernadero.



# GLOSARIO

**Alpha ( $\alpha$ )** Intervalo de confianza. Es el grado de certeza (o probabilidad), con el que se desea realizar la estimación de un parámetro a través de un estadístico muestral.

**Conjunto difuso** Un conjunto difuso es un conjunto sin un límite nítido y claramente definido. Puede contener elementos con solo un grado parcial de pertenencia.

**Defuzzificación** Es el proceso mediante el cual se obtiene un valor cuantificable, a partir de conjuntos difusos y sus correspondientes grados de pertenencia.

**Función de activación** Define la salida de un nodo dada una entrada o un conjunto de entradas, normalmente el conjunto de valores de salida se encuentra en un rango determinado.

**Función de pertenencia** Es una función que permite identificar el grado en que cada elemento de un universo dado, pertenece a dicho conjunto.

**Fuzzificación** Es el proceso mediante el cual se toman las entradas de un sistema de inferencia y se determina el grado al que pertenecen cada uno de los conjuntos difusos apropiados, a través de funciones de pertenencia, equivale a una búsqueda en una tabla o una evaluación de la función.

**Grado de pertenencia** Corresponde al grado difuso de pertenencia en el conjunto lingüístico calificado (siempre el intervalo de 0 a 1) para una entrada con valor numérico nítido limitado al universo del discurso.

**MSE** Error Medio Cuadrático.

**Método de agregación** La agregación es el proceso mediante el cual los conjuntos difusos que representan los resultados de cada regla se combinan en un solo conjunto difuso. Se admiten tres métodos integrados: max (máximo), probor (probabilístico OR), sum (suma de los conjuntos de salida de la regla).

**Método de implicación** Es un método para obtener una ponderación adecuada de las características lingüísticas que se obtienen a partir de un antecedente, que corresponde a un número único, y un consecuente, que hace alusión a un conjunto difuso. Utiliza el método AND: min (mínimo),

que trunca el conjunto difuso de salida, o prod (producto), el cual escala el conjunto difuso de salida.

**Método de Kruswal-Wallis** Es un método no paramétrico para determinar si un grupo de datos proviene de la misma distribución. Se usa cuando el conjunto de datos analizados no corresponde a una distribución normal.

**p-value** Corresponde al valor de probabilidad determinado por la prueba de Kruskal-Wallis que al contrastarse con un intervalo de confianza, permite determinar la validez de una hipótesis nula, establecida previamente, con relación a la distribución de los datos analizados.

**Regla de inferencia** Se utilizan para formular las declaraciones condicionales que comprenden la lógica difusa a partir de los conjuntos y operadores difusos.

**RMSE** Raíz del Error Medio Cuadrático.

**Sistema de inferencia difusa** Consiste en un sistema en el cual los rangos de las variables sobre los cuales representan sus estados (o, al menos, algunas de ellas) involucran conjuntos difusos.

**Superficie de reglas** Es un mapa de superficie de salida para el sistema de inferencia difusa para ver la dependencia de una de las salidas en una o dos de las entradas.

# BIBLIOGRAFÍA

- Adriyendi. (2018). Fuzzy Logic using Tsukamoto Model and Sugeno Model on Prediction Cost. *I.J. Intelligent Systems and Applications*, 6, 13-21.
- Ariani, F. & Endra, R. Y. (2013). IMPLEMENTATION OF FUZZY INFERENCE SYSTEM WITH TSUKAMOTO METHOD FOR STUDY PROGRAMME SELECTION, Bandar Lampung.
- Auken, E., Boesen, T. & Christiansen, A. V. (2017). Review of Airborne Electromagnetic Methods With Focus on Geotechnical and Hydrological Applications From 2007 to 2017. En *Advances in Geophysics* (pp. 47-93). Elsevier.
- Ballabrera, J. (2010). *Módulo I: Motores de la Biosfera Capítulo 11 Modelos generales de circulación oceánica* (inf. téc.).
- Boisson, D. (1991). Etudes de la climatisation de serres par ventilation naturelle, en periode estivale : modélisations et simulations. <http://www.theses.fr>.
- Bryan, K. (2017). Rose-Hulman Institute of Technology. <https://www.rose-hulman.edu/~bryan/lottamath/quasinewton.pdf>
- Calp, M. H. (2018). İşletmeler için Personel Yemek Talep Miktarının Yapay Sinir Ağları Kullanılarak Tahmin Edilmesi. *Journal of Polytechnic*. <https://doi.org/10.2339/politeknik.444380>
- Castañeda-Miranda, A. & Castaño, V. M. (2017). Smart frost control in greenhouses by neural networks models. *Computers and Electronics in Agriculture*, 137, 102-114.
- Chaabane, D.-E. (1986). Influence d'un écran thermique sur le microclimat nocturne d'une serre agricole. <http://www.theses.fr>.
- Chen, L., Zhang, B., Yao, F. & Cui, L. (2016). Modeling and simulation of a solar greenhouse with natural ventilation based on error optimization using fuzzy controller, Chengdu.
- Czabanski, R., Jezewski, M. & Leski, J. (2017). Introduction to Fuzzy Systems. En P. Prokopowicz, J. Czerniak, D. Mikołajewski, Ł. Apiecionek & D. Śl zak (Eds.), *Theory and Applications of Ordered Fuzzy Numbers A Tribute to Professor Witold Kosiński* (pp. 23-43). Springer.
- Fernández, R., López-Morales V, Lafont F, Enea G & Duplaix J. (2010). *Una estructura neurodifusa para modelar la evapotranspiración instantánea en invernaderos A Neurofuzzy Structure Modelling Evapotranspiration in a Greenhouse Crop* (inf. téc.).
- Fourati, F. (2014). Multiple neural control of a greenhouse. *Neurocomputing*, 139, 138-144.
- Gharabaghi, B., Bonakdari, H. & Ebtehaj, I. (2019). Hybrid evolutionary algorithm based on PSOGA for ANFIS designing in prediction of no-deposition bed load sediment transport in sewer pipe,

- En *Advances in Intelligent Systems and Computing*, Springer Verlag. [https://doi.org/10.1007/978-3-030-01177-2\\_8](https://doi.org/10.1007/978-3-030-01177-2_8)
- Gobierno de Canada. (2019). Climate models - Canada.ca. Recuperado el 15 de noviembre de 2019, desde <https://www.canada.ca/en/environment-climate-change/services/climate-change/science-research-data/modeling-projections-analysis/centre-modelling-analysis/models.html>
- Gómez Vargas, E., Obregón Neira, N. & Socarras Quintero, V. (2010). Aplicación del modelo neuro-difuso ANFIS vs redes neuronales, al problema predictivo de caudales medios mensuales del río Bogotá en Villapinzón. *Tecnura*, 14(27), 18-29. <https://doi.org/10.14483/22487638.6695>
- Guo, P., Wang, X. & Han, Y. (2010). The Enhanced Genetic Algorithms for the Optimization Design, Yantai, China, Institute of Electrical; Electronics Engineers.
- IDEAM - Instituto de Hidrología, Meteorología y Estudios Ambientales. (2019). Pronósticos y Alertas. <http://www.pronosticosyalertas.gov.co/informacion-diaria-de-precipitacion-y-temperatura-de-los-principales-aeropuertos-del-pais>
- Isanta Navarro, R. (s.f.). Annex 1 Introduction to Neural Networks and Adaptive Neuro-Fuzzy Inference Systems (ANFIS). <https://upcommons.upc.edu/bitstream/handle/2099.1/20296/Annex%5C%201%5C%20-%5C%20Introduction%5C%20to%5C%20Adaptive%5C%20Neuro-Fuzzy%5C%20Inference%5C%20Systems%5C%20%5C%28ANFIS%5C%29.pdf>
- Izquierdo, S. S. & Izquierdo, L. R. (2018). Mamdani Fuzzy Systems for Modelling and Simulation: A Critical Assessment. *Journal of Artificial Societies and Social Simulation (JASSS)*, 21.
- Jang, J. S. R. (1993). ANFIS: Adaptive-Network-Based Fuzzy Inference System. *IEEE Transactions on Systems, Man and Cybernetics*, 23(3), 665-685. <https://doi.org/10.1109/21.256541>
- Jensen, D. B., Torn, M. S. & Harte, J. (1993). *In our own hands : a strategy for conserving California's biological diversity*. University of California Press.
- Kang, M., Fan, X., Hua, J., Wang, H., Wang, X. & Wang, F. (2018). Managing Traditional Solar Greenhouse With CPSS: A Just-for-Fit Philosophy. *IEEE Transactions on Cybernetics*, 48, 3371-3380.
- Klir, G. J. & Yuan, B. (1995). *Fuzzy Sets and Fuzzy Logic Theory and Applications*. New Jersey, Prentice Hall PTR.
- Knapp, R. B. (2007a). *Fuzzy Sets and Pattern Recognition - Adaptive Fuzzy* (inf. téc.).
- Knapp, R. B. (2007b). *Fuzzy Sets and Pattern Recognition - Fuzzy inference systems* (inf. téc.).
- Lambers, J. (2011a). MAT 419/519 Optimization in Mathematical Programming. <https://www.math.usm.edu/math/lambers/mat419/lecture11.pdf>
- Lambers, J. (2011b). MAT 461/561 Numerical Analysis II. <https://www.rose-hulman.edu/~bryan/lottamath/quasineutron.pdf>
- Lenka, S. K. & Mohapatra, A. G. (2015). Gradient Descent with Momentum based Neural Network Pattern Classification for the Prediction of Soil Moisture Content in Precision Agriculture, Indore.
- LOPEZ-CRUZ, I. L., Rojano-Aguilar, A., Ojeda-Bustamante, W. & Salazar-Moreno, R. (2007). Modelos Arx para predecir la temperatura del aire de un invernadero: una metodología. *Agrociencia*, 41, 181-192. [http://www.scielo.org.mx/scielo.php?script=sci%7B%5C\\_%7Darttext%7B%5C%7Dpid=S1405-31952007000200181%7B%5C%7Dnrm=iso](http://www.scielo.org.mx/scielo.php?script=sci%7B%5C_%7Darttext%7B%5C%7Dpid=S1405-31952007000200181%7B%5C%7Dnrm=iso)

- Manabe, S., Smagorinsky, J., Strickler, R. F., Manabe, S., Smagorinsky, J. & Strickler, R. F. (1965). *December 1965 SIMULATED CLIMATOLOGY OF A GENERAL CIRCULATION MODEL WITH A HYDROLOGIC CYCLE* (inf. téc.).
- Martín, J. D. (2000). Implementación de Redes Neuro-Difusas para ser Aplicadas en Problemas de Clasificación y Modelización by, 1-25.
- Mathews, J. H. (2005). Broyden's Method - Numerical Analysis - Numerical Methods. <http://mathfaculty.fullerton.edu/mathews/n2003/BroydenMethodMod.html>
- MathWorks Inc. (2019). Mamdani and Sugeno Fuzzy Inference Systems - MATLAB and Simulink. <https://www.mathworks.com/help/fuzzy/types-of-fuzzy-inference-systems.html;jsessionid=85440d09d9bbf94114e051a26dae#d117e2400>
- Mehran, K. (2008). Takagi-Sugeno Fuzzy Modeling for Process Control. <https://www.staff.ncl.ac.uk/damian.giaouris/pdf/IA%5C%20Automation/Ts%5C%20FL%5C%20tutorial.pdf>
- NASA. (2019). NASA Earth Observatory - Newsroom.
- NETO, O. C. D. R., TEIXEIRA, A. D. S., BRAGA, A. P. D. S., SANTOS, C. C. D. & LEÃO, R. A. D. O. (2015). Application of artificial neural networks as an alternative to volumetric water balance in drip irrigation management in watermelon crop. *Journal of the Brazilian Association of Agricultural*, 35, 266-279.
- Nocedal, J. & Wright, S. J. (2006). *Numerical Optimization*. Springer.
- Nugroho, L. E., Pratama, A. G. H., Mustika, I. W. & Ferdiana, R. (2017). Development of monitoring system for smart farming using Progressive Web App, En *2017 9th International Conference on Information Technology and Electrical Engineering (ICITEE)*, Phuket.
- Outanoute, M., Lachhab, A., Ed-dahhak, A., Selmani, A., Guerbaoui, M. & Bouchikhi, B. (2015). A neural network dynamic model for temperature and relative humidity control under greenhouse, Agadir.
- Palomo Del Barrio, E. (1992). *DESARROLLO DE UNA METODOLOGÍA TEÓRICO EXPERIMENTAL DE CARACTERIZACIÓN DE INVERNADEROS* (inf. téc.).
- Perangin-angin, M. I., Fitriani, W., Mayasari, N. & Putera Utama Siahaan, A. (2016). Tuition Reduction Determination Using Fuzzy Tsukamoto. *International Journal of Engineering Science Invention*, 5, 68-72.
- Pressman, R. S. (2019). *SOFTWARE ENGINEERING: A PRACTITIONERS APPROACH* (Novena). McGraw-Hill Education.
- Putro, S., Mustika, I. W. & Nugroho, L. E. (2018). Optimized Back-propagation Artificial Neural Network Algorithm for Smart Agriculture Applications, Yogyakarta.
- Rao, S. (2009). *Engineering Optimization Theory and Practice*. Hoboken, NJ, John Wiley; Sons Inc.
- Rodríguez Díaz, F. (2005). *Modelado y control jerárquico de crecimiento de cultivos en invernadero : tesis doctoral*. Universidad de Almería, Servicio de Publicaciones.
- Ross, T. J. (2010). *Fuzzy Logic with Engineering Applications*. John Wiley; Sons, Ltd.
- Saha, S., Moorthi, S., Pan, H.-L., Wu, X., Wang, J., Nadiga, S., Tripp, P., Kistler, R., Woollen, J., Behringer, D., Liu, H., Stokes, D., Grumbine, R., Gayno, G., Wang, J., Hou, Y.-T., Chuang, H.-y., Juang, H.-M. H., Sela, J., ... Goldberg, M. (2010). The NCEP Climate Forecast System

- Reanalysis. *Bulletin of the American Meteorological Society*, 91(8), 1015-1058. <https://doi.org/10.1175/2010BAMS3001.1>
- Seydi Ghomsheh, V., Aliyari Shoorehdeli, M. & Teshnehlab, M. (2007). Training ANFIS structure with modified PSO algorithm, En *2007 Mediterranean Conference on Control and Automation, MED*. <https://doi.org/10.1109/MED.2007.4433927>
- Shing, J. & Jang, R. (1993). ANFIS : Adaptive-Network-Based Fuzzy Inference System. *IEEE TRANSACTIONS ON SYSTEMS, MAN, AND CYBERNETICS*, 23, 665-685.
- Stainforth, D. A., Aina, T., Christensen, C., Collins, M., Faull, N., Frame, D. J., Kettleborough, J. A., Knight, S., Martin, A., Murphy, J. M., Piani, C., Sexton, D., Smith, L. A., Splcer, R. A., Thorpe, A. J. & Allen, M. R. (2005). Uncertainty in predictions of the climate response to rising levels of greenhouse gases. *Nature*, 433(7024), 403-406. <https://doi.org/10.1038/nature03301>
- Suparta, W. & Alhasa, K. M. (2016). Modeling of Tropospheric Delays Using ANFIS, (2009), 5-19. <https://doi.org/10.1007/978-3-319-28437-8>
- Witten, I. H., Frank, E., Hall, M. & Pal, C. J. (2017). *Data Mining Practical Machine Learning Tools and Techniques*. Cambridge, MA, Elsevier Inc.
- Yue, Y., Quan, J., Zhao, H. & Wang, H. (2018). The Prediction of Greenhouse Temperature and Humidity Based on LM-RBF Network, Changchun.