

UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN
FACULTAD DE INGENIERÍA MECÁNICA Y ELÉCTRICA



TESIS

**ESTIMACIÓN DE LA TEMPERATURA EN UN MOLINO CONTINUO DE
LAMINACIÓN EN CALIENTE APLICANDO SISTEMAS DE CAJA GRIS
DIFUSOS**

POR

JOSÉ ANGEL BARRIOS GÓMEZ

**EN OPCIÓN AL GRADO DE DOCTOR EN
INGENIERÍA ELÉCTRICA**

MAYO, 2016

UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN
FACULTAD DE INGENIERÍA MECÁNICA Y ELÉCTRICA
SUBDIRECCIÓN DE ESTUDIOS DE POSGRADO



TESIS

**ESTIMACIÓN DE LA TEMPERATURA EN UN MOLINO CONTINUO DE
LAMINACIÓN EN CALIENTE APLICANDO SISTEMAS DE CAJA GRIS
DIFUSOS**

POR

JOSÉ ANGEL BARRIOS GÓMEZ

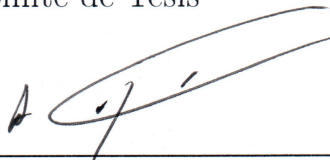
**EN OPCIÓN AL GRADO DE DOCTOR EN
INGENIERÍA ELÉCTRICA**

MAYO, 2016

UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN
FACULTAD DE INGENIERÍA MECÁNICA Y ELÉCTRICA
SUBDIRECCIÓN DE ESTUDIOS DE POSGRADO

Los miembros del comité de tesis recomendamos que la tesis
“Estimación de la temperatura en un molino continuo de laminación en
caliente aplicando sistemas de caja gris difusos” realizada por el alumno
MC. José Angel Barrios Gómez, matrícula número 1366001 sea aceptada por
su defensa como opción al grado de **Doctor** en Ingeniería Eléctrica.

El Comité de Tesis



Asesor
Dr. Alberto Cavazos González



Coasesor:
Dr. Gerardo Maximiliano Méndez



Coasesor:
Dr. Ernesto Vázquez Martínez



Coasesor:
Dr. Marco Tulio Mata Jiménez



Coasesor:
Dr. Jorge Ramírez Cuéllar



Vo. Bo.
Dr. Simón Martínez Martínez
Subdirector de Estudios de Posgrado

Cd. Universitaria, a Mayo del 2016

Agradecimientos

Un profundo y sincero agradecimiento a mis padres Angel Barrios Becerra y Adela Gómez Rivera, por estar conmigo, apoyo incondicional y todos los consejos que hasta este momento me siguen dando, gracias.

A mis hermanos Edwin Javier, Carlos Raúl y Arnoldo, les agradezco tantos buenos momentos vividos y los buenos consejos en todo momento.

A mi esposa Candibeth por su apoyo incondicional y por estar siempre a mi lado en los malos y buenos momentos, te doy las gracias y te brindo mi admiración por la excelente persona que eres, te amo por eso.

Para mis hijos Miguel Angel y Angel Sebastián, a ustedes les dedico mis esfuerzos y la culminación de esta tesis, recuerden que mis pensamientos están eternamente con ustedes.

Para mis tíos, Tono y Rome, Elsa, Librado y Magdalena, Israel y Celia, Guayo, Arsenio y Verónica, Epifanio y Rubí, les agradezco todos los consejos que en alguna ocasión cada uno me ha dado. Un especial agradecimiento a mi tío Israel (Q.E.D.), todavía lo extrañamos. A mis primos Azucena, Rogelio, Marco A., Yony, Ana Y., Juanca, Ulises, Oraida, Esdras, Librado, Fernando, Héctor, Oscar, Laura, Flor, Yaneidi, para ustedes un cordial agradecimiento por ser parte de mi vida.

Para mis abuelos Rogelio y Martha, Cecilia y Juan (Q.E.D.), a los que están y también a los que no, los quiero mucho y agradezco el apoyo incondicional.

Para mis amigos Pedro M., Félix R., Fernando, Alejandro por su apoyo y amistad incondicional. Para mis amigos de Chiapas Víctor H., Javier A., Heber B., Jorge L., Adolfo, Miguel O., a todos gracias por su amistad y compartir conmigo gran parte de mi vida.

Un sincero agradecimiento al Dr. Alberto Cavazos González que me brindó su confianza y apoyo, conocimientos y experiencia en el trayecto de la realización de esta tesis.

A mis coasesores, el Dr. Ernesto Vázquez, Dr. Marco Tulio Mata, Dr. Gerardo Maximiliano, Dr. Jorge Ramírez por sus acertadas recomendaciones, comentarios y el apoyo en la culminación de esta tesis.

A todos los profesores que me impartieron clases durante mí estancia en el postgrado de Ingeniería Eléctrica.

A la Facultad de Ingeniería Mecánica y Eléctrica.

Al CONACYT por el apoyo económico, tanto de la beca nacional como de la beca mixta.

Agradezco al ser supremo que permite la existencia de todas estas personas que quiero.

*"Nosotros, los mortales, logramos la inmortalidad
en las cosas que creamos en común
y que quedan después de nosotros"*

Albert Einstein

RESUMEN

Estimación de la temperatura en un molino continuo de laminación en caliente aplicando sistemas de caja gris difusos

Publicación No. _____

José Angel Barrios Gómez, M. C. en Ingeniería Eléctrica

Universidad Autónoma de Nuevo León, 2016

Profesor Asesor: Dr. Alberto Cavazos González

Este documento conforma la tesis de Doctor en Ingeniería Eléctrica, de la Facultad de Ingeniería Mecánica y Eléctrica, de la Universidad Autónoma de Nuevo León. El trabajo se centra en la Estimación de la temperatura en un molino continuo de laminación en caliente aplicando sistemas de caja gris difusos.

En la actualidad, en la industria de acero, específicamente en el área de laminación en caliente, las líneas de producción continuamente están expuestas a variaciones en los parámetros especificados para el producto que se desea obtener (cinta de acero). Por ello esta área requiere de sistemas de estimación de parámetros y controladores, capaces de adaptarse al proceso.

En un molino de laminación en caliente los planchones de acero se preparan térmicamente en un horno de recalentamiento, posteriormente, éstas atraviesan un rompedor de óxidos, un molino desbastador, una mesa de transferencia, un descascarado secundario y un molino continuo de laminación. Durante el proceso, los planchones de acero presentan pérdida de calor.

Existen cuatro parámetros de calidad importantes en el rollo de lámina de acero los cuales son el espesor, el ancho, la temperatura de acabado, y la temperatura de enrollado, estos dos últimos determinan las propiedades mecánicas de la lámina. La región más crítica del producto final es la punta y es donde se presenta un mayor desconocimiento de las condiciones de la barra. Una estimación adecuada de las variables de laminación de un producto determinado

es importante, ya que esto permite que los cuatro parámetros de calidad mencionados, estén dentro de las tolerancias especificadas en la parte de la cinta.

Dentro de las variables de rolado críticas en el molino continuo que se pueden presentar, se encuentra la temperatura superficial de las barras. La temperatura, que es medida por sensores infrarrojos, en la superficie de cada barra a la entrada del molino reversible y a la entrada del molino acabador, no es verdaderamente confiable, esto debido a la formación de óxidos, por lo que debe ser estimada con base en la medición a la salida del último pase del molino desbastador, en donde la superficie está limpia. En laminación de acero en caliente la estimación es crítica, para el cálculo de las referencias del molino, las cuales incluyen espacio entre rodillos y velocidades de los rodillos, estas acciones deben tomarse antes de que la barra entre al molino continuo y realizarse en el menor tiempo posible para evitar la pérdida de calor de la barra de acero.

En este proyecto de Tesis para la estimación de la temperatura utilizando sistemas de caja gris se llevara a cabo utilizando varias metodologías, para poder realizar la estimación de la temperatura se utilizaran datos reales de planta temperatura de entrada al molino y tiempo de traslado de la barra de acero. Tomando en cuenta que un sistema de caja gris esta compuesto por dos sistemas en nuestro caso uno físico y el otro difuso, las diferentes metodologías que se utilizaran son algoritmos de agrupamiento, el cual mediante una base de datos de entrada y salida, creara una base de reglas que nos formaran el sistema difuso, con el cual se realiza la estimación de la temperatura.

También sistemas difusos mamdani adaptable tipo 1 y tipo 2 son aplicados en la predicción de temperatura utilizando los mismos datos de entrada, para la etapa de simulación de todos estos sistemas, se utilizan bases de datos diferentes para entrenamiento y validación, por último se realizan comparaciones entre todos los sistemas diseñados y simulados.

Índice general

Resumen	v
Índice general	vii
Índice de tablas	xii
Índice de figuras	xviii
1. INTRODUCCIÓN	1
1.1. Planteamiento del problema	1
1.2. Objetivos	4
1.3. Estructura de la Tesis	5
2. ANTECEDENTES	7
2.1. Proceso de Laminación en caliente	7
2.1.1. Molino de laminación en caliente	8
2.2. Antecedentes sistemas difusos y caja Gris	10
2.3. Antecedentes Algoritmos de agrupamiento	14
2.4. Antecedentes Sistema Mamdani con adaptación (Neuro difuso)	15

2.5. Antecedentes Sistema Difusos tipo-2	16
2.5.1. Resumen y conclusiones	17
3. LÓGICA DIFUSA (“FUZZY LOGIC”)	18
3.1. Lógica difusa tipo-2	20
3.1.1. Conjuntos Difusos Tipo-2	21
3.1.2. Definiciones básicas	24
3.1.3. Operaciones de Conjuntos Difusos Tipo-2	27
3.1.4. Sistemas Difusos Tipo-2	31
3.1.5. Sistemas de lógica difusa Singleton Tipo-2	32
3.1.6. Sistemas Difusos Sugeno Tipo-2	38
3.2. Resumen	39
4. PRINCIPIOS DE ALGORITMOS DE AGRUPAMIENTOS DE DATOS	40
4.1. Introducción	40
4.2. Clusters K-means	41
4.3. Cluster C-means difusos	44
4.4. Resumen	47
5. APLICACIÓN DE SISTEMAS FCM Y MODELADO CON CAJA GRIS ADAPTABLES EN LA ESTIMACIÓN DE TEMPERATURA	48
5.1. Introducción	48
5.2. Modelo físico de la planta	49

5.3. Datos para la experimentación	50
5.4. Medidas de desempeño para el error de estimación	52
5.5. Generación de reglas difusas utilizando FCM	53
5.5.1. Obtención de sistemas difusos de 9 reglas utilizando FCM	54
5.5.2. Aplicación de FCM en la obtención de un sistema difuso de 25 reglas . .	60
5.6. Descripción de un modelo de Caja Gris	65
5.6.1. Modelado mediante Cajas Grises de la temperatura a la entrada del SB .	66
5.6.2. Arquitectura del sistema de Caja Gris difuso	66
5.6.3. Análisis de los sistemas difusos utilizando FCM.	67
5.7. Sistema Difuso Mamdani adaptable	69
5.7.1. Implementación y evaluación de un sistema Mamdani con Adaptación . .	69
5.7.2. Implementación y evaluación de un sistema de Caja Gris Mamdani con Adaptación	73
5.7.3. Implementación y evaluación de un sistema FCM Mamdani con Adaptación	78
5.7.4. Implementación y evaluación de un sistema de Caja Gris FCM Mamdani con Adaptación	82
5.8. Implementación y evaluación de sistemas difusos Tipo-2	86
5.8.1. Implementación y evaluación de un sistemas Mamdani tipo-2 con adap- tación	86
5.8.2. Implementación y evaluación de un sistema de Caja Gris Mamdani con Adaptación tipo-2	94

5.8.3. Implementación y evaluación de un sistemas FCM Mamdani tipo-2 con adaptación	101
5.8.4. Implementación y evaluación de un sistema de Caja Gris Mamdani FCM con Adaptación tipo-2	108
5.9. Resumen de resultados obtenidos	115
5.9.1. Resumen de resultados obtenidos para sistemas Fuzzy tipo-1	115
5.9.2. Comparación gráfica de resultados para sistemas Fuzzy tipo-1	116
5.9.3. Comparación gráfica de resultados para sistemas Fuzzy tipo-1 Caja Gris	117
5.9.4. Comparación gráfica de resultados para sistemas con FCM Fuzzy tipo-1	118
5.9.5. Comparación gráfica de resultados para sistemas Fuzzy tipo-1 con FCM Caja Gris	119
5.9.6. Resumen de resultados obtenidos para sistemas Fuzzy tipo-2	120
5.9.7. Comparación gráfica de resultados para sistemas Fuzzy tipo-2	121
5.9.8. Comparación gráfica de resultados para sistemas Fuzzy tipo-2 Caja Gris	122
5.9.9. Comparación gráfica de resultados para sistemas con FCM Fuzzy tipo-2	123
5.9.10. Comparación gráfica de resultados para sistemas Fuzzy tipo-2 con FCM Caja Gris	124
6. CONCLUSIONES	125
6.1. Contribuciones.	125
6.2. Conclusiones Generales	126
6.3. Trabajo a futuro.	127

Bibliografia**133**

Índice de tablas

5.1. Tabla de centroides para sistema de 9 reglas.	56
5.2. Tabla de parámetros del sistema mamdani y sugeno de 9 o 25 reglas, según sea el caso.	57
5.3. Tabla de centroides para sistema de 25 reglas.	62
5.4. Tabla de 9 reglas de un sistema FIS empírico.	68
5.5. Sistema base de 9 reglas empírico para generación de sistema Mamdani con adaptación.	70
5.6. Sistema Mamdani de 9 reglas con adaptación, generado a partir del sistema base.	71
5.7. Sistema base de 25 reglas empírico para generación de sistema Mamdani con adaptación.	72
5.8. Sistema Mamdani de 25 reglas con adaptación, generado a partir del sistema base.	73
5.9. Modelado con Caja Gris para un sistema base de 9 reglas empírico para generación de sistema Mamdani con adaptación.	74
5.10. Modelado con Caja Gris para un Sistema Mamdani de 9 reglas con adaptación, generado a partir del sistema base.	75

5.11. Modelado con Caja Gris para un Sistema base de 25 reglas empírico para generación de sistema Mamdani con adaptación.	76
5.12. Modelo de Caja Gris con Sistema Mamdani de 25 reglas con adaptación, generado a partir del sistema base.	77
5.13. Sistema base de 9 reglas FCM para generación de sistema Mamdani con adaptación.	78
5.14. Sistema Mamdani de 9 reglas con adaptación, generado a partir del sistema base FCM.	79
5.15. Sistema base de 25 reglas FCM para generación de sistema Mamdani con adaptación.	80
5.16. Sistema Mamdani de 25 reglas con adaptación, generado a partir del sistema base FCM.	81
5.17. Modelado con Caja Gris para un sistema base de 9 reglas empírico para generación de sistema Mamdani con adaptación.	82
5.18. Modelado con Caja Gris para un Sistema Mamdani de 9 reglas con adaptación, generado a partir del sistema base.	83
5.19. Modelado con Caja Gris para un Sistema base de 25 reglas FCM para generación de sistema Mamdani con adaptación.	84
5.20. Modelo de Caja Gris con Sistema Mamdani de 25 reglas con adaptación, generado a partir del sistema base.	85
5.21. Primeras funciones gaussianas para el Modelado de un Sistema base de 9 reglas empírico para generación de sistemas Mamdani tipo 2 con adaptación.	87

5.22. Segundas funciones gaussssianas para el Modelado de un Sistema base de 9 reglas empírico para generación de sistemas Mamdani typo 2 con adaptación.	88
5.23. Primeras funciones gaussssianas para el Modelado de un Sistema base de 9 reglas empírico para generación de sistemas Mamdani typo 2 con adaptación, generado a partir del sistema base.	88
5.24. Segundas funciones gaussssianas para el Modelado de un Sistema base de 9 reglas empírico para generación de sistemas Mamdani typo 2 con adaptación, generado a partir del sistema base.	89
5.25. Primeras gaussianas para el sistema base de 25 reglas empírico para generación de sistema Mamdani con adaptación.	90
5.26. Segundas gaussianas para el sistema base de 25 reglas empírico para generación de sistema Mamdani con adaptación.	91
5.27. Primeras gaussianas del sistema Mamdani de 25 reglas con adaptación, generado a partir del sistema base.	92
5.28. Segundas gaussianas del sistema Mamdani de 25 reglas con adaptación, generado a partir del sistema base.	93
5.29. Primera gaussiana del Modelado con Caja Gris para un Sistema base de 9 reglas empírico para generación de sistema Mamdani con adaptación tipo-2.	94
5.30. Segunda gaussiana del Modelado con Caja Gris para un Sistema base de 9 reglas empírico para generación de sistema Mamdani con adaptación tipo-2.	95
5.31. Primera gaussiana del Modelado con Caja Gris para un Sistema Mamdani tipo-2 de 9 reglas con adaptación, generado a partir del sistema base.	95

5.32. Segunda gaussiana del Modelado con Caja Gris para un Sistema Mamdani tipo-2 de 9 reglas con adaptación, generado a partir del sistema base.	96
5.33. Primera gaussiana del Modelado con Caja Gris para un Sistema base de 25 reglas empírico para generación de sistema Mamdani con adaptación tipo-2.	97
5.34. Segunda gaussiana del Modelado con Caja Gris para un Sistema base de 25 reglas empírico para generación de sistema Mamdani con adaptación tipo-2.	98
5.35. Primera gaussiana del Modelado con Caja Gris para Sistema Mamdani tipo-2 de 25 reglas con adaptación, generado a partir del sistema base.	99
5.36. Segunda gaussiana del Modelado con Caja Gris para Sistema Mamdani tipo-2 de 25 reglas con adaptación, generado a partir del sistema base.	100
5.37. Primeras funciones gaussianas para el Modelado de un Sistema base de 9 reglas FCM para generación de sistemas Mamdani tipo 2 con adaptación.	102
5.38. Segundas funciones gaussianas para el Modelado de un Sistema base de 9 reglas FCM para generación de sistemas Mamdani tipo 2 con adaptación.	102
5.39. Primeras funciones gaussianas para el Modelado de un Sistema base de 9 reglas FCM para generación de sistemas Mamdani tipo 2 con adaptación, generado a partir del sistema base.	103
5.40. Segundas funciones gaussianas para el Modelado de un Sistema base de 9 reglas empírico para generación de sistemas Mamdani tipo 2 con adaptación, generado a partir del sistema base.	103
5.41. Primeras gaussianas para el sistema base de 25 reglas FCM para generación de sistema Mamdani tipo 2 con adaptación.	104

5.42. Segundas gaussianas para el sistema base de 25 reglas FCM para generación de sistema Mamdani tipo 2 con adaptación.	105
5.43. Primeras gaussianas del sistema Mamdani de 25 reglas con adaptación, generado a partir del sistema base.	106
5.44. Segundas gaussianas del sistema Mamdani de 25 reglas con adaptación, generado a partir del sistema base.	107
5.45. Primera gaussiana del Modelado con Caja Gris para un Sistema base de 9 reglas FCM para generación de sistema Mamdani con adaptación tipo-2.	108
5.46. Segunda gaussiana del Modelado con Caja Gris para un Sistema base de 9 reglas FCM para generación de sistema Mamdani con adaptación tipo-2.	109
5.47. Primera gaussiana del Modelado con Caja Gris para un Sistema FCM Mamdani tipo-2 de 9 reglas con adaptación, generado a partir del sistema base.	109
5.48. Segunda gaussiana del Modelado con Caja Gris para un Sistema FCM Mamdani tipo-2 de 9 reglas con adaptación, generado a partir del sistema base.	110
5.49. Primera gaussiana del Modelado con Caja Gris para un Sistema base de 25 reglas FCM para generación de sistema Mamdani con adaptación tipo-2.	111
5.50. Segunda gaussiana del Modelado con Caja Gris para un Sistema base de 25 reglas FCM para generación de sistema Mamdani con adaptación tipo-2.	112
5.51. Primera gaussiana del Modelado con Caja Gris para Sistema Mamdani tipo-2 de 25 reglas con adaptación, generado a partir del sistema base.	113

5.52. Segunda gaussianiana del Modelado con Caja Gris para Sistema Mamdani tipo-2 de 25 reglas con adaptación, generado a partir del sistema base.	114
5.53. Medidas de desempeño de las diferentes estructuras de modelado de Caja Gris difusas, FIS y Modelo +PI en términos de error de predicción para todos los sistemas diseñados.	116
5.54. Medidas de desempeño para las diferentes estructuras difusas, Caja Gris difusas, y Modelo +PI en términos de error de predicción para los sistemas diseñados de forma empíricas.	121

Índice de figuras

1.1. Esquema de un molino de laminación en caliente con el diagrama de bloque de la predicción de temperatura.	2
1.2. Modelo físico con una estructura de compensación PI.	3
2.1. Proceso de laminación en caliente.	8
3.1. Un conjunto difuso tipo-2 que representa un conjunto difuso tipo-1 con una desviación estándar con incertidumbre.	22
3.2. Un conjunto difuso tipo-2 que representa conjunto difuso tipo-1 con media incierta. La media es incierta en el intervalo de $[0.4 \ 0.6]$	24
3.3. Un conjunto difuso tipo-2 en el que el grado de pertenencia de todos los puntos de dominio es un conjunto Gaussiano tipo-1.	25
3.4. Vista tridimensional de una función de pertenencia tipo-2.	25
3.5. Huella de la incertidumbre de un ejemplo de un función Gaussiana tipo-2.	26
3.6. Dos ejemplos de funciones de pertenencia tipo-2 gaussianas.	29
3.7. Unión de las dos funciones de pertenencia gaussianas.	29

3.8. Intersección de dos funciones de pertenencia gaussianas.	30
3.9. Sistema de lógica difusa tipo-2.	33
3.10. Un FLS tipo-2 vistos como una colección de FLSs tipo-1 integrados.	35
5.1. Estimación de temperatura con modelo de planta compensado con PI.	50
5.2. Función objetivo minimizada para sistema de 9 reglas.	55
5.3. Ubicación de los nueve centroides de cada grupo, para los datos de entrada. . . .	55
5.4. Función de pertenencia para temperatura de entrada del sistema con 9 reglas generado por FCM.	58
5.5. Función de pertenencia para tiempo de entrada del sistema con 9 reglas generado por FCM.	58
5.6. Función de pertenencia para temperatura de salida del sistema con 9 reglas generado por FCM.	59
5.7. Ubicación de los centroides de cada grupo.	61
5.8. Función de pertenencia para temperatura de entrada del sistema con 9 reglas generado por FCM.	63
5.9. Función de pertenencia para tiempo de entrada del sistema con 25 reglas gene- rado por FCM	64
5.10. Función de pertenencia para temperatura de salida del sistema con 25 reglas generado por FCM	64
5.11. Esquema de sistema de Caja Gris en paralelo (aditivo).	66

5.12. Esquema de modelo de Caja Gris, cálculo de las medidas de desempeño a partir del error.	67
5.13. Sistema FIS empírico con datos del laminador en caliente 3 de Ternium.	68
5.14. Diagrama de bloques de Estructura Mamdani adaptable	70
5.15. Histogramas sistemas Fuzzy tipo 1, a) Fuzzy de 9 reglas, b) Fuzzy de 25 reglas, c) Fuzzy mamdani 9 reglas, d) Fuzzy mamdani 25 reglas.	117
5.16. Histogramas sistemas Fuzzy tipo 1 Caja Gris, a) Fuzzy de 9 reglas, b) Fuzzy de 25 reglas, c) Fuzzy mamdani 9 reglas, d) Fuzzy mamdani 25 reglas.	118
5.17. Histogramas sistemas Fuzzy tipo 1 con FCM, a) FCM de 9 reglas, b) FCM de 25 reglas, c) FCM mamdani 9 reglas, d) FCM mamdani 25 reglas.	119
5.18. Histogramas sistemas Fuzzy tipo 1 FCM con Caja Gris, a) Fuzzy de 9 reglas, b) Fuzzy de 25 reglas, c) Fuzzy mamdani 9 reglas, d) Fuzzy mamdani 25 reglas. . .	120
5.19. Histogramas sistemas Fuzzy tipo 2, a) Fuzzy tipo 2 todos, b) Fuzzy tipo 2 los mejores.	122
5.20. Histogramas sistemas Fuzzy tipo 2 con Caja Gris, a) Fuzzy tipo 2 CG, todos, b) Fuzzy tipo 2 CG, los mejores.	123
5.21. Histogramas sistemas Fuzzy tipo 2 FCM, a) Fuzzy tipo 2 FCM, todos, b) Fuzzy tipo 2 FCM, los mejores.	123
5.22. Histogramas sistemas Fuzzy tipo 2 FCM con Caja Gris, a) Fuzzy tipo 2 FCM, todos, b) Fuzzy tipo 2 FCM, los mejores.	124

Capítulo 1

INTRODUCCIÓN

1.1. Planteamiento del problema

En una línea de laminación en caliente (ver Figura 1.1) se requiere la estimación de algunas variables como temperatura, fuerza, par, etc., para establecer las condiciones iniciales de rolado de cada barra. Es decir, esta estimación se requiere barra tras barra. El molino acabador (FM) se tiene que configurar correctamente cuando la barra de acero entra y así satisfacer los estándares de calidad. La configuración del molino acabador requiere conocimientos previos de algunas condiciones como la apertura de los rodillos de trabajo, la composición química del acero, el ancho el espesor de entrada al primero castillo y sobre todo la temperatura de el extremo final de la barra de entrada, en particular la temperatura superficial.

Sin embargo, la medición de la temperatura superficial de la barra en la etapa de descascarado (SB) su medición no resulta confiable debido a la presencia de vapor, cascarilla de óxido recalcancia y agua principalmente; por lo tanto, tiene que ser estimado desde la salida del molino reversible (RM), en este punto la lectura del pirómetro es más confiable. Actualmente, hay sistemas de automatización basados en el modelado físico para estimar la temperatura de rolado en la punta de la barra. El error estimación del modelado físico generalmente se

compensa con una estructura proporcional-integral aditiva (PI); en este trabajo el modelo PI compensado se conoce como modelo + PI (Figura 1.2).




Figura 1.1: Esquema de un molino de laminación en caliente con el diagrama de bloque de la predicción de temperatura.

Aunque la medición en la salida RM es más confiable que a la entrada del SB también se ve afectada por: el ruido producido por el crecimiento escalonado de la barra de transferencia, vapor de agua en el medio ambiente, oxido, ubicación pirómetro, calibración, la resolución y repetibilidad. Esto hace muy complejo el modelado matemático en el molino causando errores de estimación más grandes, y por lo tanto, posiblemente la configuración incorrecta del molino, lo que puede conducir a que el espesor final del producto terminado como no cumpla con la especificación requerida por el cliente.

La estimación se lleva acabo en tres etapas dependiendo de los diferentes fenómenos de transferencia de calor que ocurren en el molino. La primer etapa es a la entrada de la caja de descascarado la cual implica radiación al medio ambiente, la segunda etapa es a la salida de la

caja de descascarado la cual involucra convección por contacto con agua, la tercera es entre los rodillos de trabajo cuando la barra o planchón es deformado e implica dos fenómenos distintos, pérdida de calor por conducción o contacto con la superficie más fría del rodillo y ganancia de calor por deformación. La estimación de la temperatura se realiza en cascada, castillo por castillo siendo la temperatura a la salida de un castillo del molino, la temperatura a la entrada del siguiente castillo [1],[2].




Figura 1.2: Modelo físico con una estructura de compensación PI.

Barra tras barra la estimación puede presentar errores, provocado por el medio cambiante que lo rodea y variaciones en el proceso, estos factores afectan el desempeño y eficiencia de los controles del molino afectando la calidad de la punta de la cinta. Por ello en esta área se requieren sistemas de estimación, capaces de adaptarse a las diferentes condiciones del proceso. En esta investigación se pretende mediante el uso de sistemas difusos y modelos de Cajas Grises (difusos o neuro difusos), reducir el error de estimación de la temperatura, ya que estos sistemas cuentan con la capacidad de aprendizaje y adaptación. Con la finalidad de que la aplicación y evolución de los sistemas sea lo mas real posible se utilizarán datos reales de planta del molino N° 1 y 3 Ternium ubicadas en Planta Guerrero y Planta Churubusco respectivamente.

1.2. Objetivos

En el desarrollo de esta tesis se tiene como objetivo explorar, analizar y evaluar el impacto de algunos aspectos involucrados en el diseño de sistemas difusos y establecer lineamientos de diseño en el contexto de estimación de temperatura de entrada al proceso de descascarado en un molino de laminación en caliente, no obstante algunas conclusiones podrían ser generalizadas. Los aspectos que se evaluarán son los siguientes:

1. Variante de sistema difuso
 - i) Mamdani
 - ii) Sugeno
2. Tipo de sistema difuso
 - i) Tipo 1
 - ii) Tipo 2
3. Base de reglas
 - i) Forma de generación
 - (a) Empírica
 - (b) Generación basada en datos
 - ii) Tamaño
4. Esquema
 - i) Puramente difuso
 - ii) Caja gris

5. Adaptabilidad

Existen en la literatura numerosas propuestas de algoritmos para generación de reglas basadas en datos. Se seleccionó el algoritmo Fuzzy C-means (FCM) dada su disponibilidad en MATLAB y a que su aplicación es más práctica ya que no necesita una etapa extra para convertir las variables difusas a salidas como otras técnicas. Se pretende realizar la generación de reglas difusas basadas en datos reales de planta utilizando algoritmos de agrupamiento FCM para así realizar diferentes esquemas de caja gris y finalmente estimar la temperatura dentro del molino.

Para la estimación de temperatura también se pretende la aplicación de un sistema mamdani con adaptación, cabe mencionar que este sistema no ha sido propuesto antes en la literatura ni han sido evaluados para esta aplicación.

1.3. Estructura de la Tesis

La tesis esta estructurada de la siguiente forma:

Capítulo I En este capítulo se realiza el planteamiento del problema y se presentan los objetivos.

Capítulo II En este capítulo se describe brevemente el proceso de laminación. También se describe los antecedentes de sistemas difusos y caja gris, antecedentes de algoritmos de agrupamiento, antecedentes de sistemas mamdani con adaptación y antecedentes de sistemas difusos tipo-2.

Capítulo III En este capítulo se describen el concepto de lógica difusa y los fundamentos de lógica difusa tipo 2.

Capítulo IV En este capítulo se describe los principios de algoritmos de agrupamientos de datos.

Capítulo V En este capítulo se describe, implementa y evalúan los sistemas aplicando FCM y modelado con caja gris adaptables en la estimación de temperatura, también es descrito el modelo físico de planta, los datos para la experimentación y las medidas de desempeño. Además se realiza la generación de reglas difusas utilizando FCM, se describen los sistemas de caja gris, se implementan y evalúan Sistema Difuso Mamdani adaptable con FCM y caja gris.

Capítulo VI En este capítulo se presentan las conclusiones generales y trabajos futuros.

Capítulo 2

ANTECEDENTES

2.1. Proceso de Laminación en caliente

Los productos que se obtiene del proceso de laminación en caliente se producen aplicando un proceso termomecánico para reducción del espesor del planchón, a altas temperaturas. Son utilizados por una variedad de consumidores industriales en usos tales como la fabricación de ruedas, piezas automotrices, tubos, cilindros de gas, etc. También se emplean en la construcción de edificios, puentes, ferrocarriles y para chasis de automóviles o camiones. Los productos laminados en caliente pueden ser usados para fabricar bobinas o láminas cortadas a una longitud específica. Estos productos también sirven como entrada para la producción de productos laminados en frío.

El proceso de laminación está compuesto por varias etapas dentro de éstas las más importantes son: los molinos de laminación en caliente (MLC), el horno de recalentamiento (HC), los rompedores de óxido (RHO), molinos desbastador (MD), mesa de transferencia (MT), tijera de corte (TC), descascarado secundario (DS), molino acabador (MA), mesa de enfriamiento y los enrolladores (CLR). En esta sección se presenta una descripción breve de cada etapa, así como las características en cuanto a capacidades y la evolución que han tenido con el transcurrir de

los años; el proceso y sus etapas se muestra en la Figura 2.1, para mayor detalle ver [1, 3].

2.1.1. Molino de laminación en caliente

En un MLC los planchones son cargados al HC por su lado posterior, en este lugar se mantienen almacenados los planchones que serán laminados en las corridas o turnos de producción. El proceso de laminación inicia en el HC y termina en los CLR. Las dimensiones de los planchones varían de acuerdo a la cinta que se desea producir y se presenta de 101.0mm a 304.8mm de espesor, con ancho de 508.0mm a 1,981.0mm y de longitudes desde 9.75m a 12.18m. El peso de cada planchón varía de 5.0 a 45.0 t.

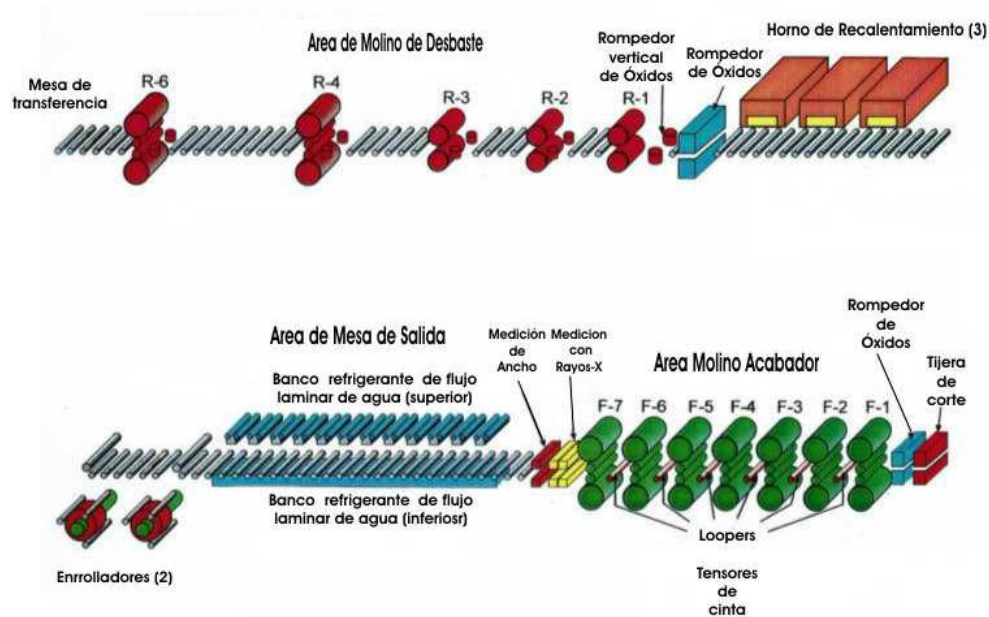


Figura 2.1: Proceso de laminación en caliente.

Con el pasar de los años, los MLC se han diseñado más largos en su tren de laminación,

mucho más rápidos en su producción, con mayor potencia, productos de dimensiones más grandes y mayor grado de mejora en acabados de superficie. Al final esto se ha logrado gracias a que los diversos componentes del MLC se han modernizado, desde el control de los motores, la instrumentación, los sistemas automáticos de control, los rodillos, castillos de reducción (CR) y demás componentes. Por otro lado al mismo tiempo se han estado desarrollando conocimientos teóricos de la tecnología de laminación en laboratorios de investigación, en industrias y en universidades.

El tren de laminación de los MLC consta de seis o siete castillos llamados MA, cuenta con drivers de corriente directa, para el control de la velocidad del planchón. Debido a las exigencias de la industria en general, este tipo de molinos han aumentado su tamaño físico y su potencia de laminación. Algunos cambios que se han tenido son: el ancho de la cinta se ha incrementado a valores mayores de 1,550mm, los diámetros de los rodillos de trabajo son mayores que 900mm, los diámetros de los rodillos de apoyo son mayores de 1,400mm de diámetro y, los drivers de potencia son de hasta los 10,000 HP, suministrados con energía eléctrica directamente por rectificadores en vez del acoplamiento motor-generador. En general el cuerpo del castillo ha cambiado muy poco. Los tornillos mecánicos para posicionamiento se han reemplazado por sistemas hidráulicos y tienen un tiempo de respuesta más rápido a señales de control automático del espesor.

Debido al desarrollo en el área computacional, se ha logrado que los sistemas de control de los molinos de laminación sean cada vez mas sofisticados, resolviendo así modelos complicados matemáticos del proceso. De igual forma, sistemas computarizados son usados para controlar la rapidez de laminación y determinar los valores de la referencia de operación de los MLC, incluyendo el perfil y la forma de la sección transversal de la cinta de laminación.

Los nuevos molinos usan dos o tres HC, un RHO, cuatro o cinco MD pudiendo ser uno solo reversible (MR), un DS a la entrada del MA, un tren de laminación de seis o siete castillos, una

mesa larga de enfriamiento (ROT), con uno o más enfriadores y dos CLR al final del tren de laminación. Este tipo de molino pueden producir anualmente de 1.5 a 2.6 millones de toneladas de acero laminado en caliente (ver Figura 1.1). Con la finalidad de lograr requerimientos en producción, los MLC llegan a estar compuestos hasta por cuatro HC, canteador vertical (EDG), un RHO con reducción horizontal, dos MD horizontal y vertical cada uno, un DS a la entrada del MA, seis o siete castillos en el MA y tres CLR, con lo cual se aumenta la capacidad anual de laminación de acero a un promedio de 3.5 millones de toneladas.

Los MLC modernos se han estandarizado en una estructura general. La configuración del MLC que se utiliza para el presente trabajo fue diseñada para rolar planchones de acero al carbón templado (0.07 % a 0.38 %C) de 20.32 a 22.86 centímetros de espesor y de 9.75 a 11.89 metros de longitud, con un índice de producción de 3.7 millones de toneladas por año (Figura 1.1).

2.2. Antecedentes sistemas difusos y caja Gris

En la actualidad algunos investigadores han optado por la utilización de algunas técnicas de Inteligencia Artificial como Sistemas de Inferencia Difusa (FIS del inglés “Fuzzy Inference System”), Redes Neuronales Artificiales (ANN del inglés “Artificial Neural Networks”) y Algoritmos genéticos (GA del inglés “Genetic Algorithms”) para aplicarlos en la industria a problemas de estimación y predicción de variables. Este tipo de técnicas son muy útiles por su capacidad de aprendizaje y adaptación. También ofrecen la ventaja de aproximar relaciones no lineales sin tener conocimiento total del proceso y tienen la capacidad de predicción bajo diversas condiciones de funcionamiento, así como adaptación y aprendizaje [4–6]. Por lo tanto, tienen la capacidad de predicción bajo una diversidad de condiciones de funcionamiento

Uno de los primeros trabajos realizados en laminación en caliente se presentan en [7]. Un

sistema de inferencia difuso fue desarrollado para compensar el error de espesor basado en el error de predicción de la fuerza en dos secciones intermedias en el molino acabador. La configuración del molino acabador se lleva a cabo por los métodos convencionales. Un sistema que integra la experiencia del operador y un FIS para configurar espacios y las velocidades en el molino acabador es presentado por Watanabe y otros en [5]. Varios sistemas basados en ANN para la estimación de variables del molino acabador, como la fuerza, temperatura entre rodillos, y la configuración completa se han propuesto en [4, 6, 8–11].

Mohanti y otros realizaron un modelo de la relación de propiedades mecánicas e intersticiales libres de la cinta de acero, como una función de la composición química y los parámetros de recalentamiento en laminación en frío utilizando ANNs [12].

En [13] una operación de laminación es optimizada con un GA multiobjetivo con dos funciones objetivo. En [14] es presentado una red neuronal adaptada por un GA multiobjetivo para analizar y depurar el laminado en caliente de la placa de acero en términos de rendimiento y la tensión de tracción. Chakraborti y otros [15] realizan una optimización de operación real de laminación en TATA steel siendo esto con un nuevo GA multiobjetivo para minimizar el rendimiento y la resistencia a la tracción y variaciones de ancho.

Méndez y otros [16] han propuesto predicción de temperatura en la punta de la barra en un molino de laminación en caliente mediante un FIS tipo 2 con aprendizaje híbrido. Min-You [17] ha propuesto la predicción de propiedad del material usando redes neuronales difusas, que incluye la autogeneración del modelo inicial difuso, selección de datos significativos, la validación de la partición, y la optimización de los parámetros. Mahfouf y otros [18] presentan el uso de técnicas de neuro difusas para el modelado y la optimización de las propiedades mecánicas de los aceros de aleación en el tratamiento térmico y la laminación en caliente.

Uno de los enfoques propuestos en la literatura para la estimación de variables son los denominados Metodologías de Caja Gris (también llamados sistemas híbrido o modelos semifísicos). Básicamente, un sistema de Caja Gris se compone de dos sistemas de diferente naturaleza. El primero es por lo general un modelo físico basado de una representación fenomenológica del proceso, en este trabajo el modelo físico utilizado en la planta es considerado. El segundo sistema se basa en una técnica diferente, tal como la inteligencia artificial; el modelado con Caja Gris, se describirá más adelante. En [19] se presenta una revisión de modelos de Cajas Grises y sus aplicaciones industriales, justifica su uso en la gran demanda que existe en los modelos de predicción de la producción de material con una mayor precisión y una gama más amplia de condiciones.

En la industria, en general, principalmente se utilizan para la estimación de variables modelos de Caja Gris basadas en redes neuronales. Anderson y otros [20] proponen el uso de un modelo de Caja Gris en un sistema de aguas residuales en una planta danesa. Modelos de Caja Gris también se han propuesto en la síntesis de la fase líquida del proceso de metanol, que explota el conocimiento a priori disponible e información experimental, que puede superar considerablemente un enfoque puramente analítico [21]. Los modelos de Caja Gris también se han utilizado para modelar la tasa de crecimiento de cristales de sacarosa [22]. Rooke y otros [23] presentaron un modelo de Caja Gris en el proceso de retención en la fabricación de papel utilizando ANN, en conjunto con algunas ecuaciones físicas para describir las concentraciones habituales de la caja de alimentación y del agua estancada (aguas blancas).

Una aplicación de un modelo basada en Caja Gris difusa puede encontrarse en [24], donde se propone un modelo de estrés por fricción neuro-difuso basado en Caja Gris utilizado para modelar el procesamiento termomecánico de una aleación de aluminio-magnesio.

Aplicaciones de los modelos Caja Gris basadas en ANN también se han encontrado en la industria siderúrgica. Hodgson y otros [25] proponen la predicción de la fuerza en laminación en

caliente de aceros con un modelo de red neuronal fenomenológica y artificial integrado. Schlang y otros [26] aportan sobre el desarrollo actual y futuro del calculo neuronal en el procesamiento de acero, incluidos los modelos neuronales basados en Caja Gris.

Geerdes W. desarrolló una estructura de conexión en paralelo y dos en serie de modelos de Caja Gris para la predicción de la temperatura en un molino de laminación en caliente [27]. Torres y otros [28, 29] presentan los resultados experimentales de los modelos de Caja Gris basados en ANNs desarrolladas para la estimación de la temperatura de entrada a la caja de descascarado en un molino de laminación en caliente. En [30, 31] Jose A. Barrios y otros implementan sistemas de inferencia difusa y modelos basados en caja gris difusos, se aplicaron sistemas Mandani y Sugeno sin aprendizaje, donde el sistema sugeno presentó mejores resultados, y ambos fueron mejores que el modelo físico de planta, los sistemas neuro-difusos adaptivos y los modelos basados en Caja Gris difusos, resultaron mejor que el modelo físico.

Jose A. Barrios y otros [32] desarrollaron sistemas basados en lógica difusa, incluyendo los modelos basados en caja gris difusos, estos son aplicados para estimar la temperatura de entrada a la caja de descascarado, dada su importancia, y su rendimiento se compara con la del modelo físico utilizado en la planta. Seis sistemas difusos y seis modelos basados en caja gris difusos de el tipo de sistema de inferencia Mamdani, Sugeno y neuro-difusos adaptativos, están diseñados para dos conjuntos diferentes de reglas, y son evaluados con datos experimentales. Otro trabajo de investigación realizado por Barrios y otros [33] utilizan varias redes neuronales, modelos de caja grises basados ANNs, sistemas de inferencia difusa y modelos de caja gris basados en lógica difusa, para estimar la temperatura de entrada a la caja de descascarado.

En [16] Mendez y otros, utilizan las entradas del modelo físico, para la estimación de la temperatura a la entrada de la caja de descascarado, es la temperatura superficial medida a la salida del molino desbastador (RM), y el tiempo de traslado del planchón de acero desde la salida del RM hasta la entrada del descascarado secundario (SB). Como resultado el modelo

estima la temperatura a la entrada del SB.

2.3. Antecedentes Algoritmos de agrupamiento

Un sistema de inferencia difusa esta compuesto por las entradas, la base de reglas, una etapa de agregación, defuzificación y la salida [34]. En el caso de la aplicación a laminación en caliente [16] y [30] entre otros, la base de reglas se realiza mediante conocimiento empírico y experto de personal de planta. En [16, 28–33, 35], se utilizan las entradas de temperatura y tiempo para los sistemas de estimación de temperatura a la entrada de la caja del SB, la base de reglas ahí establecidas es mediante conocimiento empírico y personal experto de planta. En este trabajo se realizaron simulaciones con sistemas con base de regla de 9 y 25. Para los sistemas de 9 reglas no existe gran complicación para establecerlas, en cambio cuando se trata de establecer un mayor número de reglas como en el caso de 25, resulta ser más complicado debido a que el número de combinaciones de entradas-salidas aumenta, por otro lado un número de reglas muy grande implica consumo de recursos de computación, así que es deseable usar el menor número de reglas posible. Para tratar de solucionar este problema existen algunos métodos de extracción de las reglas difusas basados en datos. La derivación de la reglas difusas basado en datos podría contribuir a que la primera estimación de la temperatura a la entrada de la caja de descascarado presente un error menor y reducir el efecto sobre la estimación de los demás castillos del molino, además de optimizar el número de reglas y por lo tanto el esfuerzo computacional. En este trabajo se utiliza un método de extracción de reglas basado en datos, y se utilizan números de reglas fijos que son de 9 y 25 para distintos sistemas, con la finalidad de realizar comparaciones con trabajos anteriores [30]. Algunos autores proponen clasificación de patrones de los cuales algunos son realizados mediante redes neuronales [36–40] y otros mediante Algoritmo Difuso “CMeans” [41–44]. Aunque también existen autores que realizan la extracción de reglas difusas directo de los datos utilizando “Fuzzy Inductive Reasoning” (razonamiento

inductivo difuso) tales como en [45–50] y también utilizando GA como en [51–56].

Mediante la revisión bibliográfica efectuada se observó que la metodología basada en clasificación de patrones resulta ser más viable para la resolución del problema en cuestión, debido a que en los datos que se utilizan existen diferentes productos, y estos datos al pertenecer al mismo producto se agrupan. Por lo tanto como objetivo general se propone en este trabajo establecer reglas difusas basadas en los datos, mediante los métodos existentes, modificándolos para los datos de la aplicación en la estimación dentro del molino.

2.4. Antecedentes Sistema Mamdani con adaptación (Neuro difuso)

El sistema difuso Sugeno con adaptación es comúnmente conocido con el nombre de ANFIS (Adaptative Neuro Fuzzy Inference System). Este tipo de sistema adaptativo esta disponible en distintas como por ejemplo Matlab. Existen autores [57, 58] que han trabajado con sistemas difusos Mamdani con adaptación. Aunque los sistemas difusos del tipo Takagi-Sugeno se pueden tratar computacionalmente de manera eficiente y son favorables al análisis matemático, los modelos difuso tipo Mamdani son intuitivos, proporcionan la flexibilidad heurística y han recibido la aceptación extensa en los medios industriales y están bien adaptados en términos de interacciones con los seres humanos [57].

En trabajos anteriores se han aplicado FIS y Cajas Grises Difusas basadas en ANFIS para la estimación de temperatura [30, 31]. Existe el interés de realizar un sistema Mamdani con adaptación para la estimación de temperatura, utilizar este tipo de sistemas se fundamenta en que en la literatura es reconocido como un algoritmos más poderoso que ANFIS. De un sistema ANFIS se obtienen salidas lineales, en cambio a la salida de un sistema Mamdani adaptativo se puede obtener una relación difusa que permita aproximar una función no lineal. Se menciona

además que este sistema no es de uso común, por lo que no se han encontrado aplicaciones en laminación de acero en caliente, esto es debido a que como se mencionó no existe ningún sistema implementado (dado que es más complejo que el Takagi-Sugeno) en algún software comercial, y es necesario desarrollarlo.

2.5. Antecedentes Sistema Difusos tipo-2

Los conjuntos de los sistemas difusos tipo-2 pueden ser utilizados en situaciones donde existe incertidumbre sobre los mismos grados de pertenencia. Cuando no se puede determinar la pertenencia de un elemento en un conjunto como 0 ó 1, se utilizan conjuntos difusos del tipo-1. Del mismo modo, cuando la situación es tan difusa que tenemos problemas para determinar el grado de pertenencia incluso en un número crisp entre $[0,1]$, se utilizan conjuntos difusos de tipo-2 [59].

Gerardo M. Mendez y otros [16, 35], presentan una nueva metodología de aprendizaje basado en un algoritmo híbrido para un sistemas de lógica difusa Mamdani tipo-2. Utilizando pares de datos de entrada y salida en el paso anterior del proceso de formación, el intervalo de salida de sistemas de lógica difusa tipo-2 no singleton tipo-1 es calculado y los parámetros del consecuente son estimados por el método recursivo de mínimos cuadrados (RLS). En el pase hacia atrás, el error se propaga hacia atrás, y los parámetros del antecedente se estiman por el método de retropropagación (BP). La metodología con retropropagación existe solamente ya por lo que el aprendizaje con sistema híbrido se propone y se utiliza para construir un sistemas de lógica difusa mamdani tipo-2 capaz de aproximar el comportamiento de la temperatura de la cinta de acero, en un molino de laminación en caliente (HSM) en la zona de entrada del molino acabador (SB). Los resultados comparativos muestran el rendimiento del método de aprendizaje híbrido (RLS-BP) comparado contra el de aprendizaje solo con BP, este mismo enfoque fue aplicado para sistemas difusos TSK en [35].

2.5.1. Resumen y conclusiones

Algunas técnicas de Inteligencia Artificial como FIS, ANN y GAs se han utilizado en la industria en problemas de estimación y predicción de variables. Este tipo de técnicas son muy útiles por su capacidad de aprendizaje y adaptación. También ofrecen la ventaja de aproximar relaciones no lineales sin tener conocimiento total del proceso y tienen la capacidad de predicción bajo diversas condiciones de funcionamiento, así como adaptación y aprendizaje.

Como puede verse a partir de la revisión anterior, los modelos difusos y los basados en Caja Gris difusos se han utilizado en la industria y en estimación de la temperatura en un molino de laminación en caliente. A diferencia de estos trabajos el objetivo que se pretende en esta investigación es el de mejorar la estimación de la temperatura de la punta con el diseño de las reglas basadas en datos reales, con la obtención de grupos de estos datos, además de analizar, evaluar y comparar con sistemas de lógica difusa. Esto se realiza para la estimación de temperatura en la punta de la barra a la entrada de la caja de descascarado dada la importancia de esta variable en el cálculo del sistema de control inicial. Utilizando agrupamiento de datos varios FIS y modelos de Caja Gris difusos serán diseñados y evaluados. Los rendimientos de estos sistemas se compararán con la del modelo físico con compensación proporcional integral utilizado en planta como se muestra en la Figura 1.2. La razón principal del estudio de los modelos de Caja Gris en este trabajo es que tienen la ventaja de mantener un modelo basado en el conocimiento físico dentro de su estructura, que es importante para la ingeniería de procesos y permite una etapa de puesta en marcha mas segura. Además se utilizaran sistemas difusos tipo 2 y sistemas mandani con adaptación para realizar la estimación dentro del molino como se ha mencionado anteriormente, y así realizar un estudio similar al los demás sistemas, para poder compararlos en condiciones parecidas.

Capítulo 3

LÓGICA DIFUSA (“FUZZY LOGIC”)

El término **Lógica Difusa** (“Fuzzy Logic”) puede interpretarse como un superconjunto de la tradicional lógica booleana [60], que ha sido extendida para manejar el concepto de “parcialmente verdadero” (valores de verdad entre “absolutamente verdadero” y “absolutamente falso”). Fue presentada por Lotfi Zadeh de Universidad de California en Berkeley en los años 60, como un medio para modelar la incertidumbre del lenguaje natural. Según Zadeh, no debería considerarse a la teoría difusa como una simple teoría, sino que se debería considerar el proceso de fuzificación (del inglés *fuzzification*) como una metodología para generalizar cualquier teoría desde su versión ordinaria (discreta) a una nueva versión continua (difusa). Así puede hablarse de “cálculo difuso”, “ecuaciones diferenciales difusas”, “autómatas difusos”, “sistemas dinámicos difusos”, etc. Del mismo modo que se verifica una estrecha relación entre la lógica booleana y el concepto de subconjunto, así también se cumple una relación similar entre la lógica difusa y la teoría de conjuntos difusos [61].

La lógica difusa ha cobrado gran fama por la variedad de sus aplicaciones, las cuales van desde el control de complejos procesos industriales, hasta el diseño de dispositivos artificiales de deducción automática, pasando por la construcción de artefactos electrónicos de uso doméstico y de entretenimiento, así como también de sistemas de diagnóstico. De hecho, desde hace ya

al menos década y media, la expedición de patentes industriales de mecanismos basados en la lógica difusa tiene un crecimiento sumamente rápido en todas las naciones industrializadas del orbe [61].

Lógica difusa, es esencialmente una lógica multivaluada que se extiende a la lógica clásica. Sin embargo, la lógica difusa va más allá, porque no sólo considera que existe una infinidad de valores semánticos entre “verdadero” y “falso”, sino que también tiene en cuenta que esos mismos valores de verdad son imprecisos. Estas últimas imponen a sus enunciados únicamente valores falso o verdadero. Bien que éstas han modelado satisfactoriamente una gran parte del razonamiento “natural”, es cierto que el razonamiento humano utiliza valores de verdad que no necesariamente son “deterministas”. La lógica difusa procura crear aproximaciones matemáticas en la resolución de ciertos tipos de problemas. Pretende producir resultados exactos a partir de datos imprecisos, por lo cual es particularmente útil en aplicaciones electrónicas o computacionales. El adjetivo “difuso” aplicado a ellas se debe a que los valores de verdad no deterministas utilizados en ellas tienen, por lo general, una connotación de incertidumbre. En determinadas áreas de conocimiento, a los enunciados se les asocia valores de verdad que son grados de veracidad o falsedad. El objetivo de todo sistema de lógica difusa es describir los grados de veracidad de los enunciados de salida en términos de los de entrada. Algunos sistemas son capaces de refinar los grados de veracidad de los enunciados de salida conforme se refinan los de entrada. Por estas propiedades es que ciertos sistemas de lógica difusa aparentan una labor de aprendizaje, y son excelentes mecanismos de control de procesos. Desde el punto de vista tecnológico, la lógica difusa se encuadra en el área de Inteligencia Artificial y han dado origen a sistemas expertos de tipo difuso y a sistemas de control automático [61, 62]. Para mas detalles de los conceptos y definiciones pueden ser consultados con mayor detalle en [34, 62].

3.1. Lógica difusa tipo-2

En esta sección se introduce una área relativamente nueva en la lógica difusa, que se llama Lógica difusa tipo 2 (“Type-2 Fuzzy Logic”). Básicamente, un conjunto difuso de tipo 2 es un conjunto en el que también tenemos la incertidumbre sobre la función de pertenencia. Por supuesto, los sistemas difusos tipo-2 consisten de reglas difusas IF-THEN, que contienen conjuntos difusos de tipo-2. Podemos decir que los sistemas difusos tipo-2 es una generalización de la lógica difusa convencional (tipo-1) en el sentido de que la incertidumbre no sólo se limita a las variables lingüísticas, si no también está presente en la definición de las funciones de pertenencia.

Los Sistemas de Lógica Difusa están compuestos por reglas. Normalmente, el conocimiento que se utiliza para construir estas reglas es incierto. Esta incertidumbre conduce a reglas cuyos antecedentes o consecuentes son inciertos, lo que se traduce en incertidumbre en las funciones de pertenencia de los antecedentes o consecuentes [63]. Los sistemas difusos tipo-1 (como los que se vieron a inicios de este capítulo), cuyos funciones de pertenencia son conjuntos difusos tipo-1, son incapaces de manejar directamente estas incertidumbres. En esta sección se describe sistemas difusos tipo-2, en el que el antecedente o funciones de pertenencia del consecuente son conjuntos difusos tipo-2. Estos conjuntos son conjuntos difusos en donde los propios grados de pertenencia son conjuntos difusos tipo-1, que son muy útiles en circunstancias en las que es difícil determinar con exactitud una función de pertenencia para un conjunto difuso.

La lógica difusa original, fundado por Lotfi Zadeh, ha estado alrededor de más de 30 años, y sin embargo es incapaz de manejar las incertidumbres [64]. Tomando en cuenta que la lógica difusa original (lógica difusa tipo-1) tiene esta implicación es paradójico ya que la palabra “Difusa” tiene la connotación de incertidumbre. La lógica difusa ampliada (lógica difusa tipo-2) es capaz de manejar la incertidumbre, ya que puede modelar y reducir al mínimo sus efectos.

En esta sección se introducirá los conceptos básicos de conjuntos difusos tipo-2, y razonamiento difuso tipo-2. Después se presentará y comparará los diferentes tipos de sistemas de inferencia difusa que se han empleado en diversas aplicaciones. Más adelante se presentara la aplicación de sistemas de lógica difusa tipo-2 y la comparación con los sistemas difusos tipo-1.

3.1.1. Conjuntos Difusos Tipo-2

El concepto de un conjunto difuso tipo-2, fue introducido por Zadeh (1975) como una extensión del concepto de un conjunto difuso ordinario (en adelante denominado “conjunto difuso tipo-1”). Un conjunto difuso tipo-2 se caracteriza por una función de pertenencia difusa, es decir, el grado de pertenencia para cada elemento de este conjunto es un conjunto difuso en $[0,1]$, a diferencia de un conjunto difuso tipo-1, donde el grado de pertenencia es un número nítido (*crisp*) en $[0,1]$. Tales conjuntos pueden ser utilizados en situaciones donde existe incertidumbre sobre los mismos grados de pertenencia, por ejemplo, una incertidumbre en la forma de la función de pertenencia o en algunos de sus parámetros. Considere la posibilidad de la transición de conjuntos ordinarios a los conjuntos difusos. Cuando no se puede determinar la membresía de un elemento en un conjunto como 0 ó 1, se utilizan conjuntos difusos del tipo-1. Del mismo modo, cuando la situación es tan difusa que se tienen problemas para determinar el grado de pertenencia incluso en un número crisp entre $[0,1]$, se utilizan conjuntos difusos de tipo 2.

Esto no implica que se tienen que tener situaciones extremadamente difusos para usar conjuntos difusos tipo-2. Hay muchos problemas en el mundo real en el que no podemos determinar la forma exacta de las funciones de pertenencia, por ejemplo, en la predicción de series de tiempo a causa del ruido en los datos. Otra forma de ver esto es considerar los conjuntos difusos tipo-1 como una aproximación de primer orden para la incertidumbre en el mundo real. Entonces los conjuntos difusos tipo-2 se puede considerar como una aproximación de segundo orden. Es posible considerar conjuntos difusos de tipos más altos, pero la complejidad del sistema difuso

aumenta muy rápidamente. Por esta razón, sólo se consideran brevemente conjuntos difusos tipo-2. A continuación se presentaran tres casos comunes de conjuntos difusos tipo-2.

Caso 3.1. Se considera el caso de un conjunto difuso caracterizado por una función de pertenencia Gaussiana media m y una desviación estándar que puede tomar valores en $[\sigma_1, \sigma_2]$, es decir,

$$\mu(x) = \exp \left\{ -1/2[(x - m)/\sigma]^2 \right\} ; \quad \sigma \in [\sigma_1, \sigma_2] \quad (3.1.1)$$

Correspondiente a cada valor de σ , se obtiene una curva de composición diferente (ver Figura 3.1). Por lo tanto, el grado de pertenencia de cualquier x determinado (excepto $x = m$) puede tomar cualquiera de los números de los posibles valores dependiendo del valor de σ , es decir, el grado de pertenencia no es un número crisp, es un conjunto difuso. La Figura 3.1 muestra el dominio del conjunto difuso asociado con $x = 0.7$, sin embargo, la función de pertenencia asociado con este conjunto difuso no se muestra en la figura.




Figura 3.1: Un conjunto difuso tipo-2 que representa un conjunto difuso tipo-1 con una desviación estándar con incertidumbre.

Caso 3.2. Se considera el caso de un conjunto difuso con una función de pertenencia gaussiana que tiene una desviación estándar σ fija, pero una media incierta, tomando valores en $[m_1, m_2]$,

es decir,

$$\mu(x) = \exp \left\{ -1/2[(x - m)/\sigma]^2 \right\} ; \quad m \in [m_1, m_2] \quad (3.1.2)$$

Una vez más, $\mu(x)$ es un conjunto difuso. La figura 3.2 muestra un ejemplo de un conjunto como este. La media es incierta en el intervalo $[0.4 \ 0.6]$.

Caso 3.3. Se considera un conjunto difuso tipo-1 caracterizado por una función de pertenencia Gaussiana (media M y desviación estándar σ_x), lo que da una pertenencia crisp $m(x)$ para cada entrada $x \in X$, donde

$$m(x) = \exp \left\{ -1/2[(x - M)/\sigma_x]^2 \right\} \quad (3.1.3)$$

Esto se muestra en la Figura 3.3. Imaginando que esta pertenencia de x es un conjunto difuso. Se le llamara a los elementos del dominio de este conjunto “pertenencias primarias” de x (denotado por μ_1) y los grados de pertenencia de estas pertenencias primarias “pertenencias secundarias” de x denotado por $\mu_2(x, \mu_1)$. Por lo tanto, para un x fijo, se obtiene un conjunto difuso de tipo-1 cuyo dominio de elementos son pertenencias primarias de x y cuyos correspondientes grados de pertenencia son pertenencias secundarios de x . Si asumimos que las pertenencias secundarias siguen una función gaussiana con media $m(x)$ y una desviación estándar μ_m , como en la Figura 3.3, se puede describir la función de pertenencia secundaria para cada x como

$$\mu_2(x, \mu_1) = e^{-1/2[(\mu_1 - m(x))/\sigma_m]^2} \quad (3.1.4)$$

donde $\mu_1 \in [0, 1]$ y m es como en la ecuación 3.1.3.

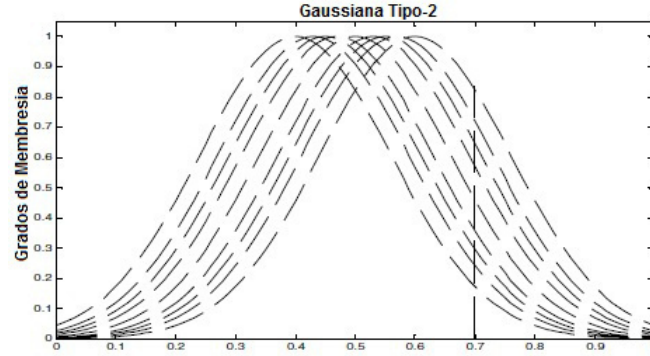


Figura 3.2: Un conjunto difuso tipo-2 que representa conjunto difuso tipo-1 con media incierta. La media es incierta en el intervalo de $[0.4 \ 0.6]$.

3.1.2. Definiciones básicas

Se pueden definir formalmente dos clases de conjuntos tipo-2 de la siguiente manera.

Definición: 3.1. **Gaussiana tipo 2.**

Un conjunto difuso gaussiano tipo-2 es aquél en el que el grado de pertenencia de cada punto de dominio es un conjunto gaussiano tipo-1 contenido en $[0,1]$. El caso 3.1 muestra un ejemplo de un conjunto difuso tipo gaussiano-2. Otra forma de ver de la funciones de pertenencia tipo 2 es de una forma tridimensional, en la que se puede apreciar mejor la idea de difusidad tipo-2. En la figura 3.4 tenemos una vista tridimensional de una función de pertenencia de tipo-2 Gaussiana.




Figura 3.3: Un conjunto difuso tipo-2 en el que el grado de pertenencia de todos los puntos de dominio es un conjunto Gaussiano tipo-1.

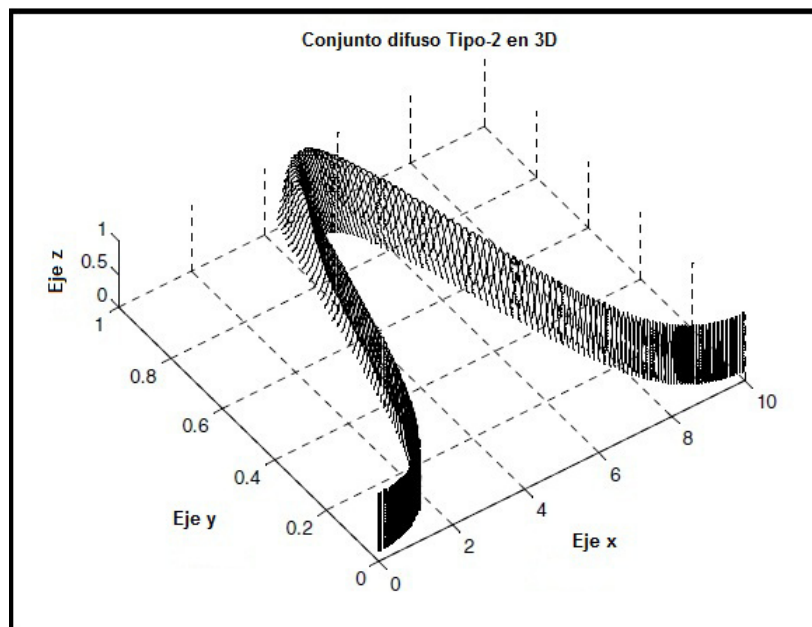


Figura 3.4: Vista tridimensional de una función de pertenencia tipo-2.

Definición: 3.2. Intervalo de tipo-2. Un conjunto difuso de intervalo tipo-2 es aquél en el

que el grado de pertenencia de cada punto de dominio es un conjunto crisp cuyo dominio es un intervalo contenido entre $[0,1]$. En el Caso 3.1 se muestra un ejemplo de intervalo de conjunto difuso tipo-2.

Definición: 3.3. Huella de incertidumbre.

La incertidumbre en las pertenencias principales de un conjunto de difuso tipo-2, \tilde{A} , consiste en una región limitada que llamamos la “huella de la incertidumbre” (FOU por sus siglas en ingles, *footprint of uncertainty*). Matemáticamente, es la unión de todas las funciones de pertenencia primaria [64]. Se muestra en la figura 3.5 la huella de incertidumbre para una función de pertenencia gaussiana tipo-2. Esta huella de incertidumbre se puede obtener mediante la proyección en dos dimensiones de la función de pertenencia gaussiana tipo-2.

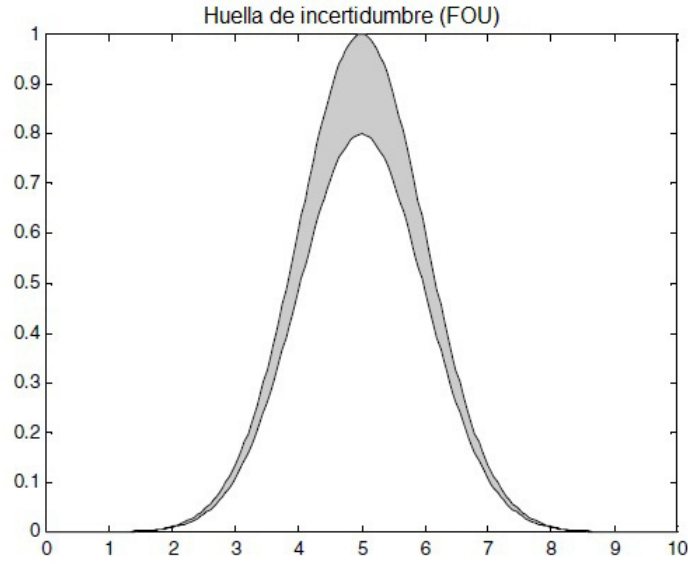


Figura 3.5: Huella de la incertidumbre de un ejemplo de un función Gaussiana tipo-2.

Definición: 3.4. Funciones de pertenencia superior e inferior.

Una “función de pertenencia superior” y una “función de pertenencia inferior” son dos funciones de pertenencia tipo-1 que son los límites para la FOU de un conjunto difuso tipo-2 \tilde{A} . La función de pertenencia superior se asocia con el límite superior del FOU (\tilde{A}). La función de pertenencia inferior se asocia con el límite inferior de FOU (\tilde{A}).

A continuación se presentan los conceptos de funciones de pertenencia inferior y superior, así como la huella de incertidumbre en el caso siguiente.

Caso 3.4. Para una función de pertenencia primaria Gaussiana con una desviación estándar incierta (Figura 3.1), la función de pertenencia superior es:

$$superior(FOU(\tilde{A})) = N(m, \sigma_2, x) \quad (3.1.5)$$

y la función de pertenencia inferior es

$$inferior(FOU(\tilde{A})) = N(m, \sigma_1, x) \quad (3.1.6)$$

3.1.3. Operaciones de Conjuntos Difusos Tipo-2

En esta sección se describen las operaciones teóricas de conjuntos difusos tipo-2, y está enfocada al caso de los conjuntos difusos de tipo-2 $\tilde{A}_i (i = 1, \dots, r)$, cuya función de pertenencia secundaria son conjuntos difusos tipo-1. Para calcular la unión, intersección y complemento de conjuntos difusos tipo-2, se tiene que ampliar las operaciones binarias de mínimo (o producto) y máximo (o suma) y la operación unitaria de negación, desde los números crisp para conjuntos difusos tipo-1, porque en cada x , $\mu_{\tilde{A}_i}(x, u)$ es una función (a diferencia del caso de tipo 1, donde $\mu_{\tilde{A}_i}(x)$ es un número crisp). La herramienta para calcular la unión, la intersección y complemento de conjuntos difusos tipo-2 es la extensión del principio Zadeh (Zadeh, 1975).

Considerando dos conjuntos difusos tipo-2 \tilde{A}_1 y \tilde{A}_2 , esto es

$$\tilde{A}_1 = \int_x \mu_{\tilde{A}_1}(x)/x \quad (3.1.7)$$

y

$$\tilde{A}_2 = \int_x \mu_{\tilde{A}_2}(x)/x \quad (3.1.8)$$

***Definición:* 3.5. Unión de conjuntos difusos tipo-2.**

La unión de \tilde{A}_1 y \tilde{A}_2 es otro conjunto difuso tipo-2. Formalmente, se tiene la siguiente expresión

$$\tilde{A}_1 \cup \tilde{A}_2 = \int_{x \in X} \mu_{\tilde{A}_1 \cup \tilde{A}_2}(x)/x \quad (3.1.9)$$

Se puede explicar la ecuación 3.1.9 por la operación de “union” [64]. Básicamente, la unión entre dos funciones de pertenencia secundaria debe realizarse entre todos los pares posibles de pertenencias primarias. Si más de una combinación de pares da el mismo punto, en la unión mantenemos el uno con máximo grado de pertenencia. A continuación se considera un ejemplo sencillo para ilustrar la operación de unión. En la Figura 3.6 se representa dos funciones de pertenencia de tipo-2 Gaussianas, y la unión se muestra en la Figura 3.7.

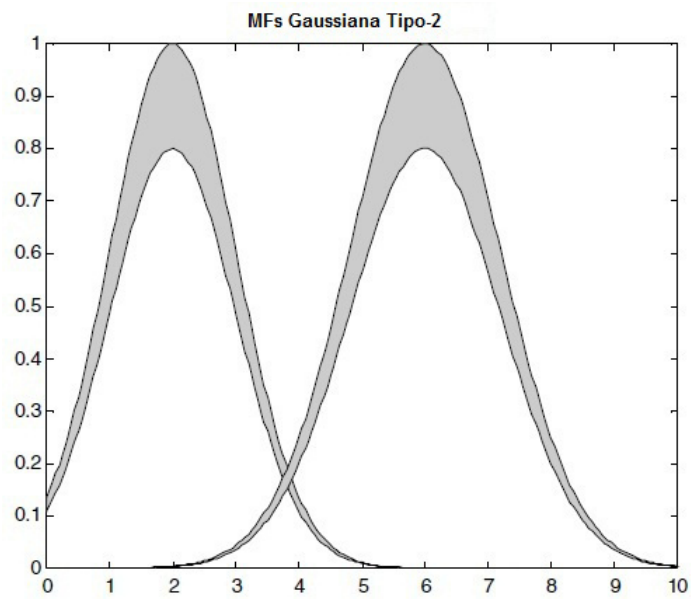


Figura 3.6: Dos ejemplos de funciones de pertenencia tipo-2 gaussianas.




Figura 3.7: Unión de las dos funciones de pertenencia gaussianas.

Definición: 3.6. Intersección de conjuntos difusos tipo-2.

La intersección de \tilde{A}_1 y \tilde{A}_2 es otro conjunto difuso tipo-2. Más formalmente, tenemos la siguiente expresión

$$\tilde{A}_1 \cap \tilde{A}_2 = \int_{x \in X} \mu_{\tilde{A}_1 \cap \tilde{A}_2}(x)/x \quad (3.1.10)$$

Se ilustra la intersección de dos funciones de pertenencia tipo-2 gaussianas en la Figura 3.8. Podemos explicar la ecuación 3.1.10 por la operación de “conjunción” [64]. Básicamente, la intersección entre dos funciones de pertenencia secundaria debe realizarse entre todos los pares posibles de pertenencias primarias. Si más de una combinación de pares da el mismo punto, entonces en la intersección mantenemos el uno con el máximo grado de pertenencia.

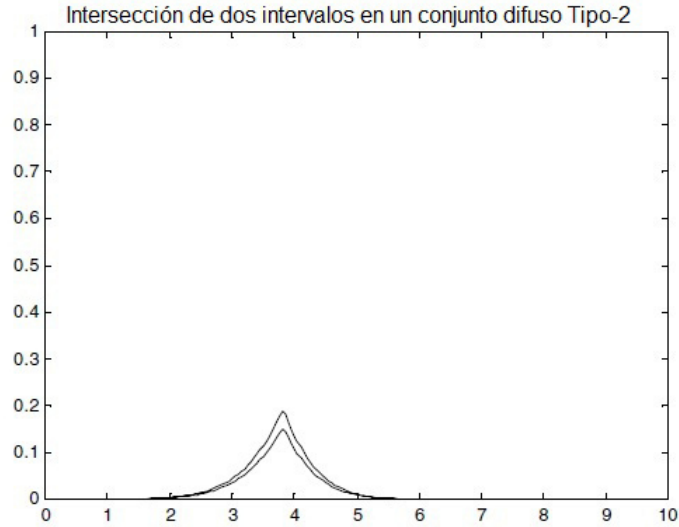


Figura 3.8: Intersección de dos funciones de pertenencia gaussianas.

Definición: 3.7. Complemento de un conjunto difuso de tipo-2.

El complemento del conjunto \tilde{A} es otro conjunto difuso de tipo-2. Más formalmente tenemos

$$\tilde{A}' = \int_x \mu_{\tilde{A}'1}(x)/x \quad (3.1.11)$$

donde la comilla denota complemento en la ecuación anterior. En esta ecuación $\mu_{\tilde{A}'1}$ es una función de pertenencia secundaria, es decir, cada valor de x $\mu_{\tilde{A}'1}$ es una función (a diferencia de la tipo-1 que para cada valor de x , $\mu_{\tilde{A}'1}$ es un valor puntual).

3.1.4. Sistemas Difusos Tipo-2

Los fundamentos de la lógica difusa no cambian de conjuntos difusos tipo-1 a tipo-2, y en general, no va a cambiar para cualquier tipo- n [63]. Un mayor tipo de número sólo indica un mayor “grado de difusidad”. Dado que un tipo superior cambia la naturaleza de las funciones de pertenencia, las operaciones que dependen de las funciones de pertenencia cambian, sin embargo, los principios básicos de la lógica difusa son independientes de la naturaleza de las funciones de pertenencia y, por tanto, no cambian. Reglas de inferencia como Modus ponens Generalizada o Modus Tollens generalizados se siguen aplicando.

La estructura de las reglas difusas tipo-2 es el mismo que para el tipo-1 esto debido a la distinción entre el tipo-2 y tipo-1 se asocia con la naturaleza de las funciones de pertenencia. Por lo tanto, la única diferencia es que ahora algunos o todos los conjuntos implicados en las reglas son de tipo-2. En un sistema difuso tipo-1, donde los conjuntos de salida son conjuntos difusos tipo-1, realiza defuzificación con el fin de obtener un número, que representa los conjuntos combinados de salida. En el caso de tipo-2, los conjuntos de salida son de tipo-2, por lo que tenemos que utilizar versiones extendidas de los métodos de defuzificación tipo-1. Dado que la defuzificación tipo-1 da un número crisp en la salida del sistema difuso, la operación de defuzificación extendida en el caso de tipo-2 da un conjunto difuso tipo-1 en la salida. Dado que esta operación nos lleva desde los conjuntos de salida tipo-2 de los sistemas difusos a un

conjunto tipo-1, se puede llamar a esta operación “reducción de tipo” (type-reduction) y llamar al conjunto difuso tipo-1 así obtenido un “conjunto de tipo reducido”. El conjunto difuso de tipo reducido puede ser entonces defuzificado para obtener un único número crisp, sin embargo, en muchas aplicaciones, el conjunto de tipo reducido puede ser más importante que un solo número crisp.

Los conjuntos de tipo-2 se puede utilizar para transmitir las incertidumbres en funciones de pertenencia de conjuntos difusos tipo-1, debido a la dependencia de las funciones de pertenencia en información disponibles lingüística y numérica. La información lingüística (por ejemplo, reglas de expertos), en general, no da ninguna información acerca de la forma de las funciones de pertenencia. Cuando las funciones de pertenencia se determina o sintoniza a partir de datos numéricos, la incertidumbre de los datos numéricos, ejemplo ruido, se traduce en incertidumbre en la función de pertenencia. En todos estos casos, la información disponible acerca de la incertidumbre lingüística numérica se puede incorporar en el marco de tipo-2.

3.1.5. Sistemas de lógica difusa Singleton Tipo-2

En esta sección se analiza la estructura de un Sistemas difuso tipo-2, o “*Fuzzy Logic System*” (FLS), que es un sistema que tiene en cuenta las incertidumbres sobre los antecedentes o consecuentes en las reglas, pero no tiene en cuenta de forma explícita las incertidumbres de medición de entrada. Más complicado (pero más versátil) los FLSs no-singleton tipo-2 que representan los dos tipos de incertidumbres se discuten más adelante.

En la Figura 3.9 se muestra un FLS tipo-2 general. Como fue visto un FLS tipo-2 es muy similar al tipo FLS-1, siendo la principal diferencia estructural que el bloque defuzificador de un FLS tipo-1 se sustituye por el bloque de procesamiento de salida de FLS tipo-2. Este bloque consiste en una “reducción de tipo” seguida de la defuzificación.

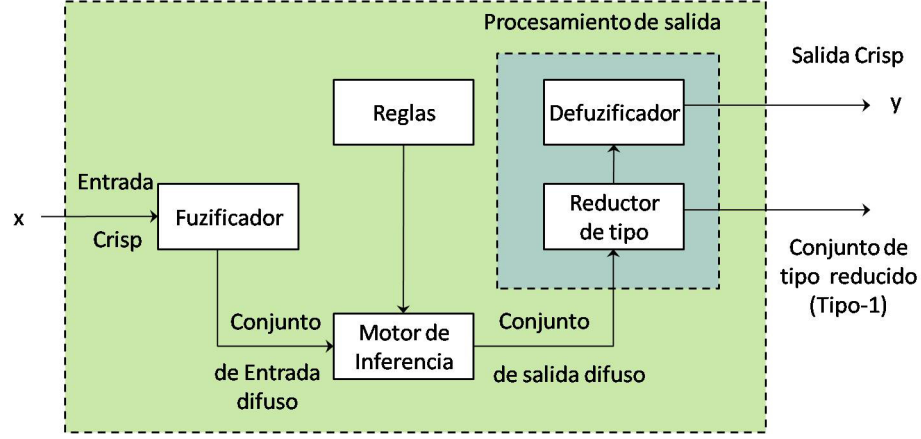


Figura 3.9: Sistema de lógica difusa tipo-2.

Durante el desarrollo de un FLS tipo-2, se supone que todos los conjuntos de reglas antecedentes y consecuentes son de tipo-2, sin embargo, esto no tiene que ser necesariamente el caso en la práctica. Todos los resultados son válidos, siempre y cuando sólo un conjunto es de tipo 2. Esto significa que un FLS es de tipo-2, siempre y cuando cualquiera de sus conjuntos antecedente o consecuentes sean de tipo-2.

En el caso del tipo-1, generalmente tenemos reglas difusas IF-THEN de la forma

$$R^l : \text{si } x_1 \text{ es } A_1^l \text{ y } \dots \text{ y } x_p \text{ es } A_p^l, \text{ entonces } y \text{ es } Y^l \quad l = 1, \dots, M \quad (3.1.12)$$

Como se mencionó anteriormente, la distinción entre el tipo-1 y de tipo-2 se asocia con la naturaleza de las funciones de pertenencia, que no es importante cuando se forman las reglas. La estructura de las reglas sigue siendo exactamente la misma en el caso de tipo-2, pero ahora algunos o la totalidad de los conjuntos implicados son de tipo-2.

Considere un FLS tipo-2 que tienen r entradas $x_1 \in X_1, \dots, x_r \in X_r$ y una salida $y \in Y$.

Como en el caso del tipo-1, se puede suponer que hay M reglas, pero, en el caso de tipo-2 la regla l -sima tiene la forma:

$$R^l : \text{si } x_1 \text{ es } \tilde{A}_1^l \text{ y } \dots x_p \text{ is } \tilde{A}_p^l, \text{ entonces y es } \hat{Y}^l \quad l = 1, \dots, M \quad (3.1.13)$$

Esta regla representa una relación difusa tipo-2 entre el espacio de entrada $X_1 \times \dots \times X_r$ y el espacio de la salida Y , del sistema difuso tipo-2. En un FLS tipo-1 el motor de inferencia combina reglas y le da una asignación o mapeo desde los conjuntos difusos de entrada tipo-1 a los conjuntos difusos de salida de tipo-1. La t -norma combina Múltiples antecedentes en las reglas. Los grados de pertenencia en los conjuntos de entrada se combinan con aquellos en los conjuntos de salida utilizando composición. Se pueden combinar multiples reglas usando la t -conorma o durante la defuzificación mediante la suma ponderada. En el caso de tipo-2 el proceso de inferencia es muy similar. El motor de inferencia combina reglas y le da una asignación o mapeo desde los conjuntos difusos de entrada tipo-2 a los conjuntos difusos de salida de tipo-2. Para hacer esto se necesita calcular uniones e intersecciones de conjuntos difusos tipo-2 , así como las composiciones de relaciones tipo-2.

En los sistemas difusos tipo-2 (Figura 3.9), como en el sistema difuso tipo-1, las entradas crisp son primero fuzificadas en conjuntos difusos de entrada que a continuación activan el bloque de inferencia, que en el caso presente se relaciona con conjuntos difusos tipo-2. En esta sección, se describe la fuzificación singleton y el efecto de tal fuzificación en el motor de inferencia. El “fuzificador” mapea un punto crisp $x = (x_1, \dots, x_r)^T \in X_1 \times X_2 \dots \times X_r \equiv X$ en un conjunto difuso tipo-2 \tilde{A}_x en X .

La salida tipo-2 del motor de inferencia (Figura 3.9) se debe procesar por el procesador de salida, y la primera operación es reducción de tipo. El método reducción de tipo incluye [64]: centroide, centro de sumas, altura, altura modificada, y el centro de conjuntos. Suponiendo que

se realiza reducción de tipo centroeide, entonces, cada elemento del conjunto reducción de tipo es el centroeide de algún conjunto integrado tipo-1 para el conjunto de salida tipo-2 del FLS. Cada uno de estos conjuntos integrados se puede considerar como un conjunto de salida de un FLS tipo 1 asociado, y en consecuencia, el FLS tipo-2 puede ser visto como una colección de diversos FLSs tipo-1. Cada FLS tipo-1 está integrado en el FLS tipo-2, por lo que el conjunto de reducción de tipo es una colección de las salidas de todos los FLSs tipo-1 integrados (ver Figura 3.10). El conjunto de reducción de tipo permite representar la salida de los FLS tipo-2 como un conjunto difuso y no como un número crisp, que es algo que no se puede hacer con un sistema difuso tipo-1.

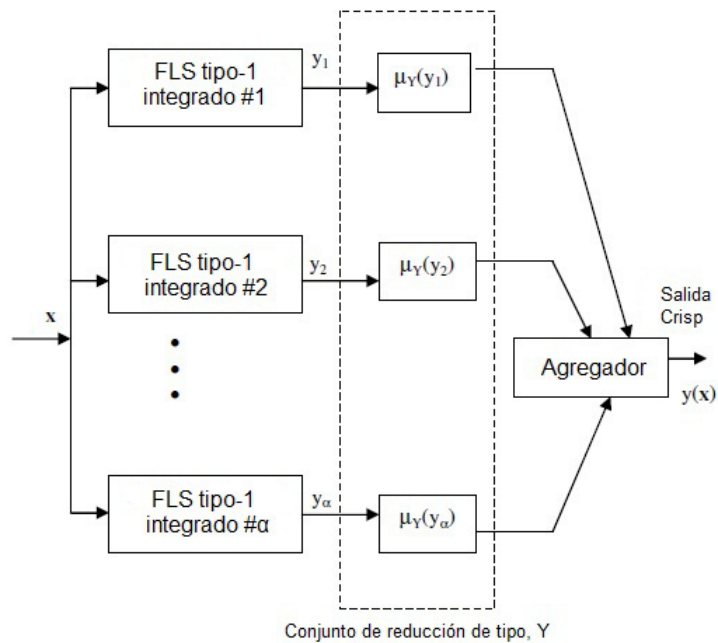


Figura 3.10: Un FLS tipo-2 vistos como una colección de FLSs tipo-1 integrados.

Con referencia a la figura 3.10, cuando las funciones de pertenencia de los antecedentes y consecuentes de FLS tipo-2 tienen dominios continuos, el número de conjuntos integrados es incontable. La figura 3.10 muestra una situación en la que se ha supuesto que las funciones

de pertenencia tienen dominios discretos (o discretizados). La pertenencia en un conjunto de reducción de tipo, $\mu_Y(y_i)$, representa el nivel de incertidumbre asociado a cada FLS tipo-1 integrado. Una salida crisp se puede conseguir mediante la agregación de las salidas de todas los FLSs tipo-1 integrados, por ejemplo, encontrar el centroide de los conjuntos de reducción de tipo. Si todas las incertidumbres de tipo-2 desaparecen, las funciones de pertenencia secundaria para todos los antecedentes y consecuentes haría cada colapso a un solo punto, lo que indica que el FLS tipo-2 colapsan a un FLS tipo-1.

Si se piensa en un FLS tipo-2 como una “perturbación” de un FLS tipo-1, debido a las incertidumbres en sus funciones de pertenencia, entonces el conjunto reducción de tipo de los FLS tipo-2 puede ser pensado como la representación de la incertidumbre en la salida crisp debido a la perturbación. Algunas medidas de la dispersión del conjunto de reducción de tipo se puede tomar a continuación, para indicar la posible variación en la salida crisp debido a la perturbación. Esto es análogo a la utilización de intervalos de confianza en una situación estocástico-incierta.

Se defuzifica el conjunto de tipo reducido para obtener una salida crisp de los FLS tipo-2. La forma más natural de hacer esto podría ser encontrar el centro de gravedad del conjunto de tipo reducido. Encontrar el centroide es equivalente a encontrar la media ponderada de las salidas de todos los FLSs tipo-1 que se integran en los FLS tipo-2, donde las ponderaciones corresponden a las pertenencias en el conjunto de reducción de tipo (véase la Figura 3.10). Si el conjunto reducción de tipo Y para una entrada x es discretizado o es discreta y se compone de puntos de α , entonces la expresión para su centroide es

$$y(x) = \left[\sum_{k=1}^{\alpha} y_k \mu_Y(y_k) \right] / \left[\sum_{k=1}^{\alpha} \mu_Y(y_k) \right] \quad (3.1.14)$$

Si α es grande, entonces el almacenamiento de datos puede ser un problema para el cálculo de

la ecuación 3.1.14. Esta ecuación puede ser evaluada utilizando el procesamiento en paralelo, en este caso el almacenamiento de datos no será un problema. Actualmente la mayoría de los investigadores todavía dependen de software para la simulación y no pueden hacer uso de procesamiento paralelo. Podemos, sin embargo, utilizar un método recursivo para reducir enormemente la memoria necesaria para almacenar los datos necesarios para calcular la salida de defuzificación. De la ecuación 3.1.14, se puede calcular como sigue:

$$A(i) = A(i - 1) + y_i \mu_Y(y_i) \quad A(0) = 0 \quad (3.1.15)$$

y

$$B(i) = B(i - 1) + y_i \mu_Y(y_i) \quad B(0) = 0 \quad (3.1.16)$$

para $i = 1, \dots, \alpha$. Con estas fórmulas sólo tenemos que guardar A y B durante cada iteración.

De lo mencionado anteriormente acerca de los cinco elementos que componen la figura 3.9 del FLS Tipo-2, se puede ver que hay muchas posibilidades para elegir, incluso más que para un FLS tipo-1. Para empezar, hay que decidir sobre el tipo de defuzificación (singleton o no singleton). También hay que elegir un FOU para cada función de pertenencia tipo-2, decidir sobre las formas funcionales, tanto para las funciones de pertenencia primaria y secundaria, y elegir los parámetros de las funciones de pertenencia (fijado a priori o en sintonía durante un procedimiento de entrenamiento). Luego se tiene que elegir la composición (max-min, max-producto), implicación (mínimo, producto), método de reducción de tipo (centroide, centro de sumas, altura, altura modificada, centro de conjunto), y defuzificación. Claramente, hay una riqueza aún mayor entre los FLSs tipo-2, que la que hay entre los FLSs tipo-1. En otras palabras, hay más grados de libertad del diseño asociado a un FLS tipo-2 que con un FLS tipo-1, por lo que un FLS tipo-2 tiene el potencial de superar a un FLS tipo-1.

3.1.6. Sistemas Difusos Sugeno Tipo-2

Los sistemas difusos de las secciones anteriores fueron tipo Mamdani, aunque no se refirieron con ese termino. En esta sección, se hace la distinción entre los dos tipos de FLSs, refiriendo a los FLSs anteriores como FLSs “Mamdani”. Ambos tipos de FLS se caracterizan por reglas IF-THEN y tienen las mismas estructuras de antecedentes. Se diferencian en las estructuras de sus consecuentes. El consecuente de una regla Mamdani es un conjunto difuso, mientras que el consecuente de una regla de Sugeno es una función.

Si se considera un FLS Sugeno tipo-2 con r entradas $x_1 \in X_1, \dots, x_r \in X_r$ y una salida $y \in Y$. Un FLS Sugeno tipo-2 también se describe por reglas difusas IF-THEN que representan las relaciones de entrada-salida de un sistema. En un modelo general Sugeno tipo-2 de primer orden con una base de M reglas, teniendo cada uno antecedentes r , la i -ésima regla se pueden expresar como:

$$R^l : \text{si } x_1 \text{ es } \tilde{A}_1^l \text{ y } \dots \text{ } x_p \text{ is } \tilde{A}_p^l, \text{ entonces } Y^i = C_0^i + C_1^i x_1 + \dots + C_r^i x_r \quad (3.1.17)$$

donde $i = 1, \dots, M$; $C_j^i (j = 1, \dots, r)$ son los consecuentes de conjuntos difusos tipo-1; Y_i es la salida de la i -ésima regla, es también un conjunto difuso tipo-1 (porque es una combinación lineal de conjuntos difusos tipo-1) y $\tilde{A}_k^i (k = 1, \dots, r)$ son antecedentes de los conjuntos difusos tipo-2. Estas reglas nos permiten considerar simultáneamente la incertidumbre sobre las funciones de pertenencia antecedentes y valores de parámetros de consecuentes. Para un FLS Sugeno tipo-2 no hay necesidad de reducción de tipo, al igual que no hay necesidad de defuzificación en un FLS Sugeno tipo-1 .

3.2. Resumen

En este capítulo se describió con cierto detalle la teoría de conjuntos difusos, el razonamiento difuso y los sistemas de inferencia difusos para sistemas tipo-2. También se describieron las diferencias entre sistemas mandani, sugeno, singleton, para sistemas difusos tipo-2.

Capítulo 4

PRINCIPIOS DE ALGORITMOS DE AGRUPAMIENTOS DE DATOS

4.1. Introducción

Algoritmos Clusters son utilizados extensamente no sólo para organizar y clasificar datos, si no también para la compresión de datos y la construcción de modelos. Cuatro de los más representativos técnicas de clusters off-line utilizados con frecuencia conjuntamente con redes de función de base radial y modelado difuso son: (hard) clusters C-means (o K-means), Clusters difusos C-means, el método cluster mountain, y cluster substractivo.

El Cluster (agrupamiento) particiona o divide un conjunto de datos en varios grupos de tal manera que la semejanza dentro de un grupo es mayor que entre los grupos. La realización de tal división requiere una métrica de similitud que tome dos vectores de entrada y devuelva un valor que refleja su semejanza. Puesto que la mayoría de las métricas de semejanza son sensibles al rango de elementos en los vectores de entrada, cada una de las variables de entrada se debe normalizar dentro, por ejemplo, del intervalo de unidad $[0,1]$. El conjunto de datos considerado es normalizado para estar dentro de hipercubo unitario.

Las técnicas Cluster se utilizan conjuntamente con las redes de funciones de base radiales o modelado difuso sobre todo para determinar las localizaciones iniciales para las funciones de base radiales o reglas difusas IF-THEN. Con este fin, las técnicas de agrupamiento cluster se validan con base en las suposiciones siguientes:

1.- Entradas similares al sistema objetivo que será modelado deberá producir salidas similares. 2.- Estos pares similares de la entrada-salida son envueltos dentro de clusters en el conjunto de datos de entrenamiento.

La suposición 1 indica que el sistema objetivo que se modelará es un mapeo suave de entrada-salida; esto es generalmente verdad para los sistemas del mundo real. La suposición 2 requiere que el conjunto de datos se ajuste a un cierto tipo específico de distribución; sin embargo, esto no es siempre verdadero. Por lo tanto, técnicas de clusters usadas para la identificación de la estructura en modelado con redes neuronales o difusos es altamente heurístico, y encontrar un conjunto de datos al cual las técnicas de cluster no puedan ser aplicadas satisfactoriamente no es raro.

4.2. Clusters K-means

Los cluster K-mean, también conocidos como cluster C-means, han sido aplicados en una variedad de áreas, incluyendo procesamiento de imagen y comprensión de datos de habla, procesamiento de datos para modelado de sistemas usando redes de funciones de base radial, y descomposición de tareas en arquitecturas en redes neuronales heterogéneas.

El algoritmo K-means realiza una partición de una colección de n vectores x_j , $j = 1, \dots, n$, en c grupos G_i , $i = 1, \dots, c$, y encuentra un centro de cluster en cada grupo tal que una función de costo (o función objetivo) de semejanza (o distancia) medida es reducida al mínimo. Cuando

la distancia Euclideana es escogida como la medida de semejanza entre un vector x_k en un grupo j y el correspondiente cluster de centro c_i , la función objetivo puede ser definida por

$$J = \sum_{i=1}^c J_i = \sum_{i=1}^c \left(\sum_{k, x_k \in G_i} \|x_k - c_i\|^2 \right) \quad (4.2.1)$$

donde $x_k =$ es el vector de agrupamiento del vector j donde $J_i = \sum_{k, x_k \in G_i} \|x_k - c_i\|^2$ es la función objetivo dentro del grupo i .

Así, el valor de J_i depende de las propiedades geométricas de G_i , y la posición (ubicación) de c_i . En general, una función de distancia genérica $d(x_k, c_i)$ puede ser aplicada para el vector x_k en el grupo i ; la función objetivo total correspondiente así es expresada como

$$J = \sum_{i=1}^c J_i = \sum_{i=1}^c \left(\sum_{k, x_k \in G_i} d(x_k - c_i) \right) \quad (4.2.2)$$

Por simplicidad, la distancia euclidiana es usada como la medida de semejanza, y la función objetivo total, es expresada como en la ecuación 4.2.1.

Los grupos divididos típicamente son definidos por una la **matriz de pertenencia U** binaria $c \times n$, donde el elemento u_{ij} es 1 si el j_{th} punto de referencia x_j pertenece al grupo i , y 0 de otra manera. Una vez que el centro de cluster c_i es fijado, la minimización de u_{ij} para (4.2.1) puede ser obtenida así:

$$u_{ij} = \begin{cases} 1 & \text{si } \|x_j - c_i\|^2 \leq \|x_j - c_k\|^2, \text{ para cada } k \neq i, \\ 0 & \text{en otro caso} \end{cases}$$

replantando, x_j pertenece al grupo i si c_i es el centro mas cercano entre todos los centros.

Puesto que un punto de referencias dado puede solamente estar en un grupo, la matriz de pertenencia U tiene las características siguientes:

$$\sum_{i=1}^c u_{ij} = 1, \forall j = 1, \dots, n \quad (4.2.3)$$

y

$$\sum_{i=1}^c \sum_{j=1}^n u_{ij} = n \quad (4.2.4)$$

De otra forma, si u_{ij} es fijo, entonces el centro óptimo c_i que minimiza (4.2.1) es el medio de todos los vectores en grupo i :

$$c_i = \frac{1}{|G_i|} \sum_{k, x_k \in G_i} x_k \quad (4.2.5)$$

donde $|G_i|$ es el tamaño de G_i , o $|G_i| = \sum_{j=1}^n u_{ij}$.

Para una operación por lotes, el algoritmo K-means es presentado con un conjunto de datos x_i , $i = 1, \dots, n$; el algoritmo determina el cluster central c_i y la matriz membresía U iterativamente usando los pasos siguientes:

Paso 1: Inicializar el centro del cluster c_i , $i = 1, \dots, c$. Esto es logrado típicamente por selección aleatoria de puntos de c de entre todos los puntos de datos.

Paso 2: Determinar la matriz membresía U por la ecuación 4.2.3.

Paso 3: Calcular la función objetivo según la ecuación 4.2.1. Parar si está debajo de cierto valor de la tolerancia o su mejora respecto la iteración anterior está por debajo de un cierto umbral.

Paso 4: Actualizar los centros del cluster según la ecuación 4.2.4. Regresar al paso 2.

El algoritmo es inherentemente iterativo, y no se puede garantizar que se va a converger a una solución óptima. El funcionamiento del algoritmo K-means depende de las posiciones iniciales de los centros de cluster, de tal modo que se hace recomendable emplear algunos métodos anticipados (front-end) para encontrar adecuados clusters de centros iniciales o para hacer funcionar el algoritmo varias veces, cada uno con un diverso conjuntos de cluster de centros iniciales. Por otra parte, el algoritmo precedente es solamente representativo; es también posible inicializar primero una matriz de pertenencia aleatoriamente y en seguida seguir el procedimiento iterativo.

El algoritmo de K-means también puede ser operado en el modo en línea, donde los centros de cluster y los grupos correspondientes se obtienen a través del tiempo promedio. Es decir, para un punto de referencia x , el algoritmo encuentra el cluster más cercano al centro c_i y es actualizado utilizando la formula

$$\Delta c_i = \eta(x - c_i) \quad (4.2.6)$$

Esta fórmula en línea está esencialmente integrada en muchas reglas de aprendizaje de las redes neuronales de aprendizaje sin supervisión.

4.3. Cluster C-means difusos

Los cluster C-means difusos (FCM), también conocido como ISODATA difuso es un algoritmo cluster de datos en cual cada punto de los datos pertenece a un cluster en un grado especificado por un grado de pertenencia. Bezdek propuso este algoritmo en 1973 [34] como

una mejora del anterior algoritmo hard C-means (HCM).

FCM realiza un partición de una colección de n vectores $x_i, i = 1, \dots, n$ en c grupos difusos, y encuentra un centro de cluster en cada grupo tales que una función objetivo de medida de semejanza es minimizada. La diferencia principal entre FCM y HCM es que FCM emplea partición difusa tales que un punto de referencias dado puede pertenecer a varios grupos con el grado de correspondencia especificado por el grado de pertenencia entre 0 y 1. Para dar cabida a la introducción de la partición difusa, la matriz U de pertenencia se le permite tener elementos con valores entre 0 y 1. Sin embargo, la imposición de normalización estipula que la suma de los grados de pertenencia a un conjunto de datos siempre será igual a la unidad:

$$\sum_{i=1}^c u_{ij} = 1, \forall j = 1, \dots, n. \quad (4.3.1)$$

La función objetivo para FCM es entonces una generalización de la ecuación 4.2.2,

$$J(U, c_1, \dots, c_c) = \sum_{i=1}^c J_i = \sum_{i=1}^c \sum_{j=1}^n u_{ij}^m d_{ij}^2 \quad (4.3.2)$$

donde u_{ij} está entre 0 y 1; c_i es el cluster central del grupo difuso i ; $d_{ij} = \|c_i - x_j\|$ es la distancia euclidiana entre el i -ésimo cluster central y el j -ésimo punto de referencias y $m \in [1, \infty)$ es un exponente de ponderación. Las condiciones necesarias para la ecuación 4.3.2 para alcanzar un mínimo pueden ser encontradas formando una nueva función objetivo \bar{J} como sigue:

$$\begin{aligned} \bar{J} = (U, c_1, \dots, c_c, \lambda_1, \dots, \lambda_n) &= J(U, c_1, \dots, c_c) + \sum_{j=1}^n \lambda_j (\sum_{i=1}^c u_{ij} - 1) \\ &= \sum_{i=1}^c \sum_{j=1}^n u_{ij}^m d_{ij}^2 + \sum_{j=1}^n \lambda_j (\sum_{i=1}^c u_{ij} - 1) \end{aligned} \quad (4.3.3)$$

donde $\lambda_j, j = 1$ hasta n , son los multiplicadores de Lagrange para las n restricciones en la ecuación 4.3.1. Diferenciando $\bar{J} = (U, c_1, \dots, c_c, \lambda_1, \dots, \lambda_n)$ con respecto a todos sus argumentos

de entrada, la condición necesaria para la ecuación 4.3.2 para alcanzar su mínimo es

$$c_i = \frac{\sum_{j=1}^n u_{ij}^m x_j}{\sum_{j=1}^n u_{ij}^m} \quad (4.3.4)$$

y

$$u_{ij} = \frac{1}{\sum_{k=1}^c \left(\frac{d_{ij}}{d_{kj}} \right)^{2/(m-1)}} \quad (4.3.5)$$

El algoritmo C-means difuso es simplemente un procedimiento iterado a través de las dos condiciones necesarias anteriores. En una operación por lotes (batch-mode), FCM determina que el centro de los clusters c_i y la matriz de pertenencia U utilizan los siguientes pasos [34]:

Paso 1: Inicializar la matriz de pertenencia U con valores aleatorios entre 0 y 1 tales que las restricciones en la ecuación 4.3.1 son satisfechos.

Paso 2: Calcular el cluster central difuso c de c_i , $i = 1, \dots, c$, usando la ecuación 4.3.4.

Paso 3: Calcular la función objetivo según la ecuación 4.3.2. Parar si está debajo de cierto valor de la tolerancia o su mejora sobre la iteración anterior está debajo de cierto umbral (límite).

Paso 4: Calcular una nueva U usando la ecuación 4.3.5. Regresar al paso 2.

Los centros de cluster pueden también primero ser inicializados y entonces realizar el procedimiento iterativo. No se garantiza de que FCM converja a una solución óptima. El funcionamiento depende de los centros iniciales del cluster, lo que nos permite ya sea utilizar otro algoritmo rápido para determinar los centros de cluster iniciales o ejecutar FCM varias veces, cada comienzo con un conjunto diferente de centros de cluster inicial.

4.4. Resumen

En este capítulo se presento y explico con brevedad algunos sistemas de agrupamiento de datos los cuales son Clusters K-means, y su versión mejorada llamado Cluster C-means difusos; estos últimos son los que en este trabajo de investigación se utilizan como base para la formación de reglas difusas en los sistemas de estimación de temperatura, que se describen en el siguiente capítulo.

Capítulo 5

APLICACIÓN DE SISTEMAS FCM Y MODELADO CON CAJA GRIS ADAPTABLES EN LA ESTIMACIÓN DE TEMPERATURA

5.1. Introducción

En los capítulos anteriores se mencionó que la **lógica difusa** es una herramienta muy efectiva para modelado, ya que cuenta con capacidades de aprendizaje y adaptación y tiene capacidad para predecir y aproximar funciones altamente no lineales, agregando otros aspectos importantes como son el diseño y la implementación sencilla, y que no se requiere un conocimiento detallado del proceso. En el presente capítulo se realizarán diseños de distintos modelos con sistemas difusos y desarrollados en [16, 27, 32, 33] utilizando FCM, además se presentarán sistemas difusos Mamdani adaptables Fuzzy tipo-1 y Fuzzy tipo-2, así como cajas grises basadas en FIS usando reglas empíricas y FCM, para la estimación de la temperatura a la entrada de la caja de descascarado del molino de laminación en caliente.

En esta sección se propone el uso de algoritmos de agrupamiento FCM para la obtención

de reglas difusas, además se describirá el modelo físico utilizado en planta, así como los datos que se utilizarán para los experimentos y simulaciones, también la arquitectura de los diferentes sistemas de lógica difusa, diseñados mediante modelado empírico, FCM y cajas grises, que se proponen para la estimación de la temperatura, los cuales son sistemas de inferencia tipo Mamdani, Sugeno, y ANFIS, y también Sistemas Fuzzy tipo-2. Estos resultados se obtendrán mediante simulación en el ToolBox de Fuzzy Logic de Matlab para cada sistema y se realizará una comparación de éstos entre sí.

Para realizar una comparación válida de los resultados obtenidos de los sistemas diseñados en esta investigación, se utilizarán algunos sistemas desarrollados en los trabajos publicados en [29–33], los cuales están diseñados de forma empírica y se utilizó una base de datos diferente. Estos sistemas son Mamdani 9 y 25 reglas, Sugeno de 9 y 25 reglas, ANFIS de 9 y 25 reglas, y sistemas de Caja Gris para cada uno de estos. Los sistemas se comportan de forma similar aunque obtienen mejor desempeño debido a que los datos nuevos de este molino son mas consistentes, el modelo de planta estima mejor ya que se utilizan hornos de recalentamiento para los planchones lo que provoca que el planchón tenga una temperatura mas controlada y homogénea, al contrario de datos de otros molinos donde se tienen fosas para recalentar el material. Es importante destacar que estos sistemas se simularon y evaluaron con los datos nuevos que pertenecen a otro molino y esto mejora los resultados, para tener las mismas condiciones de operación que en [29–33], los sistemas diseñados en esta investigación utilizan los mismos números de entradas y salidas.

5.2. Modelo físico de la planta

Debido a que en la industria únicamente se tiene la posibilidad de realizar la medición de la temperatura superficial de la BT, la temperatura central se estima a partir de la temperatura

superficial, y por consecuencia, esta contendrá las incertidumbre de la primera. Por esta razón, fue desarrollado un modelo de transferencia de calor basado en diferencias finitas con compensación de error PI (proporcional + integral) que realiza una estimación de la temperatura a la entrada del SB el cual es usado en planta, esta configuración se describe en la Figura 5.1.

Las constantes del compensador son $T_s = 1$, $T_i = 5$, $K = 0.2$, los parámetros que se utilizan en este compensador PI son los que comúnmente se usan en planta. Cabe la posibilidad de que el ajuste de las ganancias no sea correcto y requiera uno más fino, ya que utilizan valores recomendados por el fabricante.

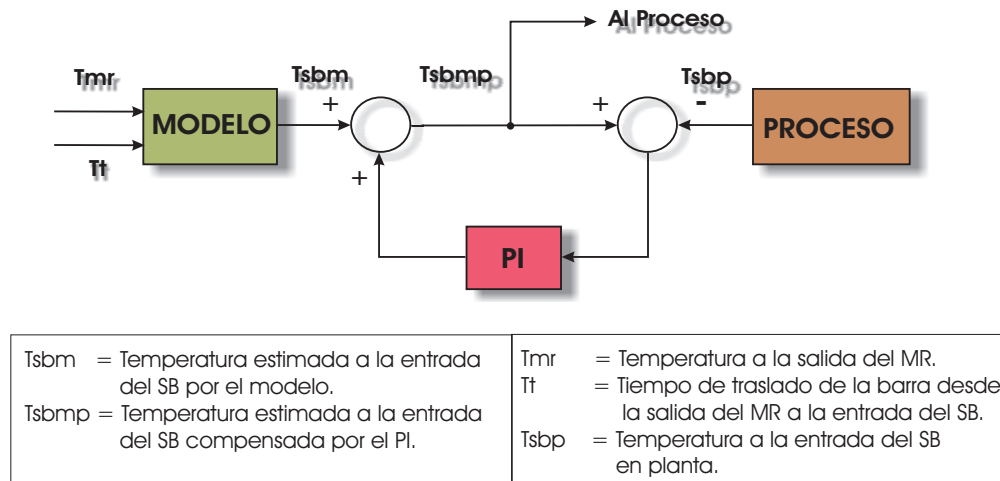


Figura 5.1: Estimación de temperatura con modelo de planta compensado con PI.

5.3. Datos para la experimentación

En esta sección se describen los datos que se utilizarán para la evaluación de los sistemas, estos serán utilizados para todos los modelos diseñados en esta investigación. Los datos de entrada requeridos por los sistemas son: la temperatura superficial medida a la salida del molino reversible (RM), y el tiempo de traslado del planchón de acero desde la salida del RM hasta la

entrada del descascarado secundario (SB). Como resultado el modelo estima la temperatura a la entrada del SB. El tiempo de traslado también es calculado, sin embargo en este trabajo se utilizará el medido, ya que es esta comparación la que se lleva a cabo para ajuste del modelo.

Los datos usados para llevar a cabo la experimentación fueron recolectados del molino de laminación en caliente de APM, y éstos consisten en un total de 47,797 rollos de diferentes grados de acero. Esta base de datos inicial se redujo a 38,419 rollos, debido a algunas inconsistencias en algunos datos, se realizó la depuración de la siguiente manera:

- Se eliminaron datos incompletos, lo que es temperaturas o tiempos faltantes.
- Se eliminaron datos que estuvieran fuera del rango de $\pm 40\text{ }^{\circ}\text{C}$, a partir de una media de los datos, esto fue un 6 %.
- Se eliminaron datos incoherentes (datos que no representaban el valor real, fuera de margen de operación, celdas vacías).
- Se eliminaron diferencias de temperatura (entrada-salida) menores de $20\text{ }^{\circ}\text{C}$.

Los datos utilizados fueron un total de 38,419 (100 %), así 37,000 filas de datos que corresponden a diversos productos fueron ordenados de manera aleatoria y 1,419 filas de datos se mantuvieron sin modificar es decir de forma consecutiva. Del grupo de datos aleatorios para el diseño de los sistemas FCM se utilizan 10,000 datos (27 %), para entrenar los sistemas que lo requieren se utilizan 3,700 datos (10 %) y en la validación de todos los sistemas se utilizan 3,700 datos (10 %).

5.4. Medidas de desempeño para el error de estimación

En esta sección se establecen los indicadores que serán utilizados para la medida de desempeño del error de estimación, y éstos serán los que se utilicen para todos los resultados obtenidos de las simulaciones en este trabajo.

Es importante hacer notar que al trabajar con una base de datos grande lo conveniente es trabajar con medidas de desempeño estadísticas, las cuales son: Desviación estándar, Media, Media Absoluta, RMS y Banda de Tolerancia.

No existe en planta una banda de tolerancia (medida rendimiento). En la práctica no hay límites de especificación estándar de error de estimación de temperatura de entrada. Por lo que un número razonable de temperatura tuvo que ser elegido. De acuerdo con uno de los fabricantes de sistemas de automatización de molinos, General Electric que es el de mayor participación en los molinos de laminación en caliente, establece una regla en particular que en planta un $\pm 14^{\circ}C$ de error tiene un impacto de acarreo de 1 mm (10 %) de error en el espesor, el cual se propaga en todo el molino acabador (General Electric, 1993). En este trabajo se considera $\pm 20^{\circ}C$ de tolerancia en la banda de error de predicción. Tomando en cuenta esto se calcula el porcentaje de cumplimiento dentro de la banda de tolerancia para cada sistema, para mayor detalle ver [29]. De este modo el índice de rendimiento se define como el porcentaje de barras dentro de un $\pm 20^{\circ}C$ y para fines prácticos se abreviará “%bars $\pm 20^{\circ}C$ ”.

Estas medidas de desempeño se aplican sobre el error; en cada uno de estos se busca reducirlos, mas cercano a cero es mejor, excepto en el caso del porcentaje de cumplimiento dentro de la banda de tolerancia, donde se busca un porcentaje mayor, un 100 % sería lo ideal ya que es el número de barras cuya estimación estuvo dentro del rango de cumplimiento.

La evaluación de los sistemas desarrollados se llevará a cabo aplicando las medidas de

desempeño al error de estimación, el cual se calcula como sigue:

$$e = T_{esd} - T_{esp}$$

donde:

T_{esd} = es la Temperatura estimada a la entrada del SB por el sistema difuso.

T_{esp} = Temperatura a la entrada del SB.

Para realizar la validación de los sistemas se utilizan: temperatura a la entrada del SB y tiempo de traslado de la barra, y para realizar entrenamiento se utilizan tres entradas: la misma temperatura, y el mismo tiempo y además una temperatura que es medida a la entrada del SB.

Las medidas de desempeño se aplican sobre el error, por lo que el objetivo es reducirlo, con excepción de el porcentaje de cumplimiento dentro de la banda de tolerancia, donde se desea obtener un porcentaje mayor.

5.5. Generación de reglas difusas utilizando FCM

El uso de algoritmos de agrupamiento FCM para la obtención de reglas difusas se considera factible de realizar ya que debido a que los datos que se utilizan existen para diferentes productos, los datos pertenecientes a un mismo producto pueden ser considerados que forman un grupo, además de que se cuenta con una base de datos grande con la cual el algoritmo de agrupamiento puede determinar los grupos que se requieren, cabe aclarar que puede haber productos semejantes que pueden conformar un grupo dependiendo de la aplicación del algoritmo FCM. Como se demostró con anterioridad en [28–33], el diseño de sistemas difusos para 9 y 25 reglas, resulta ser conveniente para este caso de estudio, ya que se obtuvieron buenos resultados,

con base a este antecedente en este trabajo se desarrollan sistemas con ese número de reglas para mejor comprensión. También en estos trabajos y en [16] se propone el uso de funciones gaussianas como funciones pertenencia debido a los cambios suaves que estas representan, y que son mas representativas de los procesos físicos.

5.5.1. Obtención de sistemas difusos de 9 reglas utilizando FCM

A continuación se utiliza FCM para establecer reglas difusas con base en datos de entrada y salida del sistema, como se mencionó anteriormente éstos son temperatura de salida del RM y tiempo de traslado para la entrada y temperatura a la salida del SB como salida del sistema. Para la implementación del sistema FCM se utilizan 10,000 datos el cual representa un 27% del total, esto es llevado a cabo con la función *fcm* de MatLab, a la cual se le indica el vector con el que trabajará y el número de cluster que debe encontrar, esto minimizará una función objetivo (ver sección 4.3), y generará centros de cluster que nos indican donde estarán ubicados los centros de cada función de pertenencia, respectivamente tanto para las entradas como para las salidas.

Se puede observar en la Figura 5.2 como la función objetivo es minimizada. Y en la gráfica de la Figura 5.3 se observa los centroides encontrados mediante FCM, se puede ver la ubicación de los centros de cada grupo para las entradas.




Figura 5.2: Función objetivo minimizada para sistema de 9 reglas.




Figura 5.3: Ubicación de los nueve centroides de cada grupo, para los datos de entrada.

Como se puede apreciar en la Figura 5.3, los puntos indicados con “x” representan los diferentes grupos encontrados por FCM, en algunos casos estos grupos contienen número de datos con valores semejantes por lo que los centros de estos se encuentran muy cercanos, y algunos casi traslapados.

Los centros de cada grupo que se ha formado para las entradas y salidas del sistema, se utilizan para ubicar las medias de cada función de pertenencia gaussiana, esto quiere decir que se tendrán 9 funciones de pertenencia para la entrada de temperatura, 9 para la entrada de tiempo, 9 para la salida del sistema es decir la temperatura a la entrada del SB. A continuación se muestra en la Tabla 5.1 los centros respectivos para las entradas y salidas del sistema difuso.

Tabla 5.1: Tabla de centroides para sistema de 9 reglas.

	Centroides		
	Temp.entr.	Tiempo	Temp.sal.
1	1116.581482	18.20177615	1080.699547
2	1141.5997	18.5592134	1067.182074
3	1103.558353	17.83600997	1061.195812
4	1150.318734	18.4089501	1112.780636
5	1124.480345	18.20823243	1061.783683
6	1129.049682	18.42950966	1090.142235
7	1157.525782	18.74446859	1095.250481
8	1136.19071	18.40563673	1102.614731
9	1144.636781	18.58820356	1084.02769

Se puede observar en la Figura 5.3, que se encuentran dos centros de grupos muy cercanos que corresponden a los valores [1144 18.5] y [1145 18.6] de temperatura y tiempo respectivamente, como se muestra en la Tabla 5.1, esto se debe a que en esta región hay mayor concentración

de datos y el algoritmo FCM tiende a balancear la cantidad de datos en cada grupo.

Con los centroides obtenidos utilizando FCM, los sistemas difusos quedan como se muestra en las Figuras 5.4, 5.5, 5.6. Los parámetros de este sistema Mamdani son los de la Tabla 5.2.

Tabla 5.2: Tabla de parámetros del sistema mamdani y sugeno de 9 o 25 reglas, según sea el caso.

Parámetros	
Nombre	FIS1
Tipo	mamdani, sugeno
# de entradas	2
Etiquetas de entrada	in1 and in2
# de salidas	1
Etiqueta de salida	out1
Etiqueta de salida	9 y 25
Método And	min
Método Or	max
Método Implicación	prod
Método agregación	max
Método defuzificación	centroid

En la Figura 5.4 se aprecian las funciones de pertenencia para la entrada **Temperatura** de un sistema Mamdani de 9 reglas obtenido a partir de la técnica FCM, el rango establecido para esta entrada es [1072 1192], con 9 funciones de pertenencia, las cuales tienen diferentes desviaciones estándar, que han sido generadas por el algoritmo FCM.

También para la entrada **Tiempo** se presenta la Figura 5.5 donde se aprecian las 9 funciones de pertenencia, el rango establecido para esta entrada es de [15 23], pero es mostrado en [16.5 20.5] para mejor apreciación, de la misma forma estas tienen diferentes desviaciones estándar establecidas por FCM.




Figura 5.4: Función de pertenencia para temperatura de entrada del sistema con 9 reglas generado por FCM.




Figura 5.5: Función de pertenencia para tiempo de entrada del sistema con 9 reglas generado por FCM.

Para las 9 funciones de pertenencia de salida **Temperatura** que se muestran en la Figura 5.6, el rango establecido es de $[1045 \ 1125]$, de igual manera estas funciones de pertenencia tienen diferentes desviaciones estándar establecidas por FCM.




Figura 5.6: Función de pertenencia para temperatura de salida del sistema con 9 reglas generado por FCM.

En las Figuras 5.4, 5.5, 5.6, se puede observar como las funciones de pertenencia no guardan un orden numérico creciente, a diferencia de el diseño mediante conocimiento empírico en donde desde la primera a la última función de pertenencia están establecidas a lo largo del rango de operación y tienen desviaciones estándar iguales.

En el diseño mediante la técnica de FCM se puede ver que al establecer los centros de las funciones de pertenencia, ubica cada una de estas funciones precisamente donde el sistema mejor se desempeñará. Se podría decir que el sistema difuso al ser generado por FCM tiene cierta similitud con un sistema difuso con entrenamiento. Por lo que se puede observar que cada

función de pertenencia está ubicada en un punto específico dentro del rango de trabajo, y éstas tienen sus correspondientes posiciones dentro del rango de trabajo de salida.

Las 9 reglas para este sistema quedan establecidas como se muestran a continuación en la ecuación 5.5.1:

$$\text{If (in1 is in1c}(i)) \text{ and (in2 is in2c1}(i)) \text{ then (out1 is out1c1}(i)) \quad (5.5.1)$$

donde $i = 1, \dots, 9$ para sistemas con 9 reglas. La estructura de las reglas es siempre la misma entrada 1 en cluster i , entrada 2 en cluster i y salida en cluster i , estas reglas aportan la estructura y posición de los centroides que corresponde a cada entrada y salida.

Definimos que entrada uno “in1” es temperatura medida en el RM y entrada dos “in2” es tiempo de traslado, y salida uno “out1” es temperatura en le SB y “c(i)” son los clusters. En estas reglas se observa cómo cada entrada temperatura y tiempo corresponde a una salida en particular, es decir por ejemplo en la regla uno, si la entrada “in1” corresponde al cluster “c1” y la entrada “in2” corresponde al cluster “c1” la salida “out1” corresponde al cluster “outc1”, y esto aplica para todas las demás reglas, a diferencia de las reglas empíricas donde se realiza combinación de estas.

5.5.2. Aplicación de FCM en la obtención de un sistema difuso de 25 reglas

De la misma forma que en el caso del diseño del sistema con 9 reglas aplicando FCM, se utiliza temperatura de salida del RM y tiempo de traslado para la entradas y temperatura a la salida del SB como salida. Se toma el mismo conjunto de datos, esto es llevado a cabo con la función *fcm* de MatLab que generará centros de cluster que indican donde estarán ubicados los centros de cada función de pertenencia gaussina, respectivamente para las entradas y salidas

del sistema.

Como se realizó en el caso de 9 reglas el algoritmo FCM utiliza los datos de entrada y de salida del sistema para minimizar la función objetivo. En general el desempeño del algoritmo FCM de 9 y 25 reglas es gráficamente muy parecido.

En la Figura 5.7 se observa donde se encuentran ubicados los centros de cada grupo para las entradas.




Figura 5.7: Ubicación de los centroides de cada grupo.

Como se puede apreciar en la Figura 5.7 al igual que en el caso de 9 reglas, algunos grupos contienen número de datos con valores semejantes por lo que los centros de éstos son cercanos. Así los centros de cada grupo que se ha formado para las entradas y salidas del sistema, se utilizan para ubicar las medias de cada función de pertenencia gaussiana, esto quiere decir que se tendrán 25 funciones de pertenencia para la entrada de temperatura, 25 para la entrada de tiempo, 25 para la salida del sistema es decir la temperatura a la entrada del SB. A continuación

se muestra en la Tabla 5.3 los centros respectivos para las entradas y salidas del sistema difuso.

Tabla 5.3: Tabla de centroides para sistema de 25 reglas.

	Centroides		
	Temp.entr.	Tiempo	Temp.sal.
1	1143.7088	18.4279612	1114.8907
2	1148.2976	18.7118648	1070.0214
3	1123.2423	18.3266463	1095.5381
4	1096.3852	17.7763476	1063.7505
5	1141.3976	18.4257234	1104.4117
6	1135.6011	18.4728531	1085.8179
7	1123.6206	18.1629561	1064.5794
8	1160.5214	18.9796855	1081.3401
9	1153.1096	18.4704587	1105.8227
10	1136.1926	18.4635579	1067.7562
11	1131.7727	18.3302556	1104.5988
12	1146.2794	18.6514125	1082.7366
13	1164.8822	18.7688603	1100.7024
14	1133.3188	18.4331697	1093.9991
15	1122.8772	18.3766112	1086.502
16	1154.8744	18.7429217	1092.7837
17	1121.7533	18.059911	1053.169
18	1134.2768	18.3113207	1076.7566
19	1144.1883	18.5900629	1094.1401
20	1120.7057	18.2006494	1076.771
21	1106.9172	17.6518148	1054.2974
22	1110.3385	17.9412374	1070.4062
23	1139.0363	18.4839634	1056.2752
24	1111.5693	18.173742	1083.1923
25	1156.4305	18.2370824	1117.5499

Utilizando los centroides de la Tabla 5.3, el conjuntos difusos quedan como se muestra en las Figura 5.8, 5.9, 5.10, que son las respectivas entradas y salidas. Los parámetros de este sistema Mamdani son los mismos descritos en la Tabla 5.2.

En la Figura 5.8 se aprecian las funciones de pertenencia para la entrada temperatura de un sistema Mamdani de 25 reglas obtenido a partir de la técnica FCM, el rango establecido

para esta entrada es $[1072 \ 1192]$, con 25 funciones de pertenencia, las cuales tienen diferentes desviaciones estándar.




Figura 5.8: Función de pertenencia para temperatura de entrada del sistema con 9 reglas generado por FCM.

También para la entrada tiempo se presenta la Figura 5.9 en la cual se aprecian las 25 funciones de pertenencia, y el rango establecido para esta entrada es de $[15 \ 23]$, de la misma forma estas tienen diferentes desviaciones estándar establecidas por FCM.

En el caso de las 25 funciones de pertenencia de salida temperatura que se muestran en la Figura 5.10, el rango establecido es de $[1045 \ 1125]$, también estas funciones de pertenencia tienen diferentes desviaciones estándar establecidas por FCM.




Figura 5.9: Función de pertenencia para tiempo de entrada del sistema con 25 reglas generado por FCM




Figura 5.10: Función de pertenencia para temperatura de salida del sistema con 25 reglas generado por FCM

En las Figuras 5.8, 5.9, 5.10, se observa nuevamente como en el caso de 9 reglas como las funciones de pertenencia no guardan un orden ascendente o descendente. En el diseño mediante la técnica de FCM de el sistema con 25 reglas se puede ver que al establecer los centro de las funciones de pertenencia, ubica cada una de estas funciones donde mejor el sistema tendrá un buen desempeño, de la misma forma que sucedió con el sistema de 9 reglas.

Las 25 reglas para este sistemas quedan establecidas como se muestran a continuación en la ecuación 5.5.2.

$$\text{If (in1 is in1c}(i)) \text{ and (in2 is in2c1}(i)) \text{ then (out1 is out1c1}(i)) \quad (5.5.2)$$

donde $i = 1, \dots, 25$ para sistemas con 25 reglas.

5.6. Descripción de un modelo de Caja Gris

Un modelo de Caja Gris es conocido y encontrado en la literatura también con el nombre de sistemas híbridos y sistema semifísico. Un sistema de Caja Gris tiene la ventaja de considerar mas de una clase sistema dentro de su estructura, teniendo más flexibilidad en el modelado de fenómenos dinámicos. Básicamente un sistema de Caja Gris está constituido por dos sistemas de diferente naturaleza, el primero considerado como sistema físico que normalmente es un sistema matemático, en este caso particular es el modelo de planta, el segundo sistema considera diferente técnica al anterior, por ejemplo inteligencia artificial. Para estos sistemas se pueden considerar dos estructuras, serie (multiplicativo) y paralelo (aditivo). En este trabajo se considera al estructura en paralelo, como se ve en la Figura 5.11




Figura 5.11: Esquema de sistema de Caja Gris en paralelo (aditivo).

5.6.1. Modelado mediante Cajas Grises de la temperatura a la entrada del SB

Como se menciona anteriormente en este trabajo, se desarrollan varios sistemas que consisten de un modelo físico apoyado por un sistema de LD. Peculiarmente para el desarrollo de un modelo de Caja Gris aditivo (en paralelo) como se muestra en la Figura 5.12, se diseña un sistema de LD, cuyo propósito es generar un factor de compensación para la estimación del modelo físico. Esto a diferencia de los sistemas basados solamente en LD para la estimación de temperatura.

5.6.2. Arquitectura del sistema de Caja Gris difuso

Para implementar el sistema de Caja Gris que se propone, es necesario también el diseño de un sistema difuso en este caso se realizó mediante FCM, este sistema de Caja Gris modela el *error* de estimación del modelo de planta. De la misma forma que los sistemas difusos generados por FCM, las entradas al sistema de Caja Gris son *temperatura* y *tiempo*, y a la salida *temperatura*.

En la Figura 5.12, \hat{E}_{FIS} es el error del modelo +PI estimado por el sistema FIS; $\hat{T}_{mod.}$ es la temperatura estimada por el modelo físico; \hat{T}_{total} es la temperatura estimada por el modelo de

Caja Gris; T_{medida} es la temperatura medida en la planta; y E_{semi} es el error de estimación del modelo de Caja Gris.





Figura 5.12: Esquema de modelo de Caja Gris, cálculo de las medidas de desempeño a partir del error.


5.6.3. Análisis de los sistemas difusos utilizando FCM.

En esta sección se presenta la metodología utilizada para el análisis de resultados de los sistemas desarrollados mediante FCM, las medidas de desempeño se aplicarán al error de estimación de estos sistemas y serán comparados para observar su eficiencia en contra del sistema utilizado en planta y con los sistemas antes mencionados en la Sección 5.6.2.


Antes de presentar los resultados de FCM, se describirá rápidamente los sistemas empíricos utilizados en los trabajos [29–33], estos se utilizarán para compararlos con los obtenidos en este trabajo. En el sistema de la Figura 5.13 se puede observar las dos entradas y salida de un sistema FIS Mamdani de 9 reglas diseñado mediante conocimiento empírico, las funciones de pertenencia se ordenan a lo largo del rango de trabajo, y tienen las mismas desviaciones estándar.



(a) Entrada Temperatura



(b) Entrada Tiempo



(c) Temperatura de salida

Figura 5.13: Sistema FIS empírico con datos del laminador en caliente 3 de Ternium.

La Tabla 5.4, describe cada una de las reglas utilizadas en el sistema Mamdani de 9 reglas, descrito en la Figura 5.13, los resultados de estos sistemas se presentaran en la Tabla 5.53.

Tabla 5.4: Tabla de 9 reglas de un sistema FIS empírico.

Sistema de 9 reglas	
1.	If (Temperatura is Baja) and (Tiempo is Corto) then (Temp is Baja3)
2.	If (Temperatura is Baja) and (Tiempo is TimeMedio) then (Temp is Baja2)
3.	If (Temperatura is Baja) and (Tiempo is Largo) then (Temp is Baja1)
4.	If (Temperatura is TempMedia) and (Tiempo is Corto) then (Temp is Media3)
5.	If (Temperatura is TempMedia) and (Tiempo is TimeMedio) then (Temp is Media2)
6.	If (Temperatura is TempMedia) and (Tiempo is Largo) then (Temp is Media1)
7.	If (Temperatura is Alta) and (Tiempo is Corto) then (Temp is Alta3)
8.	If (Temperatura is Alta) and (Tiempo is TimeMedio) then (Temp is Alta2)
9.	If (Temperatura is Alta) and (Tiempo is Largo) then (Temp is Alta1)

En la sección 5.9.1, serán también presentados los resultados obtenidos con los sistemas diseñados de forma empírica (es decir FIS solos), y también sistemas diseñados por FCM aplicando modelado de Caja Gris difuso, esto es para los sistemas FIS, con aprendizaje y también el modelo de planta, estos resultados se muestran en las Tabla 5.53. Las comparaciones gráficas se muestran e interpretan en la sección 5.9.2, 5.9.3, 5.9.4 y 5.9.5.

5.7. Sistema Difuso Mamdani adaptable

Anteriormente se dieron antecedentes de sistemas Mamdani con adaptación, se mencionó que existen sistemas Neuro difusos y normalmente se utiliza el sistema difuso Sugeno con adaptación comúnmente conocido con el nombre de ANFIS, los cuales son los que se ha presentado hasta ahora. Los modelos difuso tipo Mamdani son intuitivos, proporcionan la perspicacia heurística y han recibido la aceptación extensa en los medios industriales y están bien adaptados en términos de interacciones con los seres humanos.

El interés de realizar un sistema Mamdani con adaptación se fundamenta en que son reconocidos en la literatura cómo más poderosos que el antes mencionados ANFIS. De un sistema ANFIS se obtienen salidas lineales, en cambio a la salida de un sistema Mamdani adaptativo se puede obtener una relación difusa que permita aproximar una función no lineal.

5.7.1. Implementación y evaluación de un sistema Mamdani con Adaptación

En esta sección se describe cómo el sistema Mamdani con adaptación es formado a partir de un sistema base, el cual es diseñado de forma empírica como se ha hecho inicialmente en [29–33], a partir de este sistema base el sistema Mamdani se adapta mediante un algoritmo de

aprendizaje híbrido, el cual encuentra la mejor respuesta con nuevas medias en las funciones de pertenencia, cabe aclarar que en [16] se avaluó para estimación de temperatura pero con otros datos, utilizando también aprendizaje híbrido, no en Caja Gris. La estructura del sistema Mamdani adaptable se muestra a continuación en la Figura 5.14.




Figura 5.14: Diagrama de bloques de Estructura Mamdani adaptable

En la Tabla 5.5 se puede observar las medias y desviación estándar de las MF del sistema base formado por 9 reglas, las etiquetas lingüísticas en este caso son numéricas, para temperatura de entrada las etiquetas son Baja (1102), Media (1132) y Alta (1162), para el Tiempo las etiquetas son bajo (17), medio (19), Alto (21), para la temperatura de salida se tienen 9 diferentes. Las desviaciones estándar para temperatura y tiempo son fijas.

Tabla 5.5: Sistema base de 9 reglas empírico para generación de sistema Mamdani con adaptación.

Reglas empíricas para el sistema de 9 reglas			Sigma desviación estándar		
Temp RM	Tiempo	Temp SB	sig.temp	sig.tiempo	sig.temp.salida
1102	17	1070	12.74	0.8495	3.318
1102	19	1063	12.74	0.8495	3.318
1102	21	1055	12.74	0.8495	3.318
1132	17	1093	12.74	0.8495	3.318
1132	19	1085	12.74	0.8495	3.318
1132	21	1077	12.74	0.8495	3.318
1162	17	1115	12.74	0.8495	3.318
1162	19	1107	12.74	0.8495	3.318
1162	21	1100	12.74	0.8495	3.318

El algoritmo del sistema Mamdani adaptativo toma el sistema base y mediante aprendizaje híbrido se obtiene un sistema adaptado, el cual será el sistema que se utilizará para realizar las simulaciones y evaluaciones. El sistema Mamdani adaptado se muestra en la Tabla 5.6.

Tabla 5.6: Sistema Mamdani de 9 reglas con adaptación, generado a partir del sistema base.

SISTEMA ADAPTADO			Sigma .desviacion est.	
Temp RM	Tiempo	Temp SB	sig.temp	sig.tiempo
1109.31527	28.1030284	1066.66306	38.2882479	35.7125372
1097.99503	2.17824701	1055.96366	39.6311116	46.0980997
1098.67202	7.69138242	1058.30267	37.5005782	35.4944071
1148.47813	32.2474918	1104.51552	26.9015724	34.2044755
1148.19442	25.9837512	1103.80902	26.8141834	25.123742
1151.41942	18.6651801	1105.79366	25.3019681	9.63444203
1154.76776	18.4732068	1107.73808	27.8639219	13.2578871
1154.52948	18.6925995	1106.46675	26.2868521	9.38913117
1154.55807	18.6939164	1106.55543	26.3701363	9.41192642

El sistema Mamdani adaptable utiliza datos de entrenamiento y como resultado todas las reglas del sistema fueron adaptadas a diferentes posiciones, como se puede ver en la Tabla 5.6, como consecuencia de esto se obtienen diferentes funciones de pertenencia con diferentes desviaciones estándar, cabe mencionar que en el sistema usado la desviación estándar de los conjuntos difusos de salida no se adaptan.

De la misma forma para generar un sistema Mamdani adaptable de 25 reglas, se tiene que tener un sistema base de 25 reglas, el cual se muestra en la Tabla 5.7. Se puede observar que este sistema está compuesto por 5 funciones de pertenencia para cada entrada temperatura (1092,1112,1132,1152,1172) y tiempo (10.33,17.67,19,20.34,21.66) y 25 funciones de pertenencia diferentes para la temperatura de salida. La desviaciones estándar para temperatura es 8.494 y para tiempo es 0.5662, éstas son las mismas para cada una de las funciones de pertenencia. El algoritmo de Mamdani adaptable no proporciona desviación estándar para la temperatura de salida en este sistema ni en ninguno de los presentados en las siguientes secciones.

Tabla 5.7: Sistema base de 25 reglas empírico para generación de sistema Mamdani con adaptación.

Reglas empíricas para el sistema de 9 reglas			Sigma desviación estandar	
Temp RM	Tiempo	Temp SB	sig.temp	sig.tiempo
1092	16.33	1061	8.494	0.5662
1092	17.67	1058	8.494	0.5662
1092	19	1055	8.494	0.5662
1092	20.34	1052	8.494	0.5662
1092	21.66	1049	8.494	0.5662
1112	16.33	1076	8.494	0.5662
1112	17.67	1073	8.494	0.5662
1112	19	1070	8.494	0.5662
1112	20.34	1067	8.494	0.5662
1112	21.66	1064	8.494	0.5662
1132	16.33	1091	8.494	0.5662
1132	17.67	1088	8.494	0.5662
1132	19	1085	8.494	0.5662
1132	20.34	1082	8.494	0.5662
1132	21.66	1079	8.494	0.5662
1152	16.33	1106	8.494	0.5662
1152	17.67	1103	8.494	0.5662
1152	19	1100	8.494	0.5662
1152	20.34	1097	8.494	0.5662
1152	21.66	1094	8.494	0.5662
1172	16.33	1122	8.494	0.5662
1172	17.67	1119	8.494	0.5662
1172	19	1116	8.494	0.5662
1172	20.34	1113	8.494	0.5662
1172	21.66	1110	8.494	0.5662

El Sistema base Mamdani de 25 reglas presentado en 5.7 es entrenado, por el algoritmo de aprendizaje Híbrido y se obtiene como resultado, un sistema Mamdani de 25 reglas adaptado, el cual contiene las nuevas MFs de Temperatura y Tiempo modificadas, además de las nuevas desviaciones estándares, como se muestra en la Tabla 5.8.

Tabla 5.8: Sistema Mamdani de 25 reglas con adaptación, generado a partir del sistema base.

SISTEMA ADAPTADO DE 25 REGLAS			Sigma desviación estándar	
Temp RM	Tiempo	Temp SB	sig.temp	sig.tiempo
1091.42277	13.97431504	1063.02176	8.755756658	0.301884667
1091.49137	14.08577296	1059.8133	8.746816839	0.221724411
1098.22651	25.05888279	1056.20874	29.61009738	-23.7883584
1096.75178	16.27882368	1054.95795	29.31223993	-13.8353928
1082.80505	15.1338244	1045.97666	1.220145834	-4.9830888
1111.44633	47.58390523	1067.39632	4.227823422	39.16455742
1111.9375	-38.8231995	1066.21333	15.10627312	67.58688984
1122.69664	12.8035667	1072.96385	22.58254339	-0.07059006
1107.16147	14.26468814	1067.01215	15.31258577	11.3705809
1112.78743	-2.16913318	1067.38841	3.676258278	-46.0265436
1140.01953	-33.7308845	1091.29924	19.24214252	-63.4807885
1141.21572	53.07152191	1091.65529	20.16997099	-46.7017716
1139.02927	36.08969424	1090.63289	19.11021084	24.24648245
1140.8534	22.96207848	1091.93451	19.39103838	-11.2717666
1140.2103	23.04139505	1091.07049	20.36631007	-11.2246879
1158.45013	13.73048753	1102.22654	-0.03957768	2.99601793
1150.51578	18.40550243	1099.77564	18.66002396	6.762249546
1151.35262	18.46584136	1099.90877	19.32227874	6.667105508
1150.67977	13.10078504	1099.15086	19.29146125	19.00613337
1150.77651	18.48789951	1099.52542	19.22060615	6.478848621
1164.67195	27.6209417	1102.46873	27.35529978	21.1012592
1172.02523	17.36285918	1118.99716	8.407422236	0.00859573
1163.22497	5.31204963	1103.85219	27.06068476	-29.7577207
1173.88333	38.93712675	1108.3889	2.801531433	-5.74506392
1162.08039	18.69629741	1103.55606	26.08448572	-6.94237204

En la Tabla 5.53 de la Sección 5.9.1 se presenta la comparación de los resultados de los sistemas Mamdani adaptados con sistemas Mamdani y Sugeno sin adaptación. También las comparaciones gráficas se muestran e interpretan en la sección 5.9.2.

5.7.2. Implementación y evaluación de un sistema de Caja Gris Mamdani con Adaptación

En ésta sección se realiza un análisis parecido al que se efectuó en la sección anterior, cabe mencionar que este sistema no ha sido propuesto antes en la literatura ni han sido evaluados

para esta aplicación. Son desarrollados los sistemas de Caja Gris difusos para los sistemas Mamdani adaptables. Se utiliza el mismo esquema presentado en el diagrama 5.11. El sistema de Caja Gris difuso Mamdani con adaptación estimará el error de predicción de la temperatura del Modelo de Planta.

En la Tabla 5.9 se observa la base de reglas de un modelo de Caja Gris formado por 9 reglas, donde las etiquetas lingüísticas son numéricas, se establece que la temperatura de entrada las etiquetas son Baja [1101], Media [1133] y Alta [1163], y para el Tiempo las etiquetas son bajo [17.25], medio [19.5], Alto (21.75), para la temperatura de salida se tienen 9 diferentes etiquetas. Las desviaciones estándar para Temperatura y Tiempo son fijas [13.17] y [0.9557] respectivamente.

Tabla 5.9: Modelado con Caja Gris para un sistema base de 9 reglas empírico para generación de sistema Mamdani con adaptación.

Reglas empírica 9reglas			Sigma desviación est.	
Temp RM	Tiempo	temp SB	sig.temp	sig.tiempo
1101	17.25	-46.63	13.17	0.9557
1101	19.5	-57.25	13.17	0.9557
1101	21.75	-67.88	13.17	0.9557
1133	17.25	-14.99	13.17	0.9557
1133	19.5	-25.73	13.17	0.9557
1133	21.75	-36.12	13.17	0.9557
1163	17.25	17.33	13.17	0.9557
1163	19.5	6.249	13.17	0.9557
1163	21.75	-4.139	13.17	0.9557

Este sistema Mamdani adaptable utiliza los datos de entrenamiento para lograr la adaptación híbrida y como resultado todas las reglas del sistema fueron adaptadas, como se puede ver en la Tabla 5.10.

Tabla 5.10: Modelado con Caja Gris para un Sistema Mamdani de 9 reglas con adaptación, generado a partir del sistema base.

SISTEMA ADAPTADO			Sigma desviación est.	
Temp RM	Tiempo	temp SB	sig.temp	sig.tiempo
1113.014415	19.70369469	44.63106922	-63.04515443	-22.40615646
1121.171759	-1.02677236	22.8726494	44.78946179	-88.53624235
1093.657965	31.62198782	-67.18476501	-1.00114416	0.744996573
1113.475037	19.67299098	43.40953074	62.04244528	21.96357417
1132.424224	12.58355297	-18.16489006	13.44499786	0.064538253
1165.569179	17.51342181	-23.82656852	0.04581462	-10.93317228
1116.158541	19.80563425	38.38700825	57.16008186	-21.57509178
1192.737661	12.30151143	-79.26866648	95.30728816	45.07872053
1191.930881	2.667908029	-84.02425055	96.51906497	79.43004908

Para generar un modelo de Caja Gris con un sistema Mamdani adaptable de 25 reglas, se tiene un sistema base de 25 reglas, el cual se muestra en la siguiente Tabla 5.11. Este sistema esta compuesto por 5 funciones de pertenencia para cada entrada de temperatura [1091,1111,1132,1153,1173] y de tiempo [16.5,18.0,19.5,21.0,22.5] y 25 funciones de pertenencia diferentes para la salida. Las desviaciones estándar para temperatura es [8.777] y para tiempo es [0.637], estas son las mismas para cada una de las funciones de pertenencia.

Tabla 5.11: Modelado con Caja Gris para un Sistema base de 25 reglas empírico para generación de sistema Mamdani con adaptación.

Reglas empíricas para el sistema de 25 reglas			Sigma desviación estándar	
Temp RM	Tiempo	Temp SB	sig.temp	sig.tiempo
1091	16.5	-59.61	8.777	0.637
1091	18.0	-63.90	8.777	0.637
1091	19.5	-68.20	8.777	0.637
1091	21.0	-72.50	8.777	0.637
1091	22.5	-77.02	8.777	0.637
1111	16.5	-38.13	8.777	0.637
1111	18.0	-42.42	8.777	0.637
1111	19.5	-46.72	8.777	0.637
1111	21.0	-51.02	8.777	0.637
1111	22.5	-55.31	8.777	0.637
1132	16.5	-16.65	8.777	0.637
1132	18.0	-20.94	8.777	0.637
1132	19.5	-25.24	8.777	0.637
1132	21.0	-29.54	8.777	0.637
1132	22.5	-33.83	8.777	0.637
1153	16.5	4.84	8.777	0.637
1153	18.0	0.54	8.777	0.637
1153	19.5	-3.76	8.777	0.637
1153	21.0	-8.058	8.777	0.637
1153	22.5	-12.35	8.777	0.637
1173	16.5	26.32	8.777	0.637
1173	18.0	22.01	8.777	0.637
1173	19.5	17.72	8.777	0.637
1173	21.0	13.42	8.777	0.637
1173	22.5	9.129	8.777	0.637

El Sistema base Mamdani de 25 reglas presentado en 5.11 es entrenado, por el algoritmo de aprendizaje híbrido y se obtiene como resultado, un sistema Mamdani de 25 reglas adaptado, el cual contiene las nuevas entradas y salidas de Temperatura y Tiempo modificadas, además de las nuevas desviaciones estándares, como se muestra en la Tabla 5.12.

Tabla 5.12: Modelo de Caja Gris con Sistema Mamdani de 25 reglas con adaptación, generado a partir del sistema base.

SISTEMA ADAPTADO DE 25 REGLAS			Sigma desviación estándar	
Temp RM	Tiempo	Temp SB	sig.temp	sig.tiempo
1090.8246	15.1179111	-59.593097	8.26076074	-0.0320658
1029.4254	1000.5574	-53.415808	-11.699679	-1248.6161
1068.0545	28.856614	-66.543221	-7.6924887	-2.1925098
1090.1705	23.7784941	-72.467112	6.53763784	0.4672959
1090.9765	22.7956541	-77.019162	8.69553238	-0.0352639
1089.6727	5.32617352	-26.82549	0.07014272	-9.9575189
883.85671	22.63938	19.808567	259.719812	-23.516036
1064.7303	53.0475834	-28.797507	-15.956819	-8.554296
1107.584	27.067048	37.41916	-58.403778	37.4291217
1094.1888	45.1353785	-47.452352	-12.39186	-5.1464579
1112.8645	19.766443	31.687239	51.8997741	16.7012333
1118.3602	19.7430942	24.664198	44.0892306	15.1956581
1123.3011	19.7079733	18.491973	36.8343952	13.6911295
1131.713	43.6121297	-25.069912	8.50725409	-4.7929877
1132.3598	28.2245049	-33.438352	8.14308731	-0.9146164
1124.0842	19.697222	17.527727	35.6280956	13.425613
1116.6126	19.7506591	26.898868	46.5947671	15.6906504
1186.2502	11.5079883	-68.052972	76.0708496	37.060302
1185.242	3.18465525	-72.695629	77.0046584	59.1692298
1186.2396	11.5165313	-67.581866	75.8579191	36.8828563
1201.5867	-9.6387434	13.285219	1.61892351	-18.382084
1175.4464	8.44069591	18.628811	6.94727091	1.38403868
1199.1243	-17.364467	14.143804	-0.5030582	-25.646492
1215.6035	43.3170868	2.6105812	12.7957129	-28.456666
1176.2748	26.7002971	8.464645	3.31037595	-0.5538862

Los resultados de los sistemas Mamdani adaptados con sistemas Mamdani y Sugeno sin adaptación se presenta en la Tabla 5.53 de la Sección 5.9.1 y las comparaciones gráficas se muestran e interpretan en las secciones 5.9.2, 5.9.3.

5.7.3. Implementación y evaluación de un sistema FCM Mamdani con Adaptación

A continuación en esta sección se describe cómo el sistema FCM Mamdani con adaptación es formado a partir de un sistema base, el cual es generado por FCM, a partir de este sistema base el sistema Mamdani se adapta mediante un algoritmo de aprendizaje híbrido.

La Tabla 5.13 presenta las medias y desviación estándar de las MF del sistema base formado por 9 reglas FCM, la temperatura de entrada es establecida en un rango de 1072 a 1192 °C y para el tiempo se establecen en un rango de 15 a 23 segundos, para la temperatura de salida se tiene un rango de 1045 a 1125 °C. Las desviaciones estándar para temperatura y tiempo se muestran en dicha tabla. En el sistema base FCM que es formado por 9 reglas, la temperatura de entrada tienen etiquetas numéricas para nombrar cada función gaussiana y son definidas dentro del rango de operación establecido y generado por FCM, a diferencia de los modelos diseñados mediante conocimiento empírico donde se establecieron etiquetas lingüísticas para temperaturas baja, media y alta. Para las etiquetas de tiempo y temperatura de salida se realizó lo mismo, fueron establecidas en el rango de operación mediante el algoritmo FCM. Las desviaciones estándar para temperatura y tiempo son fijas.

Tabla 5.13: Sistema base de 9 reglas FCM para generación de sistema Mamdani con adaptación.

Reglas FCM para el sistema de 9 reglas			Sigma desviación estándar		
Temp RM	Tiempo	Temp SB	sig.temp	sig.tiempo	sig.temp.salida
1116.581482	18.20177615	1080.699547	8.292548842	0.435128378	6.20541
1141.5997	18.5592134	1067.182074	5.881057396	0.447202883	8.28486
1103.558353	17.83600997	1061.195812	11.23852305	0.387294321	8.99918
1150.318734	18.4089501	1112.780636	6.973799201	0.415758058	10.28983
1124.480345	18.20823243	1061.783683	6.393481247	0.414429322	9.41180
1129.049682	18.42950966	1090.142235	6.22462673	0.478115932	6.36674
1157.525782	18.74446859	1095.250481	9.021854177	0.442548904	6.43389
1136.19071	18.40563673	1102.614731	5.704275236	0.457492807	8.03817
1144.636781	18.58820356	1084.02769	6.470533409	0.478172304	6.23769

El algoritmo del sistema Mamdani adaptativo toma el sistema base FCM y mediante aprendizaje híbrido se obtiene un sistema adaptado. El sistema Mamdani adaptado se muestra en la Tabla 5.14.

Tabla 5.14: Sistema Mamdani de 9 reglas con adaptación, generado a partir del sistema base FCM.

SISTEMA ADAPTADO			Sigma .desviacion est.	
Temp RM	Tiempo	Temp SB	sig.temp	sig.tiempo
1092.768803	170.1070205	1047.523741	66.11274035	-423.140267
1158.787055	31.43771681	1117.017543	38.13605614	-54.57795049
1091.949823	-120.3104824	1040.198256	70.29443335	306.9794491
1163.517172	18.71922621	1128.316394	51.16817896	14.65334607
1086.250749	-29.72755375	1024.6456	-84.35505752	164.2422558
1158.74763	72.09116432	1121.152433	41.22797175	-158.3310167
1161.659213	18.70292957	1121.866871	44.02638655	13.18432434
1160.180176	18.68424494	1116.544504	37.43305654	-11.90296171
1156.628892	18.07032896	1107.099667	25.47383966	-10.84580187

Se utilizan datos de entrenamiento para la adaptación y como resultado todas las reglas del sistema fueron colocadas en diferentes posiciones, como se puede ver en la Tabla 5.14, con esto se obtienen diferentes funciones de pertenencia con diferentes desviaciones estándar, cabe mencionar que en el sistema usado la desviación estándar de los conjuntos difusos de salida no se adaptan.

Para generar un sistema Mamdani FCM adaptable de 25 reglas, se tiene un sistema FCM base de 25 reglas, el cual se muestra en la Tabla 5.15. Se puede observar que este sistema está compuesto por diferentes funciones gaussianas para cada regla de entradas temperatura y tiempo y la salida temperatura, y todas son numéricas.

Tabla 5.15: Sistema base de 25 reglas FCM para generación de sistema Mamdani con adaptación.

Reglas FCM para el sistema de 25 reglas			Sigma desviación estándar		
Temp RM	Tiempo	Temp SB	sig.temp	sig.tiempo	sig.temp.salida
1143.7088	18.4279612	1114.8907	4.868	0.3289	9.438
1148.2976	18.7118648	1070.0214	5.739	0.35226673	6.446
1123.2423	18.3266463	1095.5381	5.758	0.3435947	5.587
1096.3852	17.7763476	1063.7505	11.650	0.31989407	7.101
1141.3976	18.4257234	1104.4117	4.853	0.34945371	7.063
1135.6011	18.4728531	1085.8179	4.799	0.36804041	5.157
1123.6206	18.1629561	1064.5794	5.544	0.32559585	7.453
1160.5214	18.9796855	1081.3401	8.413	0.34618426	4.978
1153.1096	18.4704587	1105.8227	6.566	0.33817918	7.193
1136.1926	18.4635579	1067.7562	4.648	0.3502952	6.925
1131.7727	18.3302556	1104.5988	4.737	0.34071278	7.108
1146.2794	18.6514125	1082.7366	5.548	0.36690925	5.159
1164.8822	18.7688603	1100.7024	9.444	0.3302543	5.983
1133.3188	18.4331697	1093.9991	4.810	0.36563596	5.513
1122.8772	18.3766112	1086.502	5.862	0.35283689	5.061
1154.8744	18.7429217	1092.7837	7.102	0.35700601	5.206
1121.7533	18.059911	1053.169	5.612	0.29890974	10.010
1134.2768	18.3113207	1076.7566	4.768	0.35432769	5.654
1144.1883	18.5900629	1094.1401	5.262	0.36962782	5.485
1120.7057	18.2006494	1076.771	6.172	0.33806253	5.535
1106.9172	17.6518148	1054.2974	8.791	0.35042419	9.486
1110.3385	17.9412374	1070.4062	8.258	0.31781125	6.180
1139.0363	18.4839634	1056.2752	4.536	0.3310805	9.318
1111.5693	18.173742	1083.1923	8.079	0.3211506	4.917
1156.4305	18.2370824	1117.5499	7.048	0.30284054	9.924

El Sistema base FCM Mamdani de 25 reglas presentado es entrenado por el algoritmo de aprendizaje híbrido y se obtiene como resultado un sistema Mamdani de 25 reglas adaptado, como se muestra en la Tabla 5.16.

Tabla 5.16: Sistema Mamdani de 25 reglas con adaptación, generado a partir del sistema base FCM.

SISTEMA ADAPTADO DE 25 REGLAS			Sigma desviación estándar	
Temp RM	Tiempo	Temp SB	sig.temp	sig.tiempo
1159.775	-3.2755341	1109.6032	32.3188243	49.4668266
1156.2851	18.4370746	1104.1725	23.5409854	-6.9048029
1155.0391	18.3570862	1103.5423	22.1036432	-6.9777489
1102.4784	16.9715638	1061.8901	39.133554	-23.639794
1155.4426	-22.589673	1107.977	27.9151889	66.4654757
1153.6559	18.0605096	1102.4029	19.8938563	7.20096699
1077.7246	17.6663142	1035.3003	73.723217	-30.185717
1148.1484	32.4455113	1099.5717	-29.828962	30.56743
1156.9604	11.4376077	1103.7309	3.3727782	0.22135992
1116.4713	78.6337625	1072.519	34.0099661	-83.540236
1155.2727	28.5579582	1104.7223	29.0182293	33.2919138
1156.0634	18.4244512	1103.9882	23.2086163	6.89696098
1162.6367	12.4455474	1096.1393	24.5877291	0.51047227
1152.4779	17.3880908	1101.6586	17.8529822	7.75191441
1147.9625	20.2345518	1099.5534	27.6903779	-12.090245
1156.2625	18.4128355	1107.2746	29.1053763	8.64268951
1094.511	17.5058508	1043.6322	-56.267312	28.7223269
1153.1365	42.0042251	1104.1989	-27.130641	-51.275664
1156.2993	18.462774	1106.7834	27.6003347	7.57347698
1111.2558	22.200502	1073.3331	-0.0334059	-23.496317
1084.2483	10.9902751	1040.6073	-62.615273	45.6496768
1109.9686	27.4109913	1070.7826	10.5572275	-40.457366
1109.8986	94.4902608	1065.6413	33.6670839	-111.70322
1112.2052	19.5289106	1073.5451	0.00238456	-14.489671
1168.1822	18.5226689	1119.9343	44.2969062	-9.8868548

Los resultados y comparación de todos los sistemas FCM, es decir Mamdani adaptados y sistemas FIS sin adaptación se presentan en la Tabla 5.53 de la Sección 5.9.1. Las comparaciones gráficas se muestran e interpretan en la sección 5.9.2, 5.9.3, 5.9.4.

5.7.4. Implementación y evaluación de un sistema de Caja Gris FCM Mamdani con Adaptación

En ésta sección se desarrollan los sistemas FCM con Caja Gris difusos para los modelos Mamdani adaptables, siguiendo el mismo desarrollo de las secciones anteriores. El sistema FCM Caja Gris difuso Mamdani con adaptación estimará el error de predicción de la temperatura del Modelo de Planta.

En la Tabla 5.17 se presenta la base de reglas de un sistema FCM Caja Gris formado por 9 reglas, donde las etiquetas numéricas son establecidas por el algoritmo FCM, a lo largo del rango de trabajo. Las desviaciones estándar para las entradas son también establecidas por FCM.

Tabla 5.17: Modelado con Caja Gris para un sistema base de 9 reglas empírico para generación de sistema Mamdani con adaptación.

Reglas FCM CG para el sistema de 9 reglas			Sigma desviación estándar		
Temp RM	Tiempo	Temp SB	sig.temp	sig.tiempo	sig.temp.salida
1125.49428	18.42376664	11.66657828	6.487694864	0.465744431	7.82011
1134.868259	18.13084033	-25.34291412	5.695906153	0.432092495	8.69472
1154.124977	18.63270212	-41.68362212	7.588118917	0.405851742	12.48121
1116.69121	17.93409524	-9.175619394	8.272869589	0.423545235	6.05486
1106.463303	18.04224771	9.965431279	10.69224686	0.386214951	6.94358
1140.073878	18.60073039	11.58832859	5.92483819	0.467721248	7.83289
1150.452278	18.63410676	-2.924098994	7.552646249	0.472308287	6.00626
1156.186961	18.72534253	-20.84328363	8.646107926	0.449754702	7.46540
1133.934513	18.35497272	-5.982985797	5.998972342	0.494371097	6.23100

Este sistema Mamdani adaptable utiliza los datos de entrenamiento y como resultado todas las reglas del sistema fueron adaptadas, como se puede ver en la Tabla 5.18.

Tabla 5.18: Modelado con Caja Gris para un Sistema Mamdani de 9 reglas con adaptación, generado a partir del sistema base.

SISTEMA ADAPTADO			Sigma .desviacion est.	
Temp RM	Tiempo	Temp SB	sig.temp	sig.tiempo
1114.91264	94.29090207	33.5526903	-54.96963302	-224.5771622
1187.042546	10.98812392	-76.6394672	86.080905	47.24864298
1150.205945	26.26674342	-40.32693492	2.964980819	-0.016448219
1113.196718	-120.7480673	33.16776679	-56.15134065	319.2249844
1113.095791	146.5474523	37.15370119	-58.26506396	-344.8603036
1139.783611	18.03539469	11.56705456	5.040983709	-0.003833441
1116.956361	19.69993093	24.32882165	48.21878848	16.34977652
1188.825301	12.18086443	-87.98483257	92.58231765	45.73569422
1114.028436	19.70854293	28.53793454	53.12640909	17.46371404

Para generar un modelo de FCM Caja Gris con un sistema Mamdani adaptable de 25 reglas, se tiene un sistema base de 25 reglas, el cual se muestra en la siguiente Tabla 5.19. Este sistema esta compuesto por funciones de pertenencia con etiquetas numéricas establecidas por FCM en el rango de trabajo correspondiente. Las desviaciones estándar para temperatura y tiempo de entrada también son las mismas, y son generadas por FCM.

Tabla 5.19: Modelado con Caja Gris para un Sistema base de 25 reglas FCM para generación de sistema Mamdani con adaptación.

Reglas FCM CG para el sistema de 25 reglas			Sigma desviación estándar		
Temp RM	Tiempo	Temp SB	sig.temp	sig.tiempo	sig.temp.salida
1122.781	18.30099	6.9113	5.845	0.3542	5.685
1155.691	18.67435	1.76383	7.332	0.3514	5.033
1095.207	17.86993	9.92293	12.008	0.30714	5.638
1145.669	18.54227	-22.219	5.397	0.35839	6.714
1128.265	18.11879	-2.0412	5.199	0.3497	5.033
1132.863	18.31652	-8.4779	4.884	0.36502	5.149
1126.722	18.59227	17.9145	5.126	0.35787	7.893
1138.316	18.49964	-1.4444	4.903	0.3737	5.076
1123.109	17.96183	-20.843	5.705	0.32601	6.457
1118.346	18.01246	-4.8494	6.652	0.33087	4.886
1155.461	18.86463	-13.947	7.257	0.36569	5.391
1134.162	18.61026	7.53343	4.802	0.3766	5.868
1139.486	18.52867	17.8438	4.725	0.34464	7.898
1166.542	19.12013	-39.636	9.554	0.35699	10.159
1133.253	18.21787	-20.703	4.760	0.34546	6.518
1137.012	18.19934	-32.904	4.552	0.32947	8.939
1112.861	18.14366	14.9346	7.599	0.31974	6.985
1149.451	18.47646	-34.166	5.773	0.33673	9.143
1151.506	18.38928	-49.077	5.861	0.30857	12.792
1142.914	18.51492	-12.427	5.187	0.36768	5.415
1109.18	17.62453	-12.972	8.562	0.37544	5.179
1145.158	18.47429	9.58316	5.378	0.35093	6.127
1162.346	18.78073	-23.726	8.783	0.34473	6.699
1148.551	18.59737	-3.7122	5.971	0.36646	4.942
1107.372	18.0262	6.94746	8.983	0.30845	5.421

Este Sistema base Mamdani de 25 reglas es entrenado por el algoritmo de aprendizaje híbrido y se obtiene un sistema Mamdani de 25 reglas adaptado, este nuevo sistema es presentado en la Tabla 5.20.

Tabla 5.20: Modelo de Caja Gris con Sistema Mamdani de 25 reglas con adaptación, generado a partir del sistema base.

SISTEMA ADAPTADO DE 25 REGLAS			Sigma desviación estándar	
Temp RM	Tiempo	Temp SB	sig.temp	sig.tiempo
1120.353	33.10809	20.4297	33.130	-28.4705
1130.252	2.385786	3.58964	20.777	-47.901
1106.716	44.42109	40.8231	52.050	-53.745
1145.771	9.361494	-13.662	-36.929	-15.154
1121.353	22.68128	16.5931	30.974	-14.471
1132.868	18.39854	-8.4802	4.872	0.06797
1129.3	11.72829	4.14305	-21.713	39.0102
1126.224	25.60109	12.8975	25.897	17.2449
1175.458	-33.4988	-38.627	114.342	126.441
1123.461	50.96466	14.8581	30.786	-88.007
1158.316	9.681802	-21.666	11.720	0.86589
1133.453	-13.7117	8.84311	3.879	-7.3068
1123.908	-6.79008	7.72441	27.531	64.8632
1180.489	74.22308	-48.675	46.755	154.73
1124.715	13.66981	-7.416	-23.971	-9.1873
1140.194	54.88758	-30.744	-1.783	-8.5158
1109.947	42.36578	36.6238	47.970	-48.525
1176.803	5.506203	-46.15	46.891	32.9049
1182.19	9.022624	-62.144	57.420	32.2234
1125.923	13.36241	-7.6669	24.446	-9.5486
1126.995	3.901126	4.51502	23.709	46.7993
1181.273	10.66914	-42.155	-49.772	23.0266
1175.831	9.607619	-41.262	45.086	-24.476
1131.578	25.0539	-0.776	17.195	0.16351
1110.655	38.44848	34.3992	46.205	-41.256

Los resultados de los Modelos FCM Caja Gris con Mamdani adaptable, y también los sistemas Mamdani y Sugeno sin adaptación, ANFIS y Modelo de Planta se presentan en la Tabla 5.53 de la Sección 5.9.1 y las comparaciones gráficas se muestran en las secciones 5.9.2, 5.9.3, 5.9.4 y 5.9.5.

5.8. Implementación y evaluación de sistemas difusos Tipo-2

En esta sección se realizará un análisis similar al realizado en secciones anteriores. Son desarrollados los sistemas FIS, Caja Gris y sistemas Mamdani adaptables tipo-2. Se utiliza el mismo esquema presentado en el diagrama 5.11. También se incluyen los sistemas Mamdani con adaptación y de Caja Gris difusos tipo-2, estos últimos estimarán el error de predicción para corregir la temperatura estimada por el Modelo de Planta.

5.8.1. Implementación y evaluación de un sistemas Mamdani tipo-2 con adaptación

Anteriormente se dieron antecedentes de sistemas Mamdani con adaptación de sistemas tipo-1 en la sección 5.7.1, y se realizó la implementación y evaluación de éstos en el molino de laminación en caliente, en esta sección se realiza un estudio similar aplicando sistemas Mamdani tipo-2.

De igual forma que para los sistemas tipo-1 en esta sección se describe como el sistema Mamdani con adaptación es formado a partir de un sistema base, el cual es diseñado de forma empírica, y a partir de este sistema base el sistema Mamdani se adapta mediante su algoritmo de aprendizaje híbrido, el cual encuentra una respuesta óptima modificando las medias de las funciones de pertenencia. La estructura del sistema Mamdani adaptable fue mostrado en la sección 5.7.1.

En las Tablas 5.21 y 5.22 se observa el sistema base para un modelo mamdani tipo-2 con adaptación formado por 9 reglas, este sistema se divide en dos tablas debido a que cada función de pertenencia contiene 2 funciones gaussianas donde las etiquetas lingüísticas para cada función de pertenencia son numéricas, la temperatura de entrada es establecida en un

rango de 1072 a 1192 $^{\circ}C$ y para el Tiempo se establece un rango de 15 a 23 segundos, para la temperatura de salida se tiene un rango de 1045 a 1125 $^{\circ}C$. Las desviaciones estándar para Temperatura y Tiempo se muestran en la tabla 5.21 y 5.22. Se puede observar el sistema base formado por 9 reglas, para temperatura de entrada las etiquetas para la primera y segunda función gaussiana son para un temperatura baja (1102 1104), para una media (1132 1134) y para la alta (1162 1164), para el Tiempo las etiquetas en tiempo bajo es (17 19), medio (19 21), alto (21 23), para la temperatura de salida se tienen 9 pares diferentes. Las desviaciones estándar para temperatura y tiempo son fijas para todas las MFs, pero si son adaptadas.

Tabla 5.21: Primeras funciones gaussianas para el Modelado de un Sistema base de 9 reglas empírico para generación de sistemas Mamdani tipo 2 con adaptación.

Reglas empíricas para el Modelo de 9 reglas tipo-2			Sigma desviación estandar		
Temp RM	Tiempo	Temp SB	sig.temp	sig.tiempo	sig.tem.salida
1102	17	1070	12.74	0.8495	3.318
1102	19	1063	12.74	0.8495	3.318
1102	21	1055	12.74	0.8495	3.318
1132	17	1093	12.74	0.8495	3.318
1132	19	1085	12.74	0.8495	3.318
1132	21	1077	12.74	0.8495	3.318
1162	17	1115	12.74	0.8495	3.318
1162	19	1107	12.74	0.8495	3.318
1162	21	1100	12.74	0.8495	3.318

Tabla 5.22: Segundas funciones gaussianas para el Modelado de un Sistema base de 9 reglas empírico para generación de sistemas Mamdani tipo 2 con adaptación.

Reglas empíricas para el Modelo de 9 reglas tipo-2			Sigma desviación estandar		
Temp RM	Tiempo	Temp SB	sig.temp	sig.tiempo	sig.tem.salida
1104	19	1072	12.74	0.8495	3.318
1104	21	1065	12.74	0.8495	3.318
1104	23	1057	12.74	0.8495	3.318
1134	19	1095	12.74	0.8495	3.318
1134	21	1087	12.74	0.8495	3.318
1134	23	1079	12.74	0.8495	3.318
1164	19	1117	12.74	0.8495	3.318
1164	21	1109	12.74	0.8495	3.318
1164	23	1102	12.74	0.8495	3.318

Tomando como base el sistema anterior el algoritmo de aprendizaje híbrido obtiene como resultado un sistema adaptado, el cual será el sistema que se utilizará para realizar las simulaciones y evaluaciones de estimación de temperatura en el molino. El sistema Mamdani adaptado se muestra en las Tablas 5.23 y 5.24, para el par de funciones gaussianas.

Tabla 5.23: Primeras funciones gaussianas para el Modelado de un Sistema base de 9 reglas empírico para generación de sistemas Mamdani tipo 2 con adaptación, generado a partir del sistema base.

SISTEMA ADAPTADO			Sigma .desviacion est.	
Temp RM	Tiempo	Temp SB	sig.temp	sig.tiempo
1104.399	16.57224	1065.488	17.84674	31.64584
1102.67	6.89032	1062.961	26.59221	36.50341
1096.989	17.23253	1049.884	42.00004	21.03752
1143.54	18.08761	1091.53	20.45312	19.75047
1145.151	20.24378	1098.019	21.7789	14.1568
1142.322	22.02058	1096.08	24.46579	11.2531
1156.125	12.46068	1106.255	26.59241	23.08587
1156.737	18.6218	1103.265	26.49181	7.639815
1156.713	6.947816	1101.653	25.87849	55.08375

Tabla 5.24: Segundas funciones gaussianas para el Modelado de un Sistema base de 9 reglas empírico para generación de sistemas Mamdani tipo 2 con adaptación, generado a partir del sistema base.

SISTEMA ADAPTADO			Sigma .desviacion est.	
Temp RM	Tiempo	Temp SB	sig.temp	sig.tiempo
1106.923	-25.5212	1065.044	17.84674	31.64584
1101.941	14.86648	1063.575	26.59221	36.50341
1097.672	18.26551	1053.672	42.00004	21.03752
1145.185	33.89171	1104.363	20.45312	19.75047
1145.883	21.06387	1100.011	21.7789	14.1568
1145.143	19.57292	1095.227	24.46579	11.2531
1159.404	11.38386	1103.57	26.59241	23.08587
1157.223	18.50303	1105.24	26.49181	7.639815
1156.433	9.230323	1102.432	25.87849	55.08375

A continuación utilizando el mismo análisis y de la misma forma que para generar un sistema Mamdani adaptable de 25 reglas, es necesario tener un sistema base de 25 reglas, el cual se muestra en las siguientes Tablas 5.25 y 5.26. Se puede observar que este sistema esta compuesto por 5 funciones de pertenencia para cada entrada temperatura ([1092 1094],[1112 1114],[1132 1134],[1152 1154],[1172 1174]) y tiempo ([10.33 10.53],[17.67 17.87],[19.00 19.20],[20.34 20.54],[21.66 21.86]) y 25 funciones de pertenencia diferentes para la salida. La desviaciones estándar para temperatura es 8.494 y para tiempo es 0.5662, estas son las mismas para cada una de las funciones de pertenencia.

Tabla 5.25: Primeras gaussianas para el sistema base de 25 reglas empírico para generación de sistema Mamdani con adaptación.

Reglas empíricas para el sistema de 25 reglas			Sigma desviación estándar	
Temp RM	Tiempo	Temp SB	sig.temp	sig.tiempo
1092	16.33	1061	8.494	0.5662
1092	17.67	1058	8.494	0.5662
1092	19	1055	8.494	0.5662
1092	20.34	1052	8.494	0.5662
1092	21.66	1049	8.494	0.5662
1112	16.33	1076	8.494	0.5662
1112	17.67	1073	8.494	0.5662
1112	19	1070	8.494	0.5662
1112	20.34	1067	8.494	0.5662
1112	21.66	1064	8.494	0.5662
1132	16.33	1091	8.494	0.5662
1132	17.67	1088	8.494	0.5662
1132	19	1085	8.494	0.5662
1132	20.34	1082	8.494	0.5662
1132	21.66	1079	8.494	0.5662
1152	16.33	1106	8.494	0.5662
1152	17.67	1103	8.494	0.5662
1152	19	1100	8.494	0.5662
1152	20.34	1097	8.494	0.5662
1152	21.66	1094	8.494	0.5662
1172	16.33	1122	8.494	0.5662
1172	17.67	1119	8.494	0.5662
1172	19	1116	8.494	0.5662
1172	20.34	1113	8.494	0.5662
1172	21.66	1110	8.494	0.5662

Tabla 5.26: Segundas gaussianas para el sistema base de 25 reglas empírico para generación de sistema Mamdani con adaptación.

Reglas empíricas para el sistema de 25 reglas			Sigma desviación estándar	
Temp RM	Tiempo	Temp SB	sig.temp	sig.tiempo
1094	16.53	1063	8.494	0.5662
1094	17.87	1060	8.494	0.5662
1094	19.2	1057	8.494	0.5662
1094	20.54	1054	8.494	0.5662
1094	21.86	1051	8.494	0.5662
1114	16.53	1078	8.494	0.5662
1114	17.87	1075	8.494	0.5662
1114	19.2	1072	8.494	0.5662
1114	20.54	1069	8.494	0.5662
1114	21.86	1066	8.494	0.5662
1134	16.53	1093	8.494	0.5662
1134	17.87	1090	8.494	0.5662
1134	19.2	1087	8.494	0.5662
1134	20.54	1084	8.494	0.5662
1134	21.86	1081	8.494	0.5662
1154	16.53	1108	8.494	0.5662
1154	17.87	1105	8.494	0.5662
1154	19.2	1102	8.494	0.5662
1154	20.54	1099	8.494	0.5662
1154	21.86	1096	8.494	0.5662
1174	16.53	1124	8.494	0.5662
1174	17.87	1121	8.494	0.5662
1174	19.2	1118	8.494	0.5662
1174	20.54	1115	8.494	0.5662
1174	21.86	1112	8.494	0.5662

El Sistema base Mamdani de 25 reglas presentado en la Tabla 5.25 y 5.26 es entrenado, por el algoritmo de aprendizaje híbrido y se obtiene como resultado, un sistema Mamdani de 25 reglas adaptado, el cual contiene las nuevas entradas y salidas de Temperatura y Tiempo modificadas, además de las nuevas desviaciones estándares, como se muestra en las Tablas 5.27 y 5.28.

Tabla 5.27: Primeras gaussianas del sistema Mamdani de 25 reglas con adaptación, generado a partir del sistema base.

SISTEMA ADAPTADO DE 25 REGLAS			Sigma desviación estándar	
Temp RM	Tiempo	Temp SB	sig. temp	sig. tiempo
1091.822	15.31869	1047.219	23.90705	0.021024
1095.345	15.77522	1057.407	19.23826	9.829291
1094.788	23.94402	1054.645	22.06223	17.77296
1093.232	15.7716	1052.225	21.69445	10.75993
1091.764	24.2612	1049.262	8.175413	0.537295
1113.517	49.71471	1069.15	4.452366	40.14395
1121.061	-1.692652	1069.501	19.24868	70.14326
1105.799	19.28994	1069.206	0.047096	4.390103
1108.412	17.72704	1067.226	4.550285	7.743297
1112.917	23.60226	1069.04	41.62005	15.16974
1138.431	-3.348102	1093.021	17.47852	43.41347
1138.46	33.76113	1092.136	18.44633	37.38143
1137.562	87.07931	1088.512	21.02327	101.7042
1137.053	22.2534	1088.462	21.45791	8.998997
1136.571	22.94119	1085.498	23.57359	10.7288
1151.384	16.30767	1098.698	20.12018	30.2225
1151.273	18.36397	1098.65	19.86108	6.01856
1153.243	18.41548	1098.213	21.06756	5.7951
1153.4	15.92947	1094.184	21.21755	18.80308
1151.82	18.37885	1096.333	20.08061	5.366231
1165.04	15.79556	1119.171	24.50803	1.952316
1173.169	15.27379	1117.644	6.422476	0.045675
1166.123	10.53271	1103.373	28.50332	27.71021
1171.962	28.45357	1105.236	0.160234	12.03502
1172.601	23.52359	1107.89	15.71362	0.092476

Tabla 5.28: Segundas gaussianas del sistema Mamdani de 25 reglas con adaptación, generado a partir del sistema base.

SISTEMA ADAPTADO DE 25 REGLAS			Sigma desviación estándar	
Temp RM	Tiempo	Temp SB	sig. temp	sig. tiempo
1105.814	17.29514	1063.358	23.90705	0.021024
1096.218	15.62165	1058.209	19.23826	9.829291
1093.963	22.41076	1055.622	22.06223	17.77296
1092.398	15.52572	1053.193	21.69445	10.75993
1093.767	23.57807	1051.164	8.175413	0.537295
1112.556	16.5178	1072.407	4.452366	40.14395
1117.007	-13.54838	1068.693	19.24868	70.14326
1106.309	20.14333	1070.808	0.047096	4.390103
1113.528	19.14901	1069.558	4.550285	7.743297
1122.345	19.38484	1069.474	41.62005	15.16974
1138.59	-6.586726	1093.222	17.47852	43.41347
1139.046	30.62384	1092.272	18.44633	37.38143
1138.144	20.01249	1089.178	21.02327	101.7042
1138.855	22.60783	1089.524	21.45791	8.998997
1137.964	23.12537	1086.745	23.57359	10.7288
1152.576	31.04854	1101.898	20.12018	30.2225
1152.66	18.35415	1102.219	19.86108	6.01856
1153.682	18.35599	1101.505	21.06756	5.7951
1155.213	12.88165	1099.867	21.21755	18.80308
1152.936	18.40886	1100.304	20.08061	5.366231
1177.415	31.31714	1111.301	24.50803	1.952316
1174.25	16.14215	1119.177	6.422476	0.045675
1171.124	7.746398	1107.263	28.50332	27.71021
1179.236	32.33738	1105.267	0.160234	12.03502
1177.566	23.69839	1109.673	15.71362	0.092476

Las tablas con la comparación de los resultados de los sistemas tipo-2 Mamdani con y sin adaptación y Sugeno son presentados en la Tabla 5.54 de la Sección 5.9.6 y las comparaciones gráficas se muestran en la sección 5.9.7.

5.8.2. Implementación y evaluación de un sistema de Caja Gris Mamdani con Adaptación tipo-2

En esta sección se desarrollan y evalúan los sistemas de Caja Gris difusos para los sistemas Mamdani adaptables tipo-2. Se utiliza el mismo esquema presentado en el diagrama 5.11, y por lo tanto el sistema de Caja Gris difuso Mamdani con adaptación estimará el error de predicción para corregir la temperatura que el Modelo de Planta estima.

En la Tabla 5.29 y 5.30 se observa el sistema base para el modelo de Caja Gris formado por 9 reglas, se establece que para temperatura de entrada las etiquetas para la primera y segunda función gaussiana son temperatura Bajas [1102 1108], Media [1132 1138] y Alta [1162 1168], y para el Tiempo las etiquetas en tiempo Bajo [17 17.4], Medio [19 19.4], Alto [21 21.4], para la temperatura de salida se tienen 9. Las desviaciones estándar para Temperatura entrada, Tiempo y Temperatura de salida son fijas [12.75], [0.8495] y [4.237] respectivamente.

Tabla 5.29: Primera gaussiana del Modelado con Caja Gris para un Sistema base de 9 reglas empírico para generación de sistema Mamdani con adaptación tipo-2.

Reglas empíricas para el Modelo de 9 reglas			Sigma desviación estandar		
Temp RM	Tiempo	Temp SB	sig.temp	sig.tiempo	sig.temp
1102	17	-46.63	12.75	0.8495	4.237
1102	19	-57.25	12.75	0.8495	4.237
1102	21	-67.88	12.75	0.8495	4.237
1132	17	-14.99	12.75	0.8495	4.237
1132	19	-25.73	12.75	0.8495	4.237
1132	21	-36.12	12.75	0.8495	4.237
1162	17	17.33	12.75	0.8495	4.237
1162	19	6.249	12.75	0.8495	4.237
1162	21	-4.139	12.75	0.8495	4.237

Tabla 5.30: Segunda gaussiana del Modelado con Caja Gris para un Sistema base de 9 reglas empírico para generación de sistema Mamdani con adaptación tipo-2.

Reglas empíricas para el Modelo de 9 reglas			Sigma desviación estandar		
Temp RM	Tiempo	Temp SB	sig.temp	sig.tiempo	sig.temp
1108	17.4	-44.63	12.75	0.8495	4.237
1108	19.4	-55.25	12.75	0.8495	4.237
1108	21.4	-65.88	12.75	0.8495	4.237
1138	17.4	-12.99	12.75	0.8495	4.237
1138	19.4	-23.73	12.75	0.8495	4.237
1138	21.4	-34.12	12.75	0.8495	4.237
1168	17.4	19.33	12.75	0.8495	4.237
1168	19.4	8.249	12.75	0.8495	4.237
1168	21.4	-2.139	12.75	0.8495	4.237

El sistema anterior es tomado como base por el algoritmo de aprendizaje híbrido. El sistema adaptado se utilizará para realizar las simulaciones y evaluaciones de estimación de temperatura en el molino, este sistema adaptado se muestra a continuación en las Tablas 5.31 y 5.32, para el par de funciones gaussianas. Se puede observar que como resultado todas las reglas del sistema fueron adaptadas a diferentes posiciones.

Tabla 5.31: Primera gaussiana del Modelado con Caja Gris para un Sistema Mamdani tipo-2 de 9 reglas con adaptación, generado a partir del sistema base.

SISTEMA ADAPTADO			Sigma .desviacion est.	
Temp RM	Tiempo	Temp SB	sig.temp	sig.tiempo
1070.995	-5.63902	-15.196	60.67925	0.035829
1119.903	35.67118	-37.0587	38.4874	0.233044
1094.804	26.25837	-46.5659	9.862163	62.40901
1114.362	19.80082	44.32847	54.80579	21.18202
1121.859	20.06233	32.72612	45.86054	19.02826
1197.329	11.59986	-72.4175	82.57261	38.63106
1118.168	19.92822	36.99822	49.78442	20.01842
1154.129	6.509014	-17.1122	59.63189	29.34296
1191.348	10.32645	-74.3195	76.0117	35.80293

Tabla 5.32: Segunda gaussiana del Modelado con Caja Gris para un Sistema Mamdani tipo-2 de 9 reglas con adaptación, generado a partir del sistema base.

SISTEMA ADAPTADO			Sigma .desviacion est.	
Temp RM	Tiempo	Temp SB	sig.temp	sig.tiempo
1094.594	21.10416	-32.2803	60.67925	0.035829
1114.353	36.37518	-39.6839	38.4874	0.233044
1182.164	31.91307	-57.7751	9.862163	62.40901
1120.744	20.602	64.73189	54.80579	21.18202
1123.767	20.42571	46.2514	45.86054	19.02826
1184.919	8.209831	-81.5415	82.57261	38.63106
1122.553	20.56912	54.29751	49.78442	20.01842
1179.684	20.6761	-28.3938	59.63189	29.34296
1184.275	9.837279	-56.2233	76.0117	35.80293

En la generación de un Modelo de Caja Gris con un Sistema Mamdani adaptable de 25 reglas, se tiene un sistema base de 25 reglas, el cual se muestra en las siguientes Tablas 5.33 y 5.34. Este sistema esta compuesto por 5 pares de funciones de pertenencia para cada entrada de temperatura [1092 1094,1112 1114,1132 1134,1152 1154,1172 1174] y de tiempo [16.33 16.53,17.67 17.87,19.00 19.20,20.54,21.86] y 25 pares de funciones de pertenencia diferentes para la salida. Las desviaciones estándar para temperatura es [8.777], para tiempo es [0.5662], y temperatura de salida es de [1.56], estas son las mismas para cada una de las funciones de pertenencia.

Tabla 5.33: Primera gaussiana del Modelado con Caja Gris para un Sistema base de 25 reglas empírico para generación de sistema Mamdani con adaptación tipo-2.

Reglas empíricas para el Modelo de 25 reglas			Sigma desviación estandar		
Temp RM	Tiempo	Temp SB	sig.temp	sig.Tiempo	sig.temp
1092	16.33	-59.61	8.777	0.5662	1.56
1092	17.67	-63.9	8.777	0.5662	1.56
1092	19	-68.2	8.777	0.5662	1.56
1092	20.34	-72.5	8.777	0.5662	1.56
1092	21.66	-77.02	8.777	0.5662	1.56
1112	16.33	-38.13	8.777	0.5662	1.56
1112	17.67	-42.42	8.777	0.5662	1.56
1112	19	-46.72	8.777	0.5662	1.56
1112	20.34	-51.02	8.777	0.5662	1.56
1112	21.66	-55.31	8.777	0.5662	1.56
1132	16.33	-16.65	8.777	0.5662	1.56
1132	17.67	-20.94	8.777	0.5662	1.56
1132	19	-25.24	8.777	0.5662	1.56
1132	20.34	-29.54	8.777	0.5662	1.56
1132	21.66	-33.83	8.777	0.5662	1.56
1152	16.33	4.837	8.777	0.5662	1.56
1152	17.67	0.5356	8.777	0.5662	1.56
1152	19	-3.757	8.777	0.5662	1.56
1152	20.34	-8.058	8.777	0.5662	1.56
1152	21.66	-12.35	8.777	0.5662	1.56
1172	16.33	26.32	8.777	0.5662	1.56
1172	17.67	22.01	8.777	0.5662	1.56
1172	19	17.72	8.777	0.5662	1.56
1172	20.34	13.42	8.777	0.5662	1.56
1172	21.66	9.129	8.777	0.5662	1.56

Tabla 5.34: Segunda gaussiana del Modelado con Caja Gris para un Sistema base de 25 reglas empírico para generación de sistema Mamdani con adaptación tipo-2.

Reglas empíricas para el Modelo de 25 reglas			Sigma desviación estandar		
Temp RM	Tiempo	Temp SB	sig.temp	sig.tiempo	sig.temp
1094	16.53	-57.61	8.777	0.5662	1.56
1094	17.87	-61.9	8.777	0.5662	1.56
1094	19.2	-66.2	8.777	0.5662	1.56
1094	20.54	-70.5	8.777	0.5662	1.56
1094	21.86	-75.02	8.777	0.5662	1.56
1114	16.53	-36.13	8.777	0.5662	1.56
1114	17.87	-40.42	8.777	0.5662	1.56
1114	19.2	-44.72	8.777	0.5662	1.56
1114	20.54	-49.02	8.777	0.5662	1.56
1114	21.86	-53.31	8.777	0.5662	1.56
1134	16.53	-14.65	8.777	0.5662	1.56
1134	17.87	-18.94	8.777	0.5662	1.56
1134	19.2	-23.24	8.777	0.5662	1.56
1134	20.54	-27.54	8.777	0.5662	1.56
1134	21.86	-31.83	8.777	0.5662	1.56
1154	16.53	6.837	8.777	0.5662	1.56
1154	17.87	2.5356	8.777	0.5662	1.56
1154	19.2	-1.757	8.777	0.5662	1.56
1154	20.54	-6.058	8.777	0.5662	1.56
1154	21.86	-10.35	8.777	0.5662	1.56
1174	16.53	28.32	8.777	0.5662	1.56
1174	17.87	24.01	8.777	0.5662	1.56
1174	19.2	19.72	8.777	0.5662	1.56
1174	20.54	15.42	8.777	0.5662	1.56
1174	21.86	11.129	8.777	0.5662	1.56

El Sistema base Mamdani de 25 reglas presentado es entrenado por el algoritmo de aprendizaje híbrido y se obtiene como resultado un sistema Mamdani de 25 reglas adaptado, el cual contiene las nuevas entradas y salidas de Temperatura y Tiempo modificadas, además de las nuevas desviaciones estándares, como se muestra en las Tablas 5.35 y 5.36.

Tabla 5.35: Primera gaussiana del Modelado con Caja Gris para Sistema Mamdani tipo-2 de 25 reglas con adaptación, generado a partir del sistema base.

SISTEMA ADAPTADO DE 25 REGLAS			Sigma desviación estándar	
Temp RM	Tiempo	Temp SB	sig.temp	sig.tiempo
1062.384	-945.6819	-16.68202	0.370472	118680.7
1072.981	410.9625	-37.29728	0.29003	503.7301
1072.981	97.66028	-58.87968	0.204678	239.5663
1125.885	56.43937	-9.137414	111.0968	80.99731
1101.809	46.39886	-75.30256	19.14988	0.345653
1102.742	-6.847835	-16.70064	40.99492	7.484603
1109.074	15.82161	-17.46191	36.76033	5.57192
1107.039	49.92313	22.72253	88.39633	58.48153
1129.988	45.82742	-13.44122	550.7403	45.64108
1121.187	46.62205	-47.89479	22.87665	0.065129
1122.887	20.71848	78.51496	53.72473	22.3053
1107.141	27.12051	22.27378	33.88262	0.464047
1122.9	27.03208	21.75534	29.41759	0.147923
1188.488	9.494137	-70.298	62.46318	30.64016
1133.547	28.11893	-19.46954	0.022001	24.05827
1111.857	26.23403	22.08475	32.03486	0.109549
1109.58	26.80061	25.5783	33.65767	0.099258
1130.893	22.53165	61.95642	38.70562	19.62418
1194.054	9.336918	-88.91169	71.87639	34.35792
1195.297	9.903896	-88.51296	73.29744	34.57657
1176.046	4.504282	25.10961	516.5957	2.054437
1171.999	17.63687	22.00986	8.799493	0.044267
1178.864	7.429037	14.68894	0.150442	40.45544
1174.68	41.25616	10.61502	0.212263	3.243055
1172.305	24.91441	8.692271	8.166119	0.014132

Tabla 5.36: Segunda gaussiana del Modelado con Caja Gris para Sistema Mamdani tipo-2 de 25 reglas con adaptación, generado a partir del sistema base.

SISTEMA ADAPTADO DE 25 REGLAS			Sigma desviación estándar	
Temp RM	Tiempo	Temp SB	sig.temp	sig.tiempo
1078.161	19.15654	-42.09041	0.370472	118680.7
1080.438	501.2269	-53.21429	0.29003	503.7301
1076.861	49.54718	-64.0524	0.204678	239.5663
1072.913	13.7135	-3.47496	111.0968	80.99731
1093.569	26.752	-74.29799	19.14988	0.345653
1111.773	14.74286	-22.03888	40.99492	7.484603
1110.817	46.13224	-8.512198	36.76033	5.57192
1021.148	33.13687	44.19158	88.39633	58.48153
1137.009	5.559344	-4.341062	550.7403	45.64108
1113.797	31.2009	-48.03798	22.87665	0.065129
1116.952	19.61966	77.45245	53.72473	22.3053
1108.864	26.61387	34.76311	33.88262	0.464047
1119.445	29.08732	27.33256	29.41759	0.147923
1181.895	10.12399	-48.23377	62.46318	30.64016
1135.419	25.57578	-29.57462	0.022001	24.05827
1114.457	26.57728	31.2518	32.03486	0.109549
1112.811	26.81735	36.07225	33.65767	0.099258
1119.183	19.60443	35.0347	38.70562	19.62418
1186.885	10.9678	-63.98471	71.87639	34.35792
1187.297	10.79163	-70.67354	73.29744	34.57657
1116.789	24.26514	31.36468	516.5957	2.054437
1173.999	17.70595	24.00903	8.799493	0.044267
1183.022	-0.32237	2.535824	0.150442	40.45544
1181.792	36.42226	4.037592	0.212263	3.243055
1174.232	26.10305	10.49328	8.166119	0.014132

Las comparaciones de los resultados de los sistemas Modelos de Caja Gris con Mamdani adaptable, con los sistemas Mamdani y Sugeno sin adaptación todos tipo-2, y Modelo de Planta son presentados en la Tabla 5.54 de la Sección 5.9.6 y las comparaciones gráficas se muestran en la sección 5.9.7 y 5.9.8.

5.8.3. Implementación y evaluación de un sistemas FCM Mamdani tipo-2 con adaptación

En la sección 5.5 se describió la generación de reglas difusas mediante el algoritmo FCM y se realizó la implementación y evaluación de estos en el molino de laminación en caliente, en esta sección tomando como referencias esos modelos se realiza un estudio similar aplicando sistemas difusos tipo-2, en particular mamdani y mamdani con adaptación.

Como anteriormente se ha realizado en sistemas difusos tipo-1 en esta sección se describe cómo el sistema Mamdani con adaptación es formado a partir de un sistema base diseñado mediante un algoritmo FCM, y a partir de este sistema base el sistema Mamdani se adapta y encuentra una respuesta óptima para los centros de las todas las MFs. La estructura del sistema Mamdani adaptable fue mostrado en la sección 5.7.1.

En las Tablas 5.37 y 5.38 se observa el sistema base FCM para un modelo mamdani tipo-2 con adaptación formado por 9 reglas, este sistema se divide en dos tablas debido a que cada función de pertenencia contiene 2 funciones gaussianas donde las etiquetas para cada función de pertenencia son numéricas, se establece que la temperatura de entrada es establecida en un rango de 1072 a 1192 °C y para el tiempo se establecen en un rango de 15 a 23 segundos, para la temperatura de salida se tiene un rango de 1045 a 1125 °C. Las desviaciones estándar para temperatura y tiempo se muestran en dicha tabla. Se puede observar el sistema base FCM formado por 9 reglas, en el caso de la temperatura de entrada las etiquetas para la primera y segunda función gaussiana es numérica definida dentro del rango de operación establecido y generado por FCM, a diferencia de los modelos diseñados mediante conocimiento empírico donde se establecieron etiquetas lingüísticas para temperaturas baja, media y alta. Es similar para las etiquetas de tiempo y temperatura de salida, establecidos en el rango de operación

mediante el algoritmo FCM. Las desviaciones estándar para temperatura y tiempo son fijas.

Tabla 5.37: Primeras funciones gaussianas para el Modelado de un Sistema base de 9 reglas FCM para generación de sistemas Mamdani tipo 2 con adaptación.

Reglas FCM para el Modelo de 9 reglas tipo-2			Sigma desviación estandar		
Temp RM	Tiempo	Temp SB	sig.temp	sig.tiempo	sig.tem.out
1116.58	18.2018	1080.7	8.29255	0.43513	6.20541
1141.6	18.5592	1067.18	5.88106	0.4472	8.28486
1103.56	17.836	1061.2	11.2385	0.38729	8.99918
1150.32	18.409	1112.78	6.9738	0.41576	10.28983
1124.48	18.2082	1061.78	6.39348	0.41443	9.41180
1129.05	18.4295	1090.14	6.22463	0.47812	6.36674
1157.53	18.7445	1095.25	9.02185	0.44255	6.43389
1136.19	18.4056	1102.61	5.70428	0.45749	8.03817
1144.64	18.5882	1084.03	6.47053	0.47817	6.23769

Tabla 5.38: Segundas funciones gaussianas para el Modelado de un Sistema base de 9 reglas FCM para generación de sistemas Mamdani tipo 2 con adaptación.

Reglas FCM para el Modelo de 9 reglas tipo-2			Sigma desviación estandar		
Temp RM	Tiempo	Temp SB	sig.temp	sig.tiempo	sig.tem.salida
1118.58	18.4018	1082.7	8.29255	0.43513	6.20541
1143.6	18.7592	1069.18	5.88106	0.4472	8.28486
1105.56	18.036	1063.2	11.2385	0.38729	8.99918
1152.32	18.609	1114.78	6.9738	0.41576	10.28983
1126.48	18.4082	1063.78	6.39348	0.41443	9.41180
1131.05	18.6295	1092.14	6.22463	0.47812	6.36674
1159.53	18.9445	1097.25	9.02185	0.44255	6.43389
1138.19	18.6056	1104.61	5.70428	0.45749	8.03817
1146.64	18.7882	1086.03	6.47053	0.47817	6.23769

La base de reglas establecidas mediante FCM fue adaptado mediante aprendizaje híbrido. El sistema adaptado será el sistema que se utilizará para realizar las simulaciones y evaluaciones de estimación de temperatura en el molino. El sistema Mamdani adaptado se muestra a continuación en las Tablas 5.39 y 5.40, para el par de funciones gaussianas. Es posible observar en estas tablas como el sistema Mamdani adaptable utiliza datos de entrenamiento para lograr

la adaptación de todas las reglas del sistema y como consecuencia de esto se obtienen diferentes funciones de pertenencia con diferentes desviaciones estándar.

Tabla 5.39: Primeras funciones gaussssianas para el Modelado de un Sistema base de 9 reglas FCM para generación de sistemas Mamdani typo 2 con adaptación, generado a partir del sistema base.

SISTEMA ADAPTADO			Sigma .desviacion est.	
Temp RM	Tiempo	Temp SB	sig.temp	sig.tiempo
1104.32	88.0188	1068.86	14.4661	331.406
1155.57	27.0349	1107.01	30.5655	34.9034
1093.43	-14.488	1028.73	76.0151	341.602
1158.21	18.4588	1114.03	41.7451	12.144
1095.27	11.2454	1037.62	70.6259	100.452
1160.83	56.7131	1117.89	35.9288	136.549
1159.42	12.3481	1102.88	26.897	0.52616
1158.63	18.5472	1115.15	38.8995	11.6024
1158.87	18.5805	1113.99	36.2829	10.8157

Tabla 5.40: Segundas funciones gaussssianas para el Modelado de un Sistema base de 9 reglas empírico para generación de sistemas Mamdani typo 2 con adaptación, generado a partir del sistema base.

SISTEMA ADAPTADO			Sigma .desviacion est.	
Temp RM	Tiempo	Temp SB	sig.temp	sig.tiempo
1104.58	61.4212	1074.95	14.4661	331.406
1155.67	22.8913	1110.52	30.5655	34.9034
1092.78	-82.584	1031.37	76.0151	341.602
1162.41	18.6339	1123.9	41.7451	12.144
1094.7	-1.7379	1039.28	70.6259	100.452
1155.34	26.2878	1109.15	35.9288	136.549
1157.17	10.9577	1101.38	26.897	0.52616
1159.47	18.526	1118.47	38.8995	11.6024
1157.96	18.4874	1115.15	36.2829	10.8157

Para generar un sistema Mamdani adaptable de 25 reglas, es necesario utilizar el sistema base FCM de 25 reglas, el cual se muestra en las siguientes Tablas 5.41 y 5.42. Es posible

observar que en los sistemas FCM las funciones de pertenencia para cada entrada y salida (temperatura y tiempo, respectivamente) son diferentes, esto ocurre también para la salida Temperatura. Las desviaciones estándar para temperatura de entrada, tiempo y temperatura de salida son diferentes para cada una de las funciones de pertenencia.

Tabla 5.41: Primeras gaussianas para el sistema base de 25 reglas FCM para generación de sistema Mamdani tipo 2 con adaptación.

Reglas empíricas para el sistema de 25 reglas			Sigma desviación estándar		
Temp RM	Tiempo	Temp SB	sig.temp	sig.tiempo	sig.tem.salida
1143.7	18.428	1114.89	4.868	0.3289	9.438
1148.3	18.7119	1070.02	5.739	0.352267	6.446
1123.2	18.3266	1095.54	5.758	0.343595	5.587
1096.4	17.7763	1063.75	11.650	0.319894	7.101
1141.4	18.4257	1104.41	4.853	0.349454	7.063
1135.6	18.4729	1085.82	4.799	0.36804	5.157
1123.6	18.163	1064.58	5.544	0.325596	7.453
1160.5	18.9797	1081.34	8.413	0.346184	4.978
1153.1	18.4705	1105.82	6.566	0.338179	7.193
1136.2	18.4636	1067.76	4.648	0.350295	6.925
1131.8	18.3303	1104.6	4.737	0.340713	7.108
1146.3	18.6514	1082.74	5.548	0.366909	5.159
1164.9	18.7689	1100.7	9.444	0.330254	5.983
1133.3	18.4332	1094	4.810	0.365636	5.513
1122.9	18.3766	1086.5	5.862	0.352837	5.061
1154.9	18.7429	1092.78	7.102	0.357006	5.206
1121.8	18.0599	1053.17	5.612	0.29891	10.010
1134.3	18.3113	1076.76	4.768	0.354328	5.654
1144.2	18.5901	1094.14	5.262	0.369628	5.485
1120.7	18.2006	1076.77	6.172	0.338063	5.535
1106.9	17.6518	1054.3	8.791	0.350424	9.486
1110.3	17.9412	1070.41	8.258	0.317811	6.180
1139	18.484	1056.28	4.536	0.331081	9.318
1111.6	18.1737	1083.19	8.079	0.321151	4.917
1156.4	18.2371	1117.55	7.048	0.302841	9.924

Tabla 5.42: Segundas gaussianas para el sistema base de 25 reglas FCM para generación de sistema Mamdani tipo 2 con adaptación.

Reglas empíricas para el sistema de 25 reglas			Sigma desviación estándar		
Temp RM	Tiempo	Temp SB	sig.temp	sig.tiempo	sig.tem.salida
1144.7	18.628	1115.89	4.868	0.3289	9.438
1149.3	18.9119	1071.02	5.739	0.352267	6.446
1124.2	18.5266	1096.54	5.758	0.343595	5.587
1097.4	17.9763	1064.75	11.650	0.319894	7.101
1142.4	18.6257	1105.41	4.853	0.349454	7.063
1136.6	18.6729	1086.82	4.799	0.36804	5.157
1124.6	18.363	1065.58	5.544	0.325596	7.453
1161.5	19.1797	1082.34	8.413	0.346184	4.978
1154.1	18.6705	1106.82	6.566	0.338179	7.193
1137.2	18.6636	1068.76	4.648	0.350295	6.925
1132.8	18.5303	1105.6	4.737	0.340713	7.108
1147.3	18.8514	1083.74	5.548	0.366909	5.159
1165.9	18.9689	1101.7	9.444	0.330254	5.983
1134.3	18.6332	1095	4.810	0.365636	5.513
1123.9	18.5766	1087.5	5.862	0.352837	5.061
1155.9	18.9429	1093.78	7.102	0.357006	5.206
1122.8	18.2599	1054.17	5.612	0.29891	10.010
1135.3	18.5113	1077.76	4.768	0.354328	5.654
1145.2	18.7901	1095.14	5.262	0.369628	5.485
1121.7	18.4006	1077.77	6.172	0.338063	5.535
1107.9	17.8518	1055.3	8.791	0.350424	8.791
1111.3	18.1412	1071.41	8.258	0.317811	8.258
1140	18.684	1057.28	4.536	0.331081	4.536
1112.6	18.3737	1084.19	8.079	0.321151	8.079
1157.4	18.4371	1118.55	7.048	0.302841	7.048

El Sistema base Mamdani de 25 reglas presentado en la Tabla 5.41 y 5.42 es entrenado por el algoritmo de aprendizaje híbrido, los resultados obtenidos para las dos gaussianas son presentados en las siguientes tablas.

Tabla 5.43: Primeras gaussianas del sistema Mamdani de 25 reglas con adaptación, generado a partir del sistema base.

SISTEMA ADAPTADO DE 25 REGLAS			Sigma desviación estándar	
Temp RM	Tiempo	Temp SB	sig. temp	sig. tiempo
1161.593	14.28474	1116.824	35.45918	24.2077365
1150.552	21.98218	1102.918	19.68314	12.2395131
1147.195	20.51482	1099.573	20.18201	15.6411243
1093.039	11.56093	1052.473	31.03335	20.0171664
1153.43	0.977437	1107.94	25.37097	36.8888192
1144.113	21.66813	1095.752	17.6683	0.01985799
1114.656	20.55003	1063.007	37.07769	25.8752656
1159.528	58.1296	1105.642	29.89246	119.202796
1156.803	19319.83	1108.908	29.95976	477548.855
1126.81	42.22248	1084.001	26.17851	76.9159214
1148.816	-121.7157	1110.462	21.57453	128.067338
1151.18	14.57455	1106.101	20.60525	26.3902031
1168.415	11.80347	1104.924	27.15937	0.40479649
1133.324	18.52536	1093.999	4.79603	0.01234028
1129.642	23.67089	1091.104	22.46967	10.7618054
1154.438	35.93846	1104.769	26.79169	44.5894282
1095.01	9.768945	1054.614	26.61558	19.976607
1143.96	23.6421	1097.779	20.26072	0.12856565
1148.504	22.46429	1100.673	19.30514	0.07074795
1112.591	22.99943	1070.093	7.497565	29.7603275
1098.707	14.58509	1042.416	47.26182	69.110235
1109.126	31.08293	1054.699	0.012816	50.2756366
3185.134	51.90543	1038.936	99942.85	83.9400669
1103.183	26.24679	1067.684	314.1642	21.4586276
1171.379	15.56949	1128.349	41.81366	30.2011688

Tabla 5.44: Segundas gaussianas del sistema Mamdani de 25 reglas con adaptación, generado a partir del sistema base.

SISTEMA ADAPTADO DE 25 REGLAS			Sigma desviación estándar	
Temp RM	Tiempo	Temp SB	sig. temp	sig. tiempo
1164.7	16.58914	1122.886	35.45918	24.2077365
1149.418	23.93648	1101.835	19.68314	12.2395131
1146.815	20.50657	1105.573	20.18201	15.6411243
1092.355	10.79264	1050.243	31.03335	20.0171664
1153.099	16.73733	1109.07	25.37097	36.8888192
1141.852	22.5787	1088.457	17.6683	0.01985799
1112.197	18.31829	1058.71	37.07769	25.8752656
1158.484	19.1746	1111.357	29.89246	119.202796
1158.536	13.64589	1113.834	29.95976	477548.855
1130.942	48.2405	1080.028	26.17851	76.9159214
1148.677	17.66663	1107.239	21.57453	128.067338
1152.392	-10.66998	1105.593	20.60525	26.3902031
1167.49	12.87132	1105.568	27.15937	0.40479649
1134.319	18.63689	1094.999	4.79603	0.01234028
1137.554	23.85957	1086.86	22.46967	10.7618054
1154.395	18.52672	1110.465	26.79169	44.5894282
1095.619	9.380423	1053.332	26.61558	19.976607
1144.685	24.69593	1096.628	20.26072	0.12856565
1147.994	22.59032	1101.184	19.30514	0.07074795
1112.891	18.18757	1073.303	7.497565	29.7603275
1098.587	-10.35588	1041.393	47.26182	69.110235
1110.5	20.03626	1074.139	0.012816	50.2756366
1139.272	37.37521	1036.113	99942.85	83.9400669
1111.077	12.01637	1072.869	314.1642	21.4586276
1168.876	13.68714	1126.962	41.81366	30.2011688

Las comparaciones de los resultados de los sistemas FCM Mamdani tipo-2 con adaptación, con sistemas Mamdani y Sugeno sin adaptación, son presentados en la Tabla 5.54 de la Sección 5.9.6 y las comparaciones gráficas se muestran en la sección 5.9.9.

5.8.4. Implementación y evaluación de un sistema de Caja Gris Mamdani FCM con Adaptación tipo-2

En esta sección es implementado el Modelado con Caja Gris difusos tipo-2 para sistemas FCM, incluyendo los sistemas Mamdani adaptables tipo-2. Es utilizado el mismo esquema presentado en el diagrama 5.11, por lo tanto el sistema de Caja Gris difuso FCM Mamdani tipo-2 con adaptación estimará el error de predicción para corregir la temperatura que estima el Modelo de Planta.

En las Tablas 5.45 y 5.46 se establece el sistema base para el modelo de Caja Gris con FCM formado por 9 reglas FCM, como anteriormente se hizo, este sistema se divide en dos tablas debido a que cada función de pertenencia contiene 2 funciones gaussianas donde las etiquetas lingüísticas para cada función de pertenencia son numéricas, la temperatura de entrada es establecida en un rango de 1072 a 1192 °C y el tiempo se establece en un rango de 15 a 23 segundos, para la temperatura de salida se tiene un rango de 1045 a 1125 °C. Las desviaciones estándar de las entradas temperatura y tiempo se muestran en dicha tabla.

Tabla 5.45: Primera gaussiana del Modelado con Caja Gris para un Sistema base de 9 reglas FCM para generación de sistema Mamdani con adaptación tipo-2.

Reglas FCM para el Modelo de 9 reglas			Sigma desviación estándar		
Temp RM	Tiempo	Temp SB	sig.temp	sig.tiempo	sig.temp
1125.49	18.4238	11.6666	6.48769	0.46574	7.82011
1134.87	18.1308	-25.343	5.69591	0.43209	8.69472
1154.12	18.6327	-41.684	7.58812	0.40585	12.48121
1116.69	17.9341	-9.1756	8.27287	0.42355	6.05486
1106.46	18.0422	9.96543	10.6922	0.38621	6.94358
1140.07	18.6007	11.5883	5.92484	0.46772	7.83289
1150.45	18.6341	-2.9241	7.55265	0.47231	6.00626
1156.19	18.7253	-20.843	8.64611	0.44975	7.46540
1133.93	18.355	-5.983	5.99897	0.49437	6.23100

Tabla 5.46: Segunda gaussiana del Modelado con Caja Gris para un Sistema base de 9 reglas FCM para generación de sistema Mamdani con adaptación tipo-2.

Reglas FCM para el Modelo de 9 reglas			Sigma desviación estándar		
Temp RM	Tiempo	Temp SB	sig.temp	sig.tiempo	sig.temp
1127.49	18.6238	13.6666	6.48769	0.46574	7.82011
1136.87	18.3308	-23.343	5.69591	0.43209	8.69472
1156.12	18.8327	-39.684	7.58812	0.40585	12.48121
1118.69	18.1341	-7.1756	8.27287	0.42355	6.05486
1108.46	18.2422	11.9654	10.6922	0.38621	6.94358
1142.07	18.8007	13.5883	5.92484	0.46772	7.83289
1152.45	18.8341	-0.9241	7.55265	0.47231	6.00626
1158.19	18.9253	-18.843	8.64611	0.44975	7.46540
1135.93	18.555	-3.983	5.99897	0.49437	6.23100

Las tablas representan al sistema FCM de 9 reglas, tomado como base por el algoritmo de aprendizaje híbrido se obtiene como resultado un sistema adaptado, el cual es el sistema que se utilizará para realizar las simulaciones y evaluaciones de estimación de temperatura en el molino, este sistema adaptado se muestra a continuación en las Tablas 5.47 y 5.48, para el par de funciones gaussianas. El sistema adaptado coloca todas las reglas del sistema a diferentes posiciones, además se obtienen diferentes funciones de pertenencia con diferentes desviaciones estándar.

Tabla 5.47: Primera gaussiana del Modelado con Caja Gris para un Sistema FCM Mamdani tipo-2 de 9 reglas con adaptación, generado a partir del sistema base.

SISTEMA ADAPTADO			Sigma .desviacion est.	
Temp RM	Tiempo	Temp SB	sig.temp	sig.tiempo
1120.6	81.47	49.9449	52.0531	224.881
1180.17	8.99309	-55.622	66.8014	32.2915
1189.12	34.9654	-90.127	84.3694	112.632
1112.19	1.24687	36.5463	53.7052	495.804
1044.27	145.298	50.7809	95.4225	417.66
1120.5	20.323	33.9962	47.0117	19.5524
1128.29	26.6367	16.7349	28.6719	0.2126
3300.81	7.15335	-58.18	57694.2	37.5439
1126.86	24.7617	6.13105	18.4861	0.09146

Tabla 5.48: Segunda gaussiana del Modelado con Caja Gris para un Sistema FCM Mamdani tipo-2 de 9 reglas con adaptación, generado a partir del sistema base.

SISTEMA ADAPTADO			Sigma .desviacion est.	
Temp RM	Tiempo	Temp SB	sig.temp	sig.tiempo
1116	31.9987	46.1039	52.0531	224.881
1179.67	8.99804	-48.052	66.8014	32.2915
1189.24	5.16653	-82.359	84.3694	112.632
1110.93	-152.07	39.8161	53.7052	495.804
1083.28	42.5764	34.1661	95.4225	417.66
1123.7	20.6862	49.0928	47.0117	19.5524
1124.46	28.5503	12.9193	28.6719	0.2126
1165.72	7.24505	-50.727	57694.2	37.5439
1125.9	25.8016	7.24533	18.4861	0.09146

Para la generación de un Modelo de Caja Gris con un Sistema Mamdani FCM adaptable de 25 reglas, se tiene un sistema base de 25 reglas, el cual se muestra en las Tablas 5.49 y 5.50. Este sistema está compuesto por 25 pares de funciones de pertenencia, diferentes para cada entrada de temperatura y tiempo, y 25 pares de funciones de pertenencia diferentes para la salida. Las desviaciones estándar para temperatura, tiempo y temperatura de salida son diferentes para todas las funciones de pertenencia.

Tabla 5.49: Primera gaussiana del Modelado con Caja Gris para un Sistema base de 25 reglas FCM para generación de sistema Mamdani con adaptación tipo-2.

Reglas FCM para el Modelo de 25 reglas			Sigma desviación estándar		
Temp RM	Tiempo	Temp SB	sig.temp	sig.tiempo	sig.temp
1122.78	18.301	6.9113	5.845	0.3542	5.685
1155.69	18.674	1.7638	7.332	0.3514	5.033
1095.21	17.87	9.9229	12.008	0.30714	5.638
1145.67	18.542	-22.22	5.397	0.35839	6.714
1128.27	18.119	-2.041	5.199	0.3497	5.033
1132.86	18.317	-8.478	4.884	0.36502	5.149
1126.72	18.592	17.914	5.126	0.35787	7.893
1138.32	18.5	-1.444	4.903	0.3737	5.076
1123.11	17.962	-20.84	5.705	0.32601	6.457
1118.35	18.012	-4.849	6.652	0.33087	4.886
1155.46	18.865	-13.95	7.257	0.36569	5.391
1134.16	18.61	7.5334	4.802	0.3766	5.868
1139.49	18.529	17.844	4.725	0.34464	7.898
1166.54	19.12	-39.64	9.554	0.35699	10.159
1133.25	18.218	-20.7	4.760	0.34546	6.518
1137.01	18.199	-32.9	4.552	0.32947	8.939
1112.86	18.144	14.935	7.599	0.31974	6.985
1149.45	18.476	-34.17	5.773	0.33673	9.143
1151.51	18.389	-49.08	5.861	0.30857	12.792
1142.91	18.515	-12.43	5.187	0.36768	5.415
1109.18	17.625	-12.97	8.562	0.37544	5.179
1145.16	18.474	9.5832	5.378	0.35093	6.127
1162.35	18.781	-23.73	8.783	0.34473	6.699
1148.55	18.597	-3.712	5.971	0.36646	4.942
1107.37	18.026	6.9475	8.983	0.30845	5.421

Tabla 5.50: Segunda gaussiana del Modelado con Caja Gris para un Sistema base de 25 reglas FCM para generación de sistema Mamdani con adaptación tipo-2.

Reglas FCM para el Modelo de 25 reglas			Sigma desviación estándar		
Temp RM	Tiempo	Temp SB	sig.temp	sig.tiempo	sig.temp
1124.78	18.501	8.9113	5.845	0.3542	5.685
1157.69	18.874	3.7638	7.332	0.3514	5.033
1097.21	18.07	11.923	12.008	0.30714	5.638
1147.67	18.742	-20.22	5.397	0.35839	6.714
1130.27	18.319	-0.041	5.199	0.3497	5.033
1134.86	18.517	-6.478	4.884	0.36502	5.149
1128.72	18.792	19.914	5.126	0.35787	7.893
1140.32	18.7	0.5556	4.903	0.3737	5.076
1125.11	18.162	-18.84	5.705	0.32601	6.457
1120.35	18.212	-2.849	6.652	0.33087	4.886
1157.46	19.065	-11.95	7.257	0.36569	5.391
1136.16	18.81	9.5334	4.802	0.3766	5.868
1141.49	18.729	19.844	4.725	0.34464	7.898
1168.54	19.32	-37.64	9.554	0.35699	10.159
1135.25	18.418	-18.7	4.760	0.34546	6.518
1139.01	18.399	-30.9	4.552	0.32947	8.939
1114.86	18.344	16.935	7.599	0.31974	6.985
1151.45	18.676	-32.17	5.773	0.33673	9.143
1153.51	18.589	-47.08	5.861	0.30857	12.792
1144.91	18.715	-10.43	5.187	0.36768	5.415
1111.18	17.825	-10.97	8.562	0.37544	5.179
1147.16	18.674	11.583	5.378	0.35093	6.127
1164.35	18.981	-21.73	8.783	0.34473	6.699
1150.55	18.797	-1.712	5.971	0.36646	4.942
1109.37	18.226	8.9475	8.983	0.30845	5.421

De igual forma que en los casos anteriores este sistema base Mamdani de 25 reglas se entrena y se obtiene un sistema Mamdani de 25 reglas adaptado, estos resultados se muestran en las siguientes Tablas 5.51 y 5.52.

Tabla 5.51: Primera gaussiana del Modelado con Caja Gris para Sistema Mamdani tipo-2 de 25 reglas con adaptación, generado a partir del sistema base.

SISTEMA ADAPTADO DE 25 REGLAS			Sigma desviación estándar	
Temp RM	Tiempo	Temp SB	sig.temp	sig.tiempo
1123.57	36.420997	12.8407	29.3157	40.2145
1132.56	21.076163	5.60761	19.1641	8.7139
1103.93	52.887422	22.8163	43.5914	112.1489
1142.66	9.9181802	-22.139	11.8242	0.0489
1125.22	23.105262	14.6135	26.3573	11.9111
1123.91	12.909636	-10.054	18.1699	7.6853
1119.73	27.809369	13.6476	20.8927	1.1966
1131.36	6.6818576	-4.9029	19.129	27.2644
1126.98	-30.73279	1.40156	22.1168	180.0285
1126.11	40.671071	4.79959	24.7309	98.2931
1153.23	13.307629	-14.475	38.8401	12.5170
1128.81	22.414551	6.24919	2.81589	0.0783
1123.94	-8.428055	0.30634	24.3423	52.7962
1174.61	23.238026	-47.93	40.6235	34.2888
1168.26	8.7417094	-21.408	41.612	15.6150
1165.78	16.883465	-38.211	32.0892	39.3103
1114.23	44.119616	18.5604	36.8684	90.3712
1165.46	10.244441	-43.701	42.8713	21.5779
1172.7	9.9423818	-54.228	46.937	24.1361
1133.28	13.543944	-3.0299	21.6518	9.0568
1123.61	33.27591	0.49942	24.3262	115.4016
1125.31	21.457649	8.43207	24.028	9.5754
1168.93	11.381599	-37.434	40.69	17.7872
1131.11	25.634229	2.42533	19.9209	0.3098
1112.77	42.607156	17.8055	37.1412	80.2142

Tabla 5.52: Segunda gaussiana del Modelado con Caja Gris para Sistema Mamdani tipo-2 de 25 reglas con adaptación, generado a partir del sistema base.

SISTEMA ADAPTADO DE 25 REGLAS			Sigma desviación estándar	
Temp RM	Tiempo	Temp SB	sig.temp	sig.tiempo
1121.42	28.220231	13.174	29.3157	40.2145
1131.91	21.24963	7.89309	19.1641	8.7139
1102.86	25.295451	25.6351	43.5914	112.1489
1148.52	15.059583	-20.378	11.8242	0.0489
1123.55	22.745833	13.8347	26.3573	11.9111
1123.34	13.961946	-5.5256	18.1699	7.6853
1124.61	28.870814	15.8965	20.8927	1.1966
1131.61	18.771711	8.13066	19.129	27.2644
1126.84	8.2189653	5.26784	22.1168	180.0285
1125.07	27.861515	8.47476	24.7309	98.2931
1160.26	9.680717	-24.504	38.8401	12.5170
1130.76	24.266536	4.33127	2.81589	0.0783
1126.66	18.952296	11.315	24.3423	52.7962
1177.58	14.790573	-44.194	40.6235	34.2888
1139.54	21.925158	-24.267	41.612	15.6150
1176.69	30.865126	-31.608	32.0892	39.3103
1112.63	23.94986	19.9469	36.8684	90.3712
1170.77	9.4640873	-43.58	42.8713	21.5779
1174.53	9.5670555	-53.066	46.937	24.1361
1129.94	16.560998	-13.338	21.6518	9.0568
1124.34	-46.28809	8.51656	24.3262	115.4016
1124.87	21.632245	12.3058	24.028	9.5754
1168.78	10.970312	-35.326	40.69	17.7872
1130.11	28.142276	3.95681	19.9209	0.3098
1111.18	24.102175	19.5994	37.1412	80.2142

Las comparaciones de los resultados de los Modelos de Caja Gris con FCM Mamdani adaptable tipo-2 y los sistemas Mamdani y Sugeno sin adaptación, y Modelo de Planta, son presentados en la Tabla 5.54 de la Sección 5.9.6 y las comparaciones gráficas se muestran en la sección 5.9.10.

5.9. Resumen de resultados obtenidos

En esta sección se presenta un resumen mediante tablas de todos los sistemas aquí presentados, para mejor apreciación es dividido en dos sub-secciones, en la primera se presentan los sistemas diseñados mediante Fuzzy tipo-1 con adaptación y sin adaptación, y en la segunda sub-sección se presentan los sistemas Fuzzy tipo-2 con adaptación y sin adaptación, en las dos secciones se incluyen sistemas diseñados de forma empírica y mediante FCM.

5.9.1. Resumen de resultados obtenidos para sistemas Fuzzy tipo-1

En la Tabla 5.53 se presenta los resultados obtenidos de todos los sistemas diseñados sin aprendizaje y con aprendizaje, esto incluye los sistemas diseñados de forma empírica y con FCM y los de modelado de Caja Gris difusos. Se puede observar que los mejores sistemas fueron el Sistema FCM Caja Gris ANFIS de 25 reglas y el Sistema Mamdani adaptable con Caja Gris 9 reglas con un 100 % en cuanto a $\%bars \pm 20^{\circ}C$. El sistema que peor desempeño presento es el de Sugeno GB empírico con un 55.55 %. Los sistemas sin aprendizaje con mejor desempeño fueron tres de los diseñados mediante FCM con modelado de Caja Gris, los cuales son Sugeno y Mamdani de 9 reglas y el Sugeno de 25 reglas, los sistemas diseñados de forma empírica con modelado de Caja Gris también presentaron desempeño bastante aceptable como lo demuestran los sistemas Mamdani y Sugeno de 25 reglas. En general solo seis sistemas obtuvieron desempeño mas bajo que el modelo de Planta+PI, de un total de 33 sistemas presentados en este trabajo.


Tabla 5.53: Medidas de desempeño de las diferentes estructuras de modelado de Caja Gris difusas, FIS y Modelo +PI en términos de error de predicción para todos los sistemas diseñados.

FIS	Reglas	Des. Estándar	Media	Media Abso.	RMS	%bars $\pm 20^\circ C$
Mamdani adaptable CG	9	5.2498	-0.1736	4.1572	5.252	100
ANFIS GB fcm	25	4.4546	5.4245	5.6315	7.0188	100
Mamdani adaptable CG FCM	9	5.3197	0.5563	4.1347	5.3480	99.7027
ANFIS GB empi	9	7.8289	2.6043	6.1197	8.2497	99.6633
Mamdani adaptable CG	25	5.5165	1.9017	4.3678	5.8344	99.3266
ANFIS GB fcm	9	6.9404	2.6695	5.9829	7.4352	98.9899
Mamdani adaptable CG FCM	25	5.8672	4.3092	5.2941	7.2790	98.1081
Sugeno GB fcm	9	7.4784	6.7261	8.0566	10.058	95.9596
ANFIS GB empi	25	8.8367	4.692	7.3244	10.004	95.6229
Mamdani GB fcm	9	9.3179	9.2108	10.5029	13.101	88.5522
Sugeno GB fcm	25	11.8259	10.6231	12.6674	15.896	86.8687
Mamdani GB empi	25	15.3336	8.4974	12.8356	17.529	80.8081
Sugeno GB empi	25	15.3962	8.3801	12.7781	17.527	80.8081
Mamdani adaptable FCM	25	15.6570	-2.3005	12.7529	15.823	79.3243
ANFIS FIS empi	9	15.5748	-3.3456	12.7627	15.928	79.3243
Mamdani adaptable empi	25	15.6931	-3.6086	12.8725	16.101	78.7838
ANFIS FIS fcm	9	15.7378	1.4754	13.03	15.805	78.4595
ANFIS FIS empi	25	15.5601	1.6038	12.9055	15.64	78.4054
ANFIS FIS fcm	25	15.9652	0.2249	13.0273	15.965	78.0541
Sugeno FIS fcm	9	16.0424	1.4446	13.251	16.105	77.9459
Mamdani adaptable FCM	9	15.6649	-5.5623	13.1420	16.621	77.4324
Mamdani adaptable empi	9	15.6575	-5.6917	13.1680	16.658	77.3243
Mamdani FIS empi	9	16.1981	-5.1452	13.4786	16.994	77.1351
Sugeno FIS empi	9	16.1759	-5.0294	13.4416	16.938	77.1351
Mamdani FIS fcm	9	16.3218	2.2629	13.543	16.476	76.4865
Mamdani GB fcm	25	13.7034	13.7147	16.0782	19.386	75.0842
Comp+PI	N/A	17.3503	-6.1432	14.4411	18.404	73.973
Sugeno FIS fcm	25	17.0189	3.1735	14.1191	17.31	73.9189
Mamdani FIS fcm	25	17.4913	4.5528	14.7358	18.072	71.7568
Mamdani FIS empi	25	16.7155	-11.864	16.0869	20.496	68.2162
Sugeno FIS empi	25	16.731	-11.929	16.1302	20.546	68.027
Mamdani GB empi	9	15.3827	18.309	19.6441	23.912	56.5657
Sugeno GB empi	9	15.2892	18.4594	19.6996	23.968	55.5556


5.9.2. Comparación gráfica de resultados para sistemas Fuzzy tipo-1

A continuación se presentan algunas comparaciones gráficas de los mejores sistemas obtenidos en este trabajo, para sistemas fuzzy tipo-1 mediante Histogramas.


En la figura 5.15 se muestran los histogramas que presentan gráficamente el desempeño de los sistemas Fuzzy de 9 reglas (figura 5.15(a)), Fuzzy de 25 reglas (figura 5.15 (b)), Fuzzy mamdani de 9 reglas (figura 5.15(c)) y Fuzzy mamdani de 25 reglas (figura 5.15(d)). Se puede observar como los sistemas que mejor desempeño tienen son los ANFIS de 9 y 25 reglas y los que se comportaron con bajo desempeño fueron los sistemas mamdani y sugeno de 9 reglas. Esto es por que en los mejores sistemas las gaussianas están mas centradas y con menos dispersión, con respecto a cero.




a) Fuzzy de 9 reglas



b) Fuzzy de 25 reglas



c) Fuzzy de mamdani 9 reglas




d) Fuzzy mamadani 25 reglas

Figura 5.15: Histogramas sistemas Fuzzy tipo 1, a) Fuzzy de 9 reglas, b) Fuzzy de 25 reglas, c) Fuzzy mamdani 9 reglas, d) Fuzzy mamdani 25 reglas.


5.9.3. Comparación gráfica de resultados para sistemas Fuzzy tipo-1 Caja Gris

Los siguientes histogramas muestran el desempeño de los sistemas Fuzzy tipo 1 con caja Gris de 9 reglas (figura 5.16(a)), Fuzzy de 25 reglas (figura 5.16(b)), Fuzzy mamdani de 9 reglas (figura 5.16(c)) y Fuzzy mamdani de 25 reglas (figura 5.16(d)). Los sistemas que mejor


desempeño presentan son los ANFIS de 9 y 25 reglas y los que se comportaron menor desempeño y mas bajo que el modelo de planta fueron los sistemas mamdani y sugeno de 9 reglas. Estos sistemas con mejor desempeño se caracterizan por reducir drásticamente la dispersion con gaussianas más centradas.




a) Fuzzy de 9 reglas CG



b) Fuzzy de 25 reglas CG



c) Fuzzy de mamdani 9 reglas CG




d) Fuzzy mamdani 25 reglas CG


Figura 5.16: Histogramas sistemas Fuzzy tipo 1 Caja Gris, a) Fuzzy de 9 reglas, b) Fuzzy de 25 reglas, c) Fuzzy mamdani 9 reglas, d) Fuzzy mamdani 25 reglas.

5.9.4. Comparación gráfica de resultados para sistemas con FCM Fuzzy tipo-1


En los siguientes histogramas se presenta gráficamente el desempeño de los sistemas Fuzzy de 9 reglas (figura 5.17(a)), Fuzzy de 25 reglas (figura 5.17 (b)), Fuzzy mamdani de 9 reglas (figura 5.17(c)) y Fuzzy mamdani de 25 reglas (figura 5.17(d)). Es posible observar como los sistema mamdani adaptable con 9 y 25 reglas lucen iguales, pero la diferencia es notable con respecto $\%bars \pm 20^{\circ}C$ donde tienen 77.43 % y 79.32 % respectivamente. Los sistemas mamdani de 25 y sugeno de 25 tuvieron menor desempeño con respecto al modelo de planta.




a) Fuzzy de 9 reglas



b) Fuzzy de 25 reglas



c) Fuzzy de mamdani 9 reglas




d) Fuzzy mamdani 25 reglas


Figura 5.17: Histogramas sistemas Fuzzy tipo 1 con FCM, a) FCM de 9 reglas, b) FCM de 25 reglas, c) FCM mamdani 9 reglas, d) FCM mamdani 25 reglas.

5.9.5. Comparación gráfica de resultados para sistemas Fuzzy tipo-1 con FCM Caja Gris


Los siguientes histogramas muestran el desempeño de los sistemas Fuzzy tipo 1 con caja Gris de 9 reglas (figura 5.18(a)), Fuzzy de 25 reglas (figura 5.18(b)), Fuzzy mamdani de 9 reglas (figura 5.18(c)) y sistemas Fuzzy mamdani de 25 reglas (figura 5.18(d)). Los sistemas mamdani adaptable de 9 y 25 reglas gráficamente presentan un buen desempeño media y desviación estándar bajos, sin embargo el sistema ANFIS de 25 reglas es el que mejor se comportó con respecto a $\%bars \pm 20^{\circ}C$ con un 100 %. Nuevamente se observa que en los sistemas presentados en las gráficas se disminuye drásticamente la dispersion y las gaussianas son más centradas que en los casos anteriores.




a) Fuzzy de 9 reglas CG



b) Fuzzy de 25 reglas CG



c) Fuzzy de mamdani 9 reglas CG



d) Fuzzy mamadani 25 reglas CG

Figura 5.18: Histogramas sistemas Fuzzy tipo 1 FCM con Caja Gris, a) Fuzzy de 9 reglas, b) Fuzzy de 25 reglas, c) Fuzzy mamdani 9 reglas, d) Fuzzy mamdani 25 reglas.

5.9.6. Resumen de resultados obtenidos para sistemas Fuzzy tipo-2

En la Tabla 5.54 se presenta los resultados obtenidos en todos los sistemas difusos tipo 2 diseñados sin aprendizaje y con aprendizaje, esto incluye los sistemas diseñados de forma empírica y con FCM y los de modelado de Caja Gris difusos. Se puede observar que el mejor sistema fue un Sistema mamdani Adaptable Caja Gris diseñado de forma empírica de 9 reglas con 99.5135 % de $\%bars \pm 20^{\circ}C$. Cuatro sistemas mandani adaptable fueron los mejores con respecto a $\%bars \pm 20^{\circ}C$.


Tabla 5.54: Medidas de desempeño para las diferentes estructuras difusas, Caja Gris difusas, y Modelo +PI en términos de error de predicción para los sistemas diseñados de forma empíricas.

FIS	Reglas	Des. Estándar	Media	Media Abso.	RMS	%bars $\pm 20^{\circ}C$
Mamdani adaptable CG tipo-2 empi.	9	5.4450707	2.9833894	4.6691166	6.2081715	99.513514
Mamdani adaptable tipo-2 CG FCM	9	5.4631038	3.1778081	4.7470799	6.3194858	99.405405
Mamdani adaptable CG tipo-2 empi.	25	5.503307	3.6191752	4.9574689	6.5860938	99.351351
Mamdani adaptable tipo-2 CG FCM	25	6.0347849	5.6441516	6.1438731	8.2622777	97.027027
Sugeno tipo-2 CG FCM	9	8.2851114	6.4869874	8.3304197	10.521669	92.351351
Mamdani tipo-2 CG FCM	25	11.610413	5.0317594	10.156314	12.652425	89.27027
Mamdani tipo-2 CG FCM	9	9.0932484	9.6576004	11.055707	13.264014	87.675676
Sugeno tipo-2 CG FCM	25	10.49783	8.9639139	11.345779	13.80313	85.513514
Mamdani adaptable tipo-2 empi.	25	15.641789	-1.8114616	12.721921	15.744232	79.27027
Mamdani adaptable tipo-2 FCM	25	15.662117	-1.3642817	12.736788	15.719315	79.027027
Mamdani adaptable tipo-2 FCM	9	15.653616	-3.6079724	12.844385	16.061971	78.540541
Mamdani adaptable tipo-2 empi.	9	15.661418	-3.6321044	12.851256	16.075008	78.432432
Sugeno tipo-2 FCM	9	16.128963	1.5186759	13.317894	16.198133	77.972973
Sugeno tipo-2 empi.	9	16.431402	-2.7781442	13.388862	16.662416	77.486486
Mamdani tipo-2 empi.	9	16.283279	-3.6641919	13.34004	16.688314	77.324324
Mamdani tipo-2 FCM	9	16.271607	1.7194968	13.467786	16.360022	76.108108
Mamdani tipo-2 empi.	25	16.947364	-0.8391887	13.724918	16.965841	75.891892
Mamdani tipo-2 FCM	25	16.957475	1.9676617	13.922211	17.068975	74.594595
Comp+PI	N/A	17.350326	-6.1432432	14.441081	18.403584	73.972973
Mamdani CG tipo-2 empi.	25	17.113032	10.599373	15.698187	20.127678	73.702703
Sugeno tipo-2 FCM	25	17.091428	3.3079025	14.210795	17.406325	73.351351
Sugeno tipo-2 empi.	25	26.267518	-10.255524	20.18155	28.195245	65.243243
Sugeno CG tipo-2 empi.	9	16.27332	15.587975	18.450949	22.532961	62.378378
Sugeno CG tipo-2 empi.	25	17.418264	20.352809	22.087069	26.787138	50.027027
Mamdani CG tipo-2 empi.	9	15.054448	20.633953	21.421535	25.540852	49.324324


5.9.7. Comparación gráfica de resultados para sistemas Fuzzy tipo-2

Esta sección presenta algunas comparaciones gráficas de los mejores sistemas obtenidos mediante Histogramas, para sistemas Fuzzy tipo 2 modelados mediante Caja Gris, FCM y ambos.

En la figura 5.19(a), se presentan todos los histogramas de sistemas Fuzzy tipo 2 y en la figura 5.19 (b) se puede observar los dos sistemas que mejor resultado presentaron, los cuales son mamdani adaptable de 9 reglas y mamdani adaptable de 25 reglas.



a) Fuzzy tipo2, todos




b) Fuzzy tipo 2, los mejores


Figura 5.19: Histogramas sistemas Fuzzy tipo 2, a) Fuzzy tipo 2 todos, b) Fuzzy tipo 2 los mejores.

5.9.8. Comparación gráfica de resultados para sistemas Fuzzy tipo-2 Caja Gris

En la siguiente figura 5.20(a) muestra todos los histogramas de los sistemas Fuzzy tipo-2 con caja gris, y en la figura 5.20(b) se presentan los dos sistemas que mejor desempeño tuvieron en contra del modelo de planta, los cuales son sistemas mamdani adaptable de 9 reglas y mamdani adaptable de 25 reglas. Se puede apreciar que los modelos de Caja Gris presentan mejor desempeño y un histograma mas centrado en cero.



a) Fuzzy tipo 2 CG, todos




b) Fuzzy tipo 2 CG, los mejores


Figura 5.20: Histogramas sistemas Fuzzy tipo 2 con Caja Gris, a) Fuzzy tipo 2 CG, todos, b) Fuzzy tipo 2 CG, los mejores.

5.9.9. Comparación gráfica de resultados para sistemas con FCM Fuzzy tipo-2

En los siguientes histogramas se presenta el desempeño de todos los sistemas FCM Fuzzy tipo 2, figura 5.21(a), y los sistemas con mejor desempeño se presentan en la figura 5.21 (b), los cuales fueron mamdani adaptable de 9 reglas y mamdani adaptable de 25 reglas. También es posible apreciar que los modelos de Caja Gris presentan mejor desempeño, se puede apreciar como los histogramas están mas centrados en cero.



a) Fuzzy tipo 2 FCM, todos




b) Fuzzy tipo 2 FCM, los mejores


Figura 5.21: Histogramas sistemas Fuzzy tipo 2 FCM, a) Fuzzy tipo 2 FCM, todos, b) Fuzzy tipo 2 FCM, los mejores.

5.9.10. Comparación gráfica de resultados para sistemas Fuzzy tipo-2 con FCM Caja Gris

En la figura 5.22(a) se muestran todos los sistemas Fuzzy tipo2 con FCM Caja Gris, y en la figura 5.22(b) se muestran los sistemas mamdani adaptable de 9 reglas y mamdani adaptable de 25 reglas, los cuales fueron los que mejor desempeño presentaron.



a) Fuzzy tipo 2 FCM, todos



b) Fuzzy tipo 2 FCM, los mejores

Figura 5.22: Histogramas sistemas Fuzzy tipo 2 FCM con Caja Gris, a) Fuzzy tipo 2 FCM, todos, b) Fuzzy tipo 2 FCM, los mejores.

Capítulo 6

CONCLUSIONES

Este capítulo presentan las contribuciones y conclusiones de los sistemas desarrollados, además de mencionar los trabajos futuros que se pretenden realizar y se recomiendan para investigaciones futuras.

6.1. Contribuciones.

En este proyecto de investigación, a partir de los principios y fundamentos teóricos para sistemas FCM, Mamdani adaptable, Cajas Grises, Fuzzy tipo-1 y Fuzzy tipo-2, se establecieron las bases de conocimiento para el desarrollo de diferentes sistemas de Lógica Difusa, en el contexto de estimación de temperatura.

Se desarrollaron y evaluaron sistemas difusos con diferentes características para estimación de temperatura en un molino de laminación en caliente y se comparó su desempeño basándose en el error de estimación.

Se generaron las reglas mediante un algoritmo de generación de reglas basado en datos (FCM), lo cual no se había propuesto para estimación de variable en el molino de laminación en caliente,

para sistemas con 9 y 25 reglas.

Se desarrollaron modelos con Mamdani adaptable, para sistemas con 9 y 25 reglas empíricas. Los sistemas de caja gris basados en lógica difusa tipo 2 no han sido reportados en la literatura antes de este trabajo.

Se llegaron a conclusiones que arrojan un mayor conocimiento en el desarrollo de sistemas difusos y el diseño de los sistemas difusos para estimación de la temperatura.

6.2. Conclusiones Generales

Se concluyó principalmente que:

Los dos sistemas con mejor desempeño fueron Mamdani 9 reglas difusos empíricos con caja gris y aprendizaje híbrido y ANFIS en caja gris con 25 reglas generadas mediante FCM. Como es de esperarse los sistemas de modelado más complejos, es decir, los que incorporan todas aquellas herramientas de modelado probadas en este trabajo fueron aquéllos con mejor desempeño medido éste a partir del error de estimación.

También se demostró que el mayor beneficio del algoritmo de generación de reglas fue en las cajas grises y sobre todo para 9 reglas, es decir, cuando la variable a modelar (error de estimación del modelo físico) es de naturaleza tal que no es fácilmente de aprender mediante la lógica humana.

Por otro lado la ventaja de los sistemas con reglas empíricas es que pueden ser entendidas y ajustadas por el usuario. El comportamiento de la temperatura es no lineal pero guarda

relaciones monotónicas.

La mayor parte de los sistemas desarrollados superaron al modelo físico. Dado que los sistemas fueron probados con datos provenientes de un Molino de laminación real, estos resultados demuestran la viabilidad de la aplicación de sistemas difusos para la predicción de la temperatura en una planta real. Los resultados que se muestran en este trabajo evidencian, como se esperaba, que la aplicación de aprendizaje Híbrido y Modelado de Caja Gris aportan mejoras significativas en el rendimiento; la aplicación de ambas técnicas puede llevar a mejoras de hasta 50 puntos porcentuales, esto es 100 % de mejora, duplicando el rendimiento. El aprendizaje Híbrido sí mejora el rendimiento del sistema, mientras que los resultados muestran que el modelado con Caja Gris requiere la función de Aprendizaje Híbrido para lograr mejoras significativas cuando se aplican a un pequeño número de reglas.

El aprendizaje Híbrido tiene beneficios tanto en Caja Gris como en sistemas puramente difusos y tiene los mejores beneficios para 9 reglas, esto se puede observar en la tabla 5.53.

6.3. Trabajo a futuro.

Como primera recomendación para trabajo a futuro, se aconseja el desarrollo de una técnica para identificar reglas difusas mediante redes neuronales, para realizar una comparación con el modelo FCM que se presenta en este trabajo.

También es recomendable la aplicación y diseño de los modelos aplicados en este trabajo a otras áreas de estudio, con la finalidad de definir que este tipo de sistemas son versátiles en todas las áreas.

FCM tiene la ventaja de permitir incrementar el número de entradas sin aumentar el número de reglas, es decir, la complejidad no aumenta exponencialmente como en el caso de sistemas empíricos. Como trabajos futuros se deben evaluar los factores que pueden afectar la estimación y que no se incluyen en el modelo físico.

Algunas otras actividades futuras incluyen:

- El estudio sobre las más adecuadas operaciones de inferencia para la estimación de la temperatura.
- Prueba de sistemas Sugeno difusos de orden superior.
- La aplicación del algoritmo de aprendizaje Híbrido con un método de optimización que no sea el de mínimos cuadrados recursivos.
- La incorporación de entradas no singleton.

Bibliografía

- [1] Roberts W.L. *Flat Processing of Steel*. Marcel Dekker Inc, New York, 1998.
- [2] General Electric Models. *Users References 1*. Roanoke VA, 1993.
- [3] A. Obregón, P. Mendiola, K. Evers, A. Cavazos, and L. Leduc. Linear multivariable dynamic model of a hot strip finishing mill. *Proc. IMechE: J. Systems and Control Engineering*, 224 part I, 2010.
- [4] Bissessur Y., Martin E.B., Morris A.J., and Kitson P. Fault detection in hot steel rolling using neural networks and multivariate statistics. *IEEE Proceedings Control Theory and Application*, (147):633–640, 2000.
- [5] Watanabe T., Narazaki H., Kitamura A., Takahashi Y., and Hasegawa H. A new mill-setup system for hot strip rolling mill that integrates a process model and expertise. *IEEE International Conference on Computational Cybernetics and Simulation*, 3:2818–2822, 1997 Orlando, FL.
- [6] Maheral P., Ide K., Gomi T., Pussegoda N., and Too J.J.M. Artificial intelligence technique in the hot rolling of steel. *IEEE Canadian Conference on Electrical and Computer Engineering.*, pages 507–510, 1995 Montreal, Canada.
- [7] Sato N., Kamada N., Naito S., Fukushima T., and Fujino M. Application of fuzzy control system to hot strip mill. *Proceedings of the IEEE International Conference on Industrial Electronics, Control, Instrumentation.*, pages 1202–1206, 1992, San Diego, CA.
- [8] Martinetz T., Protzel P., Gramchow O., and Sorgel G. Neural network control for rolling mills. *ELITE Foundation, EUFIT*, (94):147–152, 1994, Achen, Germany.
- [9] Schalng M. and Poppe T. Neural network for steel manufacturing. *IEEE Expert*, (11):8–9, 1996.
- [10] Yao X., Tieu A.K., Fang X.D., and Frances D. Ieee international conference on neural networks.
- [11] Kim Y.S., Yum B.J., and Kim M. Robust design of artificial neural network for roll force prediction in hot strip mill. *IEEE International Joint Conference on Neural Network*, (4), 2001, Washington, DC.

- [12] Mohanty I., Datta S., and Bhattacharjee D. Composition-processing-property correlation of cold-rolled if steel sheets using neural network. *Materials and Manufacturing Processes*, 24(1):100, 2009.
- [13] Chakraborti N., Kumar B.S., Babu V.S., and Moitra S.and Mukhopadhyay A. Optimizing surface profiles during hot rolling: A genetic algorithms based multi-objective optimization. *Computational Materials Science*, 37(1-2):159, 2006.
- [14] Pettersson F., Chakraborti N., and Singh S.B. Neural networks analysis of steel plate processing augmented by multi-objective genetic algorithms. *Steel Research International*, 78(12):890, 2007.
- [15] Chakraborti N.and Kumar B.S.and Babu V.S., Moitra S., and Mukhopadhyay A. A new multi-objective genetic algorithm applied to hot-rolling process. *Applied Mathematical Modelling*, 32(9):1781, 200.
- [16] Gerardo M. Mendez, Alberto Cavazos, Rogelio Soto, , and Luis Leduc. Entry temperature prediction of a hot strip mill by a hybrid learning type-2 fls. *Journal of Intelligent and Fuzzy Systems*, 17(6):583–596, 2006.
- [17] Min-You Chen. Material property prediction using neural fuzzy network. *IEEE, Proceedings of the 3rd World Congress on Intelligent Control and Automation*, 2:1092–1097, 2000.
- [18] Mahfouf M., Gama M.A., and Panoutsos G. Right-first-time production: A reality or a myth? *Materials and Manufacturing Processes*, 24(1):78, 2009.
- [19] D. A. Linkens, J. H. Beynon, and C. M. Sellars. Grey box modelling methodologies and their application to materials processing. *Australasia Pacific Forum*, 12:676–682, 1997.
- [20] J.S. Anderson, T.J. McAvoy, and O.J.Hao. Use of hybrid models in wastewater systems. *Industrial and Enginer Chemistry Research*, 39:1694–1704, 2000.
- [21] Primož Potocnik, Igor Grabec, and Marko Setinc. Neural net based hybrid modeling of the methanol synthesis process. *Kluwer Academic Publishers*, 11(3):219–228, 2000.
- [22] P. Lauret, H.Boyer, and J.C.Gatina. Hybrid modelling of the sucrose crystal growth rate. *International Journal of Modelling and Simulation*, 21(1):23–29, 2001.
- [23] Paul E. Rooke and Hong Wang. Applying combined neural network and physical modelling to the retention process in papermaking. *Appita journal*, 55(4):281–286, 2002.
- [24] Q. Zhu, M.F. Abbod, J. Talamantes-Silva, C.M. Sellars, D.A. Linkens, and J.H. Beynon. Hybrid modelling of aluminium-magnesium alloys during thermomechanical processing in terms of physically-based, neuro-fuzzy and finite element models. *Acta Materialia* 51 (2003) 5051–5062, 51(17):5051–5062, 2003.
- [25] P.D. Hodgson, L.X. Kong, and C.H.J. Davies. The prediction of the hot strength in steels with an integrated phenomenological and artificial neural network model. *Journal of Materials Processing Technology*, 87:131–138, 1999.
- [26] Martin Schlang, B. Langb, T. Runklerb T. Poppeb, and K. Weinzierlc. Current and future development in neural computation in steel processing. *Control Engineering Practice*, 9(9):975–986, 2001.

- [27] Wouter Geerdes. An analysis physical, neural and hybrid models for temperature prediction in a hot strip mill. *Paper de JMSE, Universidad of Twente en cooperación con Hylsa Monterrey*, pages 1–18, 2005.
- [28] Miguel A. Torres, Alberto Cavazos, Diana Melo, Luis Leduc, and Jorge Ramírez. Modelado semifísico para la estimación de la temperatura de entrada a la concha de descascarado en un molino de laminación en caliente basada en RNA. *CONAC*, 2006.
- [29] José Angel Barrios, Miguel Torres-Alvarado, Alberto Cavazos, and Luis Leduc. Neural and neural gray-box modeling for entry temperature prediction in a hot strip mill. *Journal of Materials Engineering and Performance*, 20(7), octubre 2011.
- [30] J. Angel Barrios G. y otros. Modelado semifísico difuso de la temperatura a la entrada a la caja descascarado en laminación en caliente. *AIST*, 2006.
- [31] José Angel Barrios, Alberto Cavazos, Luis Leduc, and Jorge Ramírez. Sistemas semifísico difuso aplicado a la estimación de temperatura en laminación en caliente. *Revista Ingenierías de la UANL*, 11(40):5–11, julio-septiembre 2008.
- [32] José Angel Barrios, Alberto Cavazos, Luis Leduc, and Jorge Ramírez. Fuzzy and fuzzy grey-box modelling for entry temperature prediction in a hot strip mill. *Materials and Manufacturing Processes*, 26(1):66–77, 3 March 2011.
- [33] José Angel Barrios, Miguel Torres-Alvarado, Alberto Cavazos, and Luis Leduc. Neural, fuzzy and grey-box modelling for entry temperature prediction in a hot strip mill. *Expert Systems with Applications*, 39, 2012.
- [34] J.-S.R. Jang, C.-T. Sun, and E. Mizutani. *Neuro-Fuzzy And Soft Computing*. 1997.
- [35] Gerardo M. Mendez and Ma. De Los Angeles Hernandez. Interval type-2 anfis. *Springer*, pages 64–71, 2007.
- [36] Volkmar Uebele, Shigeo Abet, and otros. Extracting fuzzy rules from pattern classification neural networks. *System and cybernetics, IEEE*, 1993.
- [37] Shigeo Abe and Ming-Shong Lang. A classifier using fuzzy rules extracting directly from numerical data. *IEEE*, 1993.
- [38] Shigeo Abe and Ming Shong Lang. A function approximator using fuzzy rules extracted directly from numerical data. *International Joint Conference on Neural Networks*, 1993.
- [39] Lourdes M. Brasil and Otros. Fuzzyrulext: Extraction technique of if/then rules for fuzzy neural nets,.
- [40] Lili Rong and Zhongtuo Wang. An algorithm of extracting fuzzy rules directly from numerical examples by using fnn. *IEEE*, 1996.
- [41] Hossein Khosravi R., M.H.Yaghmaee, Amirhossein Baradaran, and Hadi Sadoghi. Fcm-fuzzy rule base: A new rule extraction mechanism. *International Conference on Innovations in Information Technology, IEEE*, pages 261–265, 2011.
- [42] Narendra S. Chaudhari and Avishek Ghosh. Feature extraction using fuzzy rule based system. *International Journal of Computer Science and Applications, Technomathematics Research Foundation*, 5(3):5–8.

- [43] Bilal Sowan, Keshav Dahal, M. A. Hossain, Li Zhang, and Linda Spencer. Fuzzy association rule mining approaches for enhancing prediction performance. *Expert Systems With Applications (in Press)*.
- [44] Ling Wang, Zhi-Chun Mu, and Dong-Mei Fu. Fuzzy rule modelling based on fcm and support vector regression. *Proceedings of the Seventh International Conference on Machine Learning and Cybernetics, Kunming*, pages 12–15, July 2008.
- [45] Jesús Acosta, Angela Nebot, and otros. Learning fuzzy partitions in fir methodology. *International Journal of General Systems*, 36(6):703–731, 2007.
- [46] Jesús Antonio Acosta Sarmiento. *Aprendizaje de particiones difusas para razonamiento inductivo*. Tesis doctoral, Universitat Politècnica de Catalunya, Barcelona, Diciembre 2006.
- [47] Angela Nebot, Francisco Mugica, and otros. Modeling and simulation of the central nervous system control with generic fuzzy models. *The Society for Modeling and Simulation International*, 79(11):648–669 month =, November 2003.
- [48] Josep Maria Mirats Tur. *Qualitative Modelling of Complex Systems Means of Fuzzy Inductive Reasoning Variable Selection and Search Space Reduction*. Tesis doctoral, Barcelona, Octubre 2001.
- [49] Pilar Gómez Miranda y otros. Modelado y predicción de la concentración de ozono con la metodología de razonamiento inductivo. *Unidad Profesional Interdisciplinaria de Ingeniería y Ciencias Sociales y Administrativas del IPN*.
- [50] Josep M. Mirats Tur and Rafael M. Huber Garrido. Fuzzy inductive reasoning model-based fault detection applied to a commercial aircraft. *Simulation Councils Inc*, 75(178), 2000.
- [51] Hyun-Joon Cho, Bo-Hyeun Wang, and otros. A formalism to extract fuzzy if-then rules from numerical data using genetic algorithms. *Automatic Rule Generation for Fuzzy Controllers Using Genetic Algorithms: A Study on Representation Scheme and Mutation Rate, IEEE.*, 1998.
- [52] Marcos Evandro Cintra, Heloisa de A. Camargo, and otros. Fuzzy rule base generation through genetic algorithms and bayesian classifiers - a comparative approach. *IEEE.*, 2007.
- [53] Masoud Makrehchi. A formalism to extract fuzzy if-then rules from numerical data using genetic algorithms. *Application of Genetic Algorithms in Fuzzy Rules Generation, IEEE.*, 1995.
- [54] M. Mohammadiar and R J Sfonier. Generating fuzzy rules by genetic algorithms. *International Workshop on Robot and Human Communication, IEEE.*, 1994.
- [55] Zheng Pei. A formalism to extract fuzzy if-then rules from numerical data using genetic algorithms. *International Symposium on Evolving Fuzzy Systems*, september 2006.
- [56] Li-Xin Wang and Jerry M. Mendel. Generating fuzzy rules by learning from examples. *IEEE Transaction on systems, man, and cybernetics*, 22(6), 1992.
- [57] Leizer Schnitman and Takashi Yoneyama. An efficient implementation of a learning method for mamdani fuzzy models. *IEEE*, 2000.
- [58] Samuel H. Huang, Ranganath Kothamasu, and Hao Xing. Automatic generation of pragmatic and intelligible fuzzy rules. *IEEE*, 2001.

- [59] Oscar Castillo and Patricia Melin. *Type-2 Fuzzy Logic: Theory and Applications*. 2008.
- [60] M. Kantrowitz, E. Horstkotte, and C. Joslyn. *Answers to Frequently Asked Questions about Fuzzy Logic and Fuzzy Expert Systems*.
- [61] Antonio José Gómez Flechoso. *Inducción de Conocimiento con Incertidumbre en Bases de Datos Relacionales Borrosos*. Tesis doctoral, Universidad Politécnica de Madrid, Escuela Técnica Superior de Ingenieros de Telecomunicación, Madrid, 1998.
- [62] Guillermo Morales Luna. Introducción a la lógica difusa. *Centro de Investigación y Estudios Avanzados del IPN ,(CINVESTAV IPN)*, pages 1–12, 2002.
- [63] Nilesh N. Karnik and Jerry M. Mendel. Introduction to type-2 fuzzy logic systems. *IEEE*, 1998.
- [64] Jerry M. Mendel. *Uncertain Rule-Based Fuzzy Logic Sistem*. 2001.