

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



MODELADO SEMIFÍSICO DIFUSO DE LA TEMPERATURA DE
ENTRADA A LA CAJA DE DESCASCARADO EN LAMINACIÓN EN
CALIENTE


POR
ING. JOSÉ ANGEL BARRIOS GÓMEZ

TESIS
EN OPCIÓN AL GRADO DE MAESTRO EN CIENCIAS DE LA
INGENIERÍA ELÉCTRICA CON ESPECIALIDAD
EN CONTROL

CD. UNIVERSITARIA

JULIO DEL 2008

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



MODELADO SEMIFÍSICO DIFUSO DE LA TEMPERATURA DE
ENTRADA A LA CAJA DE DESCASCARADO EN LAMINACIÓN EN
CALIENTE

POR
ING. JOSÉ ÁNGEL BARRIOS GÓMEZ

TESIS
EN OPCIÓN AL GRADO DE MAESTRO EN CIENCIAS DE LA
INGENIERÍA ELÉCTRICA CON ESPECIALIDAD
EN CONTROL

CD. UNIVERSITARIA

JULIO DEL 2008

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

Los miembros del comité de tesis recomendamos que la tesis “**MODELADO SEMIFISÍCO DIFUSO DE LA TEMPERATURA DE ENTRADA A LA CAJA DE DESCASCARADO EN LAMINACIÓN EN CALIENTE**” realizada por el alumno **Ing. José Angel Barrios Gómez**, matrícula número 001366001 sea aceptada por su defensa como opción al grado de **Maestro en Ciencias** de la Ingeniería Eléctrica con Especialidad en Control.

El Comité de Tesis

Asesor
Dr. Alberto Cavazos González

Coasesor:
Dr. Ernesto Vázquez Martínez

Coasesor:
Dr. Marco Tulio Mata Jiménez

Vo. Bo.
Dr. Guadalupe Alan Castillo Rodríguez
División de Estudios de Posgrado

Cd. Universitaria, a Julio del 2008

Agradecimientos

Un profundo agradecimiento a mis padres Angel Barrios y Adela Gómez, por enseñarme a vivir, estar conmigo, por su apoyo incondicional, por todos sus consejos; no hay mejores. A mis hermanos Edwin Javier, Carlos Raúl y Arnoldo, les agradezco que sean mis hermanos y esos buenos momentos que perduren. Para tí Hijo, te dedico estos esfuerzos, aunque no siempre estamos juntos, eternamente mis pensamientos están contigo.

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.), por sus valiosos consejos acerca de la vida, y por quererme tanto como yo a él. A mis primos Azucena, Rogelio, Marco A., Ana Y., Juanca, Ulises, Oraida, Esdras, Librado, Fernando, Héctor, Oscar, Laura, Flor, Yaneidi, para ustedes un cordial agradecimiento por convivir todos estos años a mi lado.

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.

Para mis amigos de Chiapas Víctor H., Fany D., Javier A., Heber B., Jorge L., Adolfo, Norma, Miguel O., Santiago, Gonzalo que representan parte de mi vida. Para Pancho, Lázaro, Nano, Carlos, Fide, Rata, Chicha, Dalia, Liko y Kandy, amigos también. Para los amigos que he conocido en el norte del país Pedro M., Félix R., Fernando, Alex, Lidia, Carlos, Jorge A., Cano, Oscar, Nancy, Mario, Javier, Juan, Karen, Gaby. A todos gracias por la amistad y respetar mi forma de ser y pensar. Para mi amiga Ana Luisa, por todo ese tiempo que me apoyaste y me aconsejaste y tus buenos deseos. Para mi amiga Ana Maria, por tu respeto y el apoyo en mis decisiones. Y en especial para mi amiga Gina, gracias por tu ejemplo de trabajo y motivarme para terminar esta tesis.

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

A mis coasesores, el Dr. Marco Tulio Mata Jiménez y el Dr. Ernesto Vázquez Martínez por sus acertadas recomendaciones y comentarios proporcionados para obtener la versión final de la 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 Consejo Nacional de Ciencia y Tecnología (CONACYT).

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

*"Sueña y serás libre en espíritu,
lucha y serás libre en vida"
Che...*

RESUMEN

Publicación No. _____

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

Universidad Autónoma de Nuevo León, 2008

Profesor Asesor: Dr. Alberto Cavazos González

Actualmente cualquier proceso de producción está sujeto a acciones de control con la finalidad de asegurar la calidad del producto final. Estas acciones de control involucran la manipulación de variables, como tiempo, velocidad y temperatura, que deben ser medidas; estas mediciones son afectadas por factores externos e internos los cuales provocan errores en los resultados de la medición, que se conocen como incertidumbres.

En el proceso industrial de laminación de acero en caliente las mediciones de las velocidades y fuerza de rodillos, temperatura y tiempo de traslado de las barras de transferencia, presentan continuamente incertidumbres. Para contrarrestar los efectos de las incertidumbres sobre el proceso de laminación y la calidad de la cinta de acero se han desarrollado y aplicado diversas técnicas. En este proyecto de tesis se aplica una metodología de inteligencia artificial conocida como Lógica Difusa (FL del inglés Fuzzy Logic), para reducir el error de predicción de la temperatura debido a incertidumbres; el objetivo es llevar a cabo un modelado semifísico difuso de la temperatura a la entrada de la concha de descascarado, utilizando Lógica Difusa con aprendizaje.

Índice General

Resumen	v
Índice general	vi
Índice de tablas	ix
Índice de figuras	x
1 INTRODUCCIÓN	1
1.1 Planteamiento del problema	1
1.2 Antecedentes	3
1.3 Enfoque de la tesis	9
1.4 Objetivos	9
1.5 Estructura de la tesis	10
2 PROCESO DE LAMINACIÓN EN CALIENTE	11
2.1 Introducción	11
2.2 Laminación en caliente	11
2.2.1 Molino de laminación en caliente	12
2.2.2 Horno de recalentamiento	14
2.2.3 Rompedor horizontal de óxidos	14
2.2.4 Molino desbastador	15
2.2.5 Mesa de transferencia	16
2.2.6 Tijera de corte	17
2.2.7 Descascarador secundario	17

2.2.8	Molino acabador	17
2.2.9	Mesa de enfriamiento por flujo laminar	18
2.2.10	Enrolladores	18
2.3	Conclusiones	18
3	TEORIA DE SISTEMAS LÓGICOS DIFUSOS (FUZZY LOGIC)	20
3.1	Introducción	20
3.2	Conjuntos difusos	21
3.3	Definiciones básicas y terminologías	22
3.3.1	Conjunto difuso y función de pertenencia	23
3.3.2	Determinación de los grados de pertenencia	23
3.3.3	Variables lingüísticas y valores lingüísticos	24
3.3.4	Definiciones básicas	25
3.4	Operaciones básicas	27
3.4.1	Intersección y unión difusos	30
3.5	Reglas y razonamiento difusos	31
3.5.1	Principio de extensión y relaciones difusas	31
3.5.2	Reglas difusas	32
3.6	Sistema de inferencia difusa	36
3.6.1	Modelo Fuzzy Mamdani	38
3.6.2	Modelo difuso Sugeno	40
3.6.3	Modelo difuso Sugeno dos-entradas una-salida	42
3.7	Conclusiones	43
4	MODELADO DE LA TEMPERATURA DE ENTRADA AL SB MEDI- ANTE LÓGICA DIFUSA	44
4.1	Introducción	44
4.2	Modelo físico de la planta	45
4.3	Datos para la experimentación	46
4.4	Modelos difusos Mamdani y Sugeno	46
4.4.1	Modelo difuso Mamdani 9 y 25 reglas	47
4.4.2	Modelo difuso Sugeno 9 y 25 reglas	51

4.5	Sistema de inferencia neuro difuso adaptativo (ANFIS)	52
4.5.1	Redes Neuronales difusas	52
4.5.2	Arquitectura del modelo ANFIS	53
4.5.3	Aprendizaje en el sistema ANFIS	56
4.6	Medidas de desempeño de error de estimación	57
4.7	Experimentación y simulación de los sistemas	59
4.8	Análisis de resultados	60
4.9	Conclusiones	64
5	MODELADO SEMIFÍSICO PARA LA ESTIMACIÓN DE LA TEMPERATURA DE ENTRADA AL DESCASCARADO SECUNDARIO BASADO EN LÓGICA DIFUSA	65
5.1	Introducción	65
5.1.1	Modelo semifísico	66
5.2	Modelado semifísico de la temperatura a la entrada del SB	66
5.2.1	Arquitectura del sistema semifísico difuso	67
5.2.2	Modelo difuso Mamdani 9 y 25 reglas	67
5.2.3	Modelos difusos Sugeno 9 y 25 reglas	71
5.3	Experimentación y simulación de los sistemas	72
5.4	Análisis de los resultados	72
5.5	Comparación de resultados, estimación de temperatura con sistemas Difusos vs. sistemas Semifísicos	76
5.6	Conclusiones	78
6	CONCLUSIONES Y RECOMENDACIONES	79
6.1	Conclusiones	79
6.2	Aportaciones	80
6.3	Recomendaciones	80
	Bibliografía	82

Índice de tablas

4.1	Tabla de 9 reglas Mamdani.	49
4.2	Tabla de 25 reglas difusas Mamdani.	50
4.3	Dos pasos en el procedimiento de aprendizaje híbrido para ANFIS.	57
4.4	Desviación estándar, Media, Media Absoluta, RMS, y Banda de tolerancia de las diferentes estructuras difusas, y Modelo +PI en términos de error de predicción.	61
4.5	Resumen del desempeño en los indicadores de los sistemas.	61
5.1	Tabla de 9 reglas Mamdani, predicción de error.	69
5.2	Tabla de 25 reglas Mamdani, predicción de error.	70
5.3	Desviación estándar, Media, Media Absoluta, RMS, y porcentaje de barras dentro de la Banda de tolerancia de las diferentes estructuras difusas, y Modelo +PI en términos de error de predicción.	73
5.4	Desviación estándar, Media, Media Absoluta, RMS, y Banda de tolerancia, para la comparación de los sistemas Difusos, Semifísicos y Modelo +PI en términos de error de predicción.	76

Índice de figuras

2.1	Proceso de laminación en caliente.	12
2.2	Molino Reversible (MR-1 y MR-2)	16
3.1	Típica MFs de valores lingüísticos "joven", "edad media" y "viejo".	25
3.2	Núcleo, Soporte, y Punto de Cruce de (a) el conjunto difuso "edad media" y (b) el singleton difuso "45 años".	26
3.3	El concepto de $A \subseteq B$	27
3.4	Operaciones de conjuntos difusos: (a) conjuntos difusos A y B ; (b) not A ; (c) A OR B ; (d) A AND B	29
3.5	Ejemplo de cuatro MFs parametrizadas: (a) triangular(x,20,60,80); (b) trapezoidal(x,10,20,60,95); (c) gaussiana(x,50,20); (d) campana(x,20,4,50).	30
3.6	Razonamiento aproximado para múltiples antecedentes.	34
3.7	Razonamiento difuso para múltiples reglas con múltiples antecedentes.	35
3.8	Diagrama de bloques para un FIS.	37
3.9	Varios esquemas de defuzificación para obtener una salida <i>crisp</i>	38
3.10	Modelo difuso Sugeno.	41
3.11	Dos-entradas una-salida Modelo difuso Sugeno: (a) MFs antecedente y consecuente; (b) diagrama de superficie entrada-salida total.	42
4.1	Estimación de temperatura con modelo de planta compensado con PI.	45
4.2	Esquema de sistema Mamdani y Sugeno en ToolBox de Matlab.	47
4.3	Gráfica de entradas Temperatura y Tiempo, y de salida Temp.	48
4.4	Gráfica de entradas Temperatura, Tiempo y salida Temp. para Mamdani 25 reglas.	50

4.5	Gráfica de superficies de entradas Temperatura, Tiempo y salida Temp. para Mamdani y Sugeno de 9 reglas.	51
4.6	(a) Sistema de inferencia Takagi-Sugeno de primer orden; (b) Arquitectura ANFIS equivalente para inferencia Takagi-Sugeno de primer orden.	54
4.7	Histograma del error de predicción modelos: (a) sin aprendizaje Mamdani y Sugeno de 9 y 25 reglas; (b) sin aprendizaje Mamdani, Sugeno 25 reglas y modelo +PI; (c) sin aprendizaje Mamdani, Sugeno 25 reglas y Sugeno con aprendizaje 9 y 25 reglas; (d) modelos ANFIS 9 y 25 reglas y, Modelo PI.	63
5.1	Esquema de sistema semifísico aditivo en paralelo.	66
5.2	Esquema de sistema semifísico, cálculo de las medidas de desempeño a partir del error.	67
5.3	Funciones de pertenencia de entradas y salida para Mamdani 9 reglas.	68
5.4	Funciones de pertenencia para Mamdani 25 reglas.	70
5.5	Gráfica de superficie entradas Temperatura, Tiempo y salida Error del modelo +PI para Mamdani 9 reglas y Sugeno 25 reglas.	71
5.6	Histograma del error de predicción modelos semifísicos: (a) sin aprendizaje Mamdani y Sugeno de 9 y 25 reglas; (b) Sugeno 9 y 25 reglas y modelo +PI; (c) Sugeno (9 y 25 reglas) y ANFIS (9 y 25 reglas); (d) Sugeno y Mamdani (9 reglas), ANFIS (9 reglas) y modelo +PI.	75
5.7	Histograma del error de predicción de los sistemas difusos, semifísicos y compensado +PI.	77

Capítulo 1

INTRODUCCIÓN

1.1 Planteamiento del problema

Actualmente la mayoría de los procesos industriales requieren ser controlados con eficiencia para lograr que sus sistemas tengan un mejor desempeño y una mayor eficiencia, al saber qué factores del proceso son los más críticos da lugar a investigaciones diversas para tratar de realizar una compensación adecuada de estos.

Tal es el caso en la industria de laminación de acero en caliente en donde existen en el proceso numerosas variables que presentan variaciones, las cuales se pretenden predecir de la forma más precisa. Para contrarrestar los efectos de las variaciones sobre el proceso de laminación y la calidad de la cinta de acero se han desarrollado y aplicado diversas técnicas.

Los planchones de acero se preparan térmicamente en un horno de recalentamiento en los cuales es crítico realizar una estimación de las variables de rolado en línea de las barras que están entrando continuamente, posteriormente, éstas atraviesan un rompedor de óxidos, un molino desbastador, una mesa de transferencia, un descascarado secundario y un molino continuo de laminación. Durante este proceso, los planchones de acero presentan pérdida de calor.

Dentro de las variables críticas que se pueden presentar se tiene la temperatura superficial de las barras. La temperatura que se mide en la superficie de cada barra presenta variaciones debido a la formación de óxidos que se genera al tener interacción con el ambiente que lo rodea.

El proceso de laminación en caliente (LC), está conformado por 5 etapas principales, estas son:

a) Horno de calentamiento: La temperatura de los planchones se eleva a $1,300^{\circ}C$, esto para que tenga térmicamente las características adecuadas para deformación mecánica.

b) Rompedor horizontal de óxido: Es donde una serie de chorros de agua a alta presión remueve una capa de óxido formada en la superficie de los planchones.

c) Molino desbastador (RM): En este molino se realiza la reducción vertical y horizontal para producir la barra de transferencia. En algunos casos es reversible, el planchón se mueve hacia adelante y atrás hasta producir la barra.

d) Molino continuo (FM): Conocido también como molino acabador, en este molino es donde se obtiene el espesor y ancho deseados.

e) Enrolladores: La cinta proveniente del FM es enrollada manteniendo una tensión constante proporcionada por el último castillo del FM.

En la industria de laminación en caliente se requiere estimar las variables de rolado en el molino acabador ya que estas son esenciales para lograr que los controles que gobiernan el proceso funcionen adecuadamente, y mientras más precisas sean estas estimaciones mejor será la calidad del producto final. La temperatura superficial de la barra es una de las variables

importantes para cuando el molino realiza la deformación mecánica. Actualmente en planta se cuenta con un sistema que realiza la estimación de temperatura superficial de la barra a la entrada de la caja de descascarado basado en un modelo compensado con una estructura PI (proporcional + integral). Barra tras barra la estimación presenta cierto grado de alteración, provocado por el mismo medio cambiante que lo rodea y variaciones en el proceso, estos factores afectan en el desempeño y eficiencia de los controles del molino. Por ello en esta área se requieren sistemas de estimación, capaces de adaptarse a las diferentes condiciones del proceso. Este proyecto de investigación pretende mediante el uso de sistemas de inteligencia artificial semifísicos (difusos y neuro-difusos), reducir el error de estimación de la temperatura, ya que estos sistemas cuentan con la capacidad de aprendizaje y adaptación.

1.2 Antecedentes

Algunos investigadores actualmente han optado por el uso de algunas técnicas de Inteligencia Artificial (IA) tales como Sistemas de Inferencia Difusa (FIS del inglés Fuzzy Inference System) y Redes Neuronales Artificiales (ANN del inglés Artificial Neural Networks) para aplicarlos en la industria. Este tipo de técnicas son muy útiles por su capacidad de aprendizaje y adaptación. Estas técnicas ofrecen la ventaja de estimar parámetros de un sistema no lineal sin tener conocimiento total del proceso y tienen la capacidad de predicción bajo diversas condiciones de funcionamiento.

Diversos investigadores han realizado trabajos de predicción de la temperatura a la entrada de un molino usando FL tipo-2 con aprendizaje híbrido, G.M. Méndez y otros han propuesto la predicción de temperatura en barras de molinos de laminación en caliente usando un algoritmo híbrido de lógica difusa tipo-2, incluyendo el uso de Back Propagation (BP) [11] con mínimos cuadrados recursivo y BP con el filtro de la raíz de los cuadrados. Un sistema con la metodología propuesta se ha simulado para probar su capacidad de predicción de temperatura en un molino de laminación en caliente en la zona de entrada al SB, para tres tipos diferentes de rollos. Las siguientes combinaciones han sido simuladas: intervalo singleton FL tipo-2, intervalo tipo-1 no singleton FL tipo-2, e intervalo tipo-2 no singleton FL tipo-2. En el intervalo presentado FLS

tipo-2, los modelos tienen sólo dos entradas y una salida, pero el modelo puede ser aplicado para modelar y controlar sistemas con múltiples entradas y salidas. En este trabajo también se presenta una revisión de los trabajos de estimación de variables de rolado basada en sistemas puramente neuronales o neurodifusos [12].

Se ha hecho publicaciones acerca de metodologías de modelado de caja gris (también llamados modelos Híbridos o Semifísico), y su uso en tratamiento de materiales, D. A. Linkens y otros [9], justifican que existe gran demanda en los modelos de predicción en la elaboración de materiales, con mayor exactitud en una amplia gama de condiciones. Este artículo intenta mostrar que la taxonomía de métodos de caja grises propuestos por Thompson y Kramer para las industrias de procesos, comienza a ser utilizada en la ingeniería de materiales. Los sistemas Híbridos o Semifísicos son aquellos que combinan un sistema físico que utilice la planta de estudio con cualquier otro sistema como lógica difusa o redes neuronales.

Martin Schlanga y otros [19], tienen trabajos acerca del desarrollo actual y el futuro en cómputo neuronal en tratamientos de acero. Un sistema de control de tren de laminado calcula la puesta en marcha para los accionadores basados en los modelos de proceso. Los autores mencionan que el comportamiento de proceso de trenes de laminado (en caliente y en frío) es caracterizado por la interacción de muchos componentes de proceso, por un gran número de influencias, por la no linealidad y el flujo. Concluyen que varios sistemas que utilizan redes neuronales actualmente son instalados en la industria del acero por todo el mundo las cuales funcionan activamente en el control de procedimiento y mejoran la calidad y la exactitud del proceso de rolado. La mayor parte de estas redes neuronales son aplicadas en el nivel dos de automatización y son sistemas híbridos.

J.S. Anderson, T.J. McAvoy and O.J. Hao [1] proponen el uso de modelos híbridos, en sistemas de aguas residuales en una planta danesa. Con respecto al tratamiento de aguas residuales y a sistemas microbianos del crecimiento en detalle, el sistema híbrido basado en ANN que modela estimaciones probó ser ventajoso. En el primer caso usan una configuración del modelo semiparamétrico en serie para identificar términos de relación en un modelo macroscópico de

los datos experimentales obtenidos de la serie de tiempo. El modelo híbrido se utiliza para aprender las expresiones de relación para los datos de la serie de tiempo de la forma de la nitrificación y de la desnitrificación tomados de la planta. El modelo híbrido que resulta es muy exacto y su predicción es muy conveniente. En el segundo ejemplo usan una configuración semiparamétrica paralela para modelar una planta de tratamiento aeróbico anóxico de aguas residuales, el modelo es usado para controlar períodos de entrada y salida de aire en un reactor aeróbico anóxico. Un corrector de la red neuronal se emplea conjuntamente con el modelo linealizado.

El modelado híbrido se ha aplicado por Q. Zhu y otros para predecir la tensión del flujo y la evolución microestructural durante el proceso termomecánico en aleaciones aluminio-magnesio [22]. El enfoque del modelo híbrido desarrollado combina modelos físicos y neuro-difusos, y se ha aplicado con éxito para describir cuantitativamente la tensión del flujo y la evolución de las variables internas del estado durante la deformación en caliente, bajo condiciones constantes transitorias y comportamiento de la recristalización durante el recocido subsecuente de Al-1 % Mg. La comparación de las distribuciones locales de las condiciones de la deformación y la tensión del flujo dentro de una compresión plana, de la tensión modelada por elementos finitos usando las ecuaciones empíricas y el modelado de manera híbrida, muestra un resultado muy similar, indicando que el enfoque de modelado híbrido se puede aplicar dentro de código de modelado de elemento finito .

Primoz Potocnik y otros, han propuesto modelos híbridos en el proceso de la síntesis fase líquida del metanol [16], que explota conocimiento *a priori* disponible y datos experimentales el cual puede superar considerablemente un enfoque puramente analítico. La estructura del modelo consiste en un modelo paramétrico y una ANN conectados en paralelo. El modelo paramétrico representa la base del modelo híbrido y es responsable de modelar principalmente el proceso y su extrapolación. La ANN se utiliza para realzar la exactitud que modela en el dominio donde existen bastantes datos medidos. Fue demostrado que el enfoque híbrido es conveniente para modelar el proceso y puede complementarse el conocimiento analítico con modelado experimental exitosamente. Comparado con modelado analítico puro, el error de la

predicción del RMS fue reducido en un 50% con el enfoque de modelado híbrido.

Los modelos híbridos también se han usado para modelar la tasa de crecimiento cristalino de la sucrosa. El método combina una ANN como aproximador de la tasa de crecimiento con el conocimiento anterior representado por el equilibrio total en cristales de la sucrosa. Este enfoque reduce el esfuerzo de modelado ya que la ANN no impone la parameterización a priori de la expresión de la tasa de crecimiento. Para optimizar el funcionamiento del proceso de hervir el azúcar, se investigaron dos enfoques que modelan no linealidades del proceso principal de la tasa de crecimiento. El primer enfoque fue el clásico y consistió en estimar los parámetros de las expresiones empíricas con una técnica de la optimización de parámetros no lineales. Esta estrategia de modelado impone una estructura a priori al modelo y no resuelve el problema de la exactitud fuera de la región donde los parámetros fueron completados. El segundo enfoque es nuevo. Un modelo estructurado con dos componentes fue utilizado para modelar la tasa de crecimiento. El primer componente fue una ANN como un estimador del índice de crecimiento. El segundo componente es el equilibrio total en cristales de la sucrosa. Este segundo tipo del modelo, gracias a su mayor flexibilidad, tiene capacidad de predicciones mejores bajo diversas condiciones. El esfuerzo de modelado se reduce en gran parte y las predicciones de los modelos son más exactas para las diversas condiciones del proceso [8].

P.D. Hodgson , L.X. Kong, C.H.J. Davies [5] proponen la predicción del esfuerzo de deformación en caliente en aceros con modelado híbrido. Los datos de temperatura de la torsión de un acero inoxidable 304 comercial fueron analizados, a partir del modelo fenomenológico de Estrin-Mecking y de un modelo artificial de redes neuronales con BP. Para predecir la tensión del flujo en este modelo, el coeficiente de trabajo de endurecimiento y su producto con la tensión fueron utilizados como entradas, junto con la tensión, temperatura y el índice de tensión; el coeficiente de correlación de Pearson fue utilizado para evaluar el funcionamiento y para terminar la simulación del modelo híbrido. La velocidad del entrenamiento se mejora perceptiblemente y la prueba del modelo fue satisfactoria, si se proporcionan datos razonables de entrenamiento. Además, usando el modelo fenomenológico como datos de entrenamiento, el

modelo híbrido se puede utilizar para la extrapolación. Este modelo tiene ventajas en comparación con modelos fenomenológicos y de ANN, puede predecir de manera exacta la tensión en el régimen de trabajo de endurecimiento y la región dinámica de la recristalización; la velocidad del entrenamiento mejora y la exactitud satisfactoria se alcanza dentro de pocas iteraciones, la exactitud de predicción con datos de prueba se mejora si se proporciona un conjunto de datos de entrenamiento adecuados.

Paul E. Rooke y Hong Wang [18] presentaron un método aplicado a modelar la retención del llenador y de partículas finas en una máquina de papel usando ANN conjuntamente con algunas ecuaciones físicas para describir las concentraciones comunes del "*headbox*" y del backwater (agua blanca). Los modelos de caja negra (en este caso redes neuronales) son usados para aquellas partes del sistema donde los modelos físicos no están fácilmente disponibles debido a la complejidad de estos. El método semifísico proporciona por lo tanto un marco útil, en el que alguna vez se construirán modelos mas complejos con muchas subdivisiones hasta que se logra el objetivo de un modelo exacto para el sistema en cuestión. Esta técnica se demuestra con su desarrollo en una industria de la fabricación de papel.

Min-You Chen [2] ha propuesto una red híbrida neuro difusa basada en un enfoque de modelado difuso adaptativo, que incluye la autogeneración del modelo difuso inicial, la selección de entrada significativa, la validación de partición y la optimización de parámetros, que fue desarrollada para la predicción de propiedades de material de aleación. El enfoque de modelado difuso adaptable propuesto por Chen ha sido usado para construir la propiedad de microestructura de composición para aceros de aleación en rolados en caliente. Los estudios de simulación demuestran que las características mecánicas previstas tienen buena concordancia con los datos medidos usando el modelo difuso obtenido con pocas reglas. Con el modelo que propone se puede predecir las características del acero de aleación en forma rápida y precisa. El modelo difuso que propone proporciona un marco simple y eficaz para la identificación de sistemas y la predicción.

Wouter Geerdes [4] realizó un análisis entre los modelos físicos, neuronales e híbridos para

la predicción de la temperatura en un molino de laminación en caliente. Menciona que el uso de sistemas híbridos tiene ventajas potenciales sobre el uso de una red neuronal o un modelo físico solo. Usando una red neuronal con el modelo físico aplicado a la planta provoca en el personal de la sensación de que ellos tienen el control de esta. Geerdes plantea el diseño de tres modelos híbridos, que se diferencian en cual de ellos recibe la información o de que modo la salida es usada para mejorar la predicción de temperaturas. El primero es una conexión serie entre el modelo optimizado y la red neuronal con las variables de la entrada. El segundo es una conexión en paralelo de la red neuronal y el modelo optimizado, en este caso la red neuronal se usa para predecir el error del modelo de transferencia de calor. En el tercero, se tiene una conexión serie de la red neuronal y el modelo optimizado, donde la red neuronal predice el coeficiente de transferencia de calor óptimo usado en el modelo. El primer modelo tuvo el mejor funcionamiento, ya que la salida fue generada completamente por la NN, y el tercero tuvo un menor desempeño pero es el de más fácil implementación.

Se han publicado trabajos donde se muestran resultados experimentales de diferentes estructuras semifísicas basadas en Redes Neuronales Artificiales, desarrolladas para la estimación de la temperatura de entrada del descascarado (SB del inglés Scale Bracker) en un molino de laminación en caliente. Los resultados muestran las ventajas de estos sistemas comparados con los que están basados solamente en redes neuronales artificiales y métodos tradicionales. También se han llevado a cabo pruebas con entradas adicionales a las que el modelo físico considera. Los experimentos se clasificaron en dos grupos: con entradas adicionales y sin ellas; cada uno de los grupos es probado con 8 distintos valores de épocas de entrenamiento requeridos para la convergencia. El desempeño de error de predicción de la ANN y modelo semifísico se realizó mediante un análisis estadístico [21].

Los modelos propuestos por Miguel A. Torres, y otros [21], J.S. Anderson y otros [1], Q. Zhu, y otros [22], Primoz Potocnik y otros [16], P.Lauret y otros [8], P.D. Hodgson y otros [12], son de importancia particular debido a que su estudio es enfocado a sistemas híbridos. Paul E. Rookem y otros [18], hace referencia a sistemas semifísicos. Debido a que el modelado híbrido puede ser usado en otras disciplinas y para otros conceptos diferentes, en este trabajo se usa el

término modelado semifísico.

Los modelos propuestos por M.A. Torres y otros [21], Wouter Geerdes [4], hacen referencia a sistemas semifísicos basados en redes neuronales para la estimación de temperatura en un molino de laminación.

1.3 Enfoque de la tesis

En este proyecto de investigación se propone el uso de lógica difusa y modelado semifísico basado en sistemas difusos, para lograr la estimación de la temperatura de la Barra de Transferencia (BT) a la entrada del SB. El modelo semifísico para variables de rolado basado en FIS y sistemas neurodifusos no ha sido abordado previamente. Es útil mencionar que el proceso de laminación en caliente tiene diferentes variables que son importantes en el proceso y una buena estimación de estas variables ayuda a satisfacer los aspectos de calidad requeridos para el producto final. En este caso se realiza la estimación de la temperatura de la BT a la entrada del SB, para obtener así los estándares requeridos de calidad en la punta de la BT. Se aclara que al mencionar modelado semifísico difuso, se refiere al modelado físico de la planta apoyado en este caso de lógica difusa. Se pretende el desarrollo de un sistema de lógica difusa que interactúe con el sistema físico que actualmente existe en la planta, para lograr así que el sistema realice cierto entrenamiento y aprendizaje, y pueda realizar una compensación de estimación al sistema físico.

1.4 Objetivos

Los objetivos de esta tesis son:

- 1.- Desarrollar y evaluar sistemas semifísico difuso y neuro-difuso (ANFIS) para estimación de la temperatura de entrada a la concha de descascarado.

2.- Desarrollo y evaluación de sistemas difuso y neuro-difuso para la estimación de temperatura de entrada a la caja de descascarado.

3.- Comparar el desempeño de los sistemas propuestos con sistemas basados en redes neuronales para estimar la temperatura propuestas en publicaciones anteriores.

1.5 Estructura de la tesis

Esta tesis se ha estructurado de la manera siguiente:

En el primer capítulo se da a conocer el planteamiento del problema con una breve explicación de proceso de laminación en caliente acompañado de antecedentes teóricos en el área de inteligencia artificial, sistemas híbridos, redes neuronales y lógica difusa. También se establece el enfoque y los objetivos.

En el Capítulo 2 se describe el proceso de laminación en caliente.

En el Capítulo 3 se presenta una explicación de conceptos, definiciones, operaciones, reglas y razonamiento usados en lógica difusa.

En el Capítulo 4 se presenta el desarrollo de un nuevo modelo de estimación de la temperatura a la entrada del descascarado secundario mediante el uso de lógica difusa.

En el Capítulo 5 se presenta el desarrollo del modelado semifísico difuso para la estimación de la temperatura del SB.

En el Capítulo 6 se establecen los resultados del presente trabajo así como las conclusiones y aportaciones que se logran; finalmente se establecen los posibles trabajos futuros .

Capítulo 2

PROCESO DE LAMINACIÓN EN CALIENTE

2.1 Introducción

Los productos que se obtiene del proceso de laminados 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 se pueden proveer como bobinas o láminas cortadas a una longitud específica. Estos productos también sirven como entrada para la producción de productos laminados en frío.

2.2 Laminación en caliente

El proceso de laminación está compuesto por varias etapas dentro de estas las más importantes son: los molinos de laminación en caliente (MLC), el horno de calentamiento (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 se realiza una descripción 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.

2.2.1 Molino de laminación en caliente

En un Molinos de Laminación en Caliente (MLC) los planchones son cargados al horno de calentamiento (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 enrolladores (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.

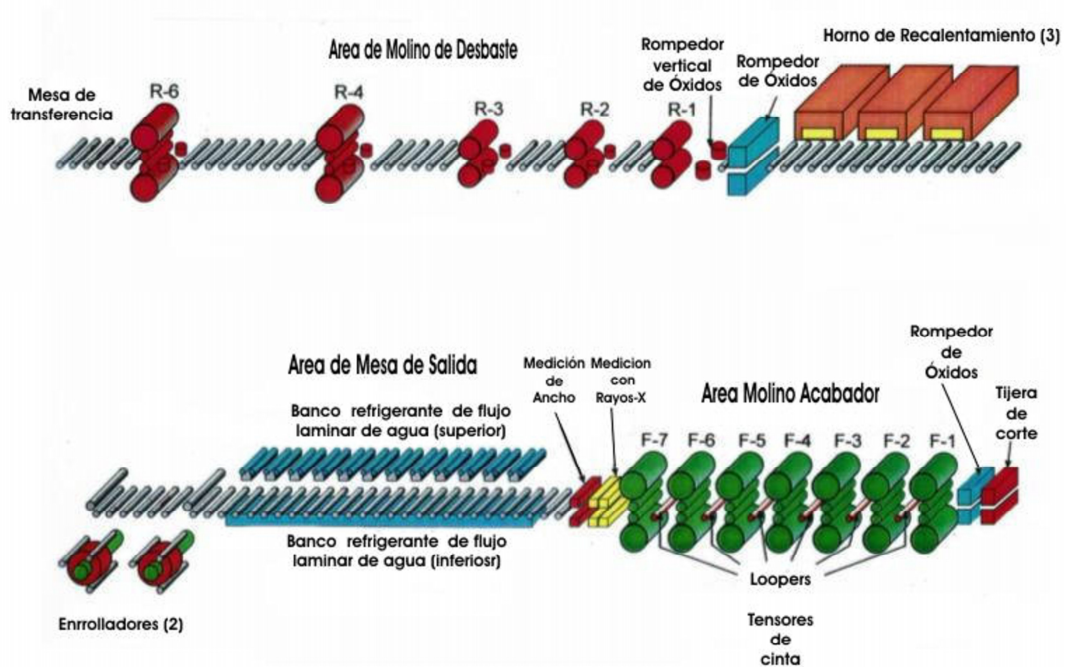


Figura 2.1: Proceso de laminación en caliente.

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 molinos acabadores (MA), cuenta con drivers de corriente directa, para el control de la velocidad del planchón. Tras el paso de los años, 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 de 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 hornos de recalentamiento(HC), un rompedor horizontal de óxidos (RHO), cuatro o cinco molinos desbastadores (MD) pudiendo ser uno solo reversible (MR), un descascarador secundario (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 enrolladores (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 2.2). Con la finalidad de lograr requerimientos en producción, los MLC llegan a estar compuestos hasta por cuatro HC, canteador vertical (EDG), un rompedor horizontal de óxido (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 8 a 9 pulgadas de espesor y de 32 a 39 pies de longitud, con un índice de producción de 3.7 millones de toneladas por año (Figura 2.2).

2.2.2 Horno de recalentamiento

En un horno de calentamiento (HC) los planchones son preparados térmicamente para la deformación mecánica, donde la temperatura es elevada hasta valores de 1,300 °C. Los planchones necesitan ser calentados uniformemente ya que partes frías en el planchón provocarían desvíos en calidad. Algunos molinos de laminación en caliente están equipados con hornos de tres zonas continuas: pre-calentamiento, calentamiento y saturación, teniendo capacidades de producir de 180 a 250 t/hr.

2.2.3 Rompedor horizontal de óxidos

Cuando los planchones se encuentran en el proceso de la preparación térmica en el HC es producida una capa de óxido en la superficie el cual tiene el nombre de óxido primario. Este óxido primario también es considerado nocivo para la calidad del laminado. Cuando el planchón se

desplaza en dirección al MD después de haber salido de HC, el rompedor horizontal de óxido (RHO) se activa durante la reducción horizontal de la barra y una serie de chorros de agua a presión elevada remueven el óxido primario de la superficie del planchón. Dependiendo de la configuración del molino se programan el número y lados que se accionan, superior, inferior, o ambos.

2.2.4 Molino desbastador

Después de que el planchón ha sido preparado térmicamente y ha pasado por el proceso de remoción de óxidos de la superficie, el planchón se somete a una primera deformación intermedia del espesor en los MDs. Existe también el llamado Molino Reversible (MR), este molino es un molino desbastador en el cual el planchón se mueve hacia adelante y hacia atrás, mientras se realiza la reducción horizontal y vertical, hasta producir un subproducto al cual se le llama barra de transferencia (BT). La orientación de la tesis se enfoca a molinos equipados con desbastadores reversibles (Figura 2.2).

La reducción vertical se efectúa sólo en los pases hacia delante por el canteador vertical (EDG), ubicado en la zona de entrada del MR.




Figura 2.2: Molino Reversible (MR-1 y MR-2)

La BT sale después del último pase por el MR, con espesor y ancho deseado en la programación. El EDG garantiza un ancho uniforme el cual es esencial para la continuación del proceso. Los valores típicos del espesor de la barra de transferencia son de 24.00mm a 32.00mm.

2.2.5 Mesa de transferencia

La finalidad de una mesa de transferencia (MT) es trasladar la BT, desde la zona de salida del MR a la zona de entrada del molino acabador (MA), en este traslado la temperatura del centro y superficie de la BT se homogeneiza. Normalmente las dimensiones de la longitud son de 80.0m a 120.0m, aunque en algunos molinos varía.

2.2.6 Tijera de corte

En el MR, la barra de transferencia sufre una deformación no uniforme en la punta. En la Tijera de Corte (TC) la parte frontal de la BT es cortada, con esto se facilita que la punta de la BT se enhebre con facilidad en el MA. La TC se ubica a la salida del MR. La parte trasera de la BT también es cortada para dar uniformidad a la parte frontal de la cinta en los enrolladores.

2.2.7 Descascarador secundario

Durante el proceso de reducción de la barra en el MR y el tiempo de traslado por la mesa de enfriamiento con dirección a la entrada del MA, se forma el óxido secundario, el cual es removido mediante chorros de agua a alta presión en el DS que se ubica a la entrada del MA.

La etapa de remoción de óxidos en el DS es de particular importancia en este trabajo. El DS se encuentra situado unos metros antes del MA, como se observa en la Figura 2.2. Debido a lo complicado que es la obtener una medición precisa de la temperatura del BT a la entrada del MA, en este trabajo se pretende obtener un modelo para estimar la temperatura a la entrada del DS.

2.2.8 Molino acabador

Después de ser eliminado el óxido de la superficie de la BT en el DS, la parte frontal es enhebrada en el Molino Acabador (MA), donde se realiza deformación mecánica final. La BT es enhebrada a una velocidad adecuada para lograr el espesor y la temperatura deseada a la salida. La velocidad con que es enhebrada depende directamente de la temperatura de entrada de la parte frontal de la BT y la temperatura deseada de la parte frontal de la cinta a la salida del MA. La reducción pretendida se divide entre los castillos de reducción disponibles. Entre los castillos de reducción se determinan relaciones de velocidad para que exista un flujo de masa constante a través de los castillos. Los espesores típicos de la cinta varían de 0.95 mm a 12.5

mm y las temperaturas típicas varían de $800\text{ }^{\circ}\text{C}$ a $890\text{ }^{\circ}\text{C}$, a la salida del MA.

2.2.9 Mesa de enfriamiento por flujo laminar

Cuando la BT sale de MA recibe el nombre de cinta, continuando el proceso por la mesa de enfriamiento ubicada entre el último castillo del MA y los enrolladores. En la mesa de enfriamiento, unas cortinas de agua son usadas para disminuir la temperatura de acabado a una temperatura de enrollado en la cual se estabilizan las propiedades metalúrgicas de la cinta y se tiene la forma de grano requerida.

2.2.10 Enrolladores

La cinta proveniente del MA entra a la última etapa en los CLR, ésta es enrollada manteniendo una tensión constante con el último castillo de reducción. Existe una temperatura adecuada a la cual la cinta debe ser enrollada para lograr las propiedades mecánicas deseadas de la cinta. Los enrolladores reciben la cinta del MA a la misma velocidad de éste, para así mantener una tensión adecuada y no dañar la cinta por exceso de tensión, la cual debe quedar uniformemente apretada en el rollo.

2.3 Conclusiones

En este capítulo han sido mencionadas algunas de las etapas de mayor importancia en el proceso de laminación en caliente. Se hace mención acerca de los MLC, que tras el pasar de los años y requerimiento en cuanto a producción han ido aumentando sus tamaños, capacidades, y mediante el desarrollo computacional se ha logrado que los sistemas de control de los molinos sean más sofisticados y eficientes. Los molinos actuales están conformados por tres HC, un RHO, cuatro o cinco MDs o simplemente un MR, un DS a la entrada del MA, un tren de laminación, una mesa de enfriamiento, y dos enrolladores. El MLC que se utiliza en el presente proyecto fue diseñado para rolar planchones de 8 a 9 pulgadas de espesor y de 32 a 39 pies de longitud, con una producción anual de 3.7 millones de toneladas.

Como se mencionó en este capítulo con el pasar de los años los molinos se han modernizado en sus sistemas de control, y debido a que el proceso de laminación en caliente se realiza en un medio muy cambiante, se trata de desarrollar sistemas que cuenten con las características necesarias para enfrentarse a estas dificultades. En el siguiente capítulo se aborda el tema de los sistemas de lógica difusa, que son herramientas efectivas para modelado y cuentan con características favorables de aprendizaje y adaptación al medio, que se pueden aplicar a la laminación en caliente.

Capítulo 3

TEORIA DE SISTEMAS LÓGICOS DIFUSOS (FUZZY LOGIC)

3.1 Introducción

El término "Lógica Difusa" (Fuzzy Logic) puede interpretarse como un superconjunto de la tradicional lógica booleana [7], 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 [3].

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 [3].

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 [3, 14].

3.2 Conjuntos difusos

De manera intuitiva se tiene el concepto de conjunto como una colección bien definida de elementos, en la que es posible determinar para un objeto cualquiera, en un universo dado, si

acaso éste pertenece o no al conjunto. La decisión, naturalmente, es "si pertenece" o bien "no pertenece" [14].

La noción intuitiva de conjunto puede ser muy estrecha. En un conjunto difuso a cada elemento del universo se le asocia un grado de pertenencia, que es un número entre 0 y 1, a ese conjunto. Un conjunto difuso es pues una correspondencia (o función) que a cada elemento del universo le asocia su grado de pertenencia. Enunciada así esta definición parece ser cíclica, más no lo es: un conjunto difuso es una función cuyo dominio es el universo y cuyo contradominio es el intervalo $[0; 1]$. En tanto el grado de pertenencia sea más cercano a 1 tanto más estará el elemento en el conjunto y en tanto el grado de pertenencia sea más cercano a 0 tanto menos estará el elemento en el conjunto [14].

3.3 Definiciones básicas y terminologías

Sea X un espacio de objetos y x sea un elemento genérico de X . Un conjunto clásico A , $A \subseteq X$, es definido como una colección de elementos u objetos $x \in X$, tales que cada x puede pertenecer o no pertenecer al sistema A . Definiendo una función característica para cada elemento x en X , podemos representar un conjunto clásico A como un conjunto de pares ordenados $(x, 0)$ o $(x, 1)$, que indica $x \notin A$ o $x \in A$, respectivamente.

A diferencia del conjunto convencional, un conjunto difuso expresa el grado al cual un elemento pertenece a un conjunto. Por lo tanto la función característica de un conjunto difuso tiene valores entre 0 y 1, el cual denota el grado de pertenencia de un elemento en un conjunto dado [6].

3.3.1 Conjunto difuso y función de pertenencia

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

$$A = \{(x, \mu_A(x)) | x \in X\}, \quad (3.3.1)$$

donde $\mu_A(x)$ es llamada **función pertenencia** (MF) para el conjunto difuso A . La MF mapea cada elemento de X a un grado de pertenencia (o valor de pertenencia) entre 0 y 1 [6].

Si el valor de la función pertenencia $\mu_A(x)$ es restringido a 0 y 1, entonces A es reducido a un conjunto clásico y $\mu_A(x)$ es la función característica de A . Por lo general, X se menciona como el universo de discusión, o simplemente el universo, y esto puede ser discreto o continuo [6].

3.3.2 Determinación de los grados de pertenencia

La utilidad de un conjunto difuso para modelar un concepto o una etiqueta lingüística dependerá de la forma que tome su función de pertenencia. Por ello, resulta de gran importancia la determinación práctica de una función de pertenencia precisa y justificable. Los métodos más usados son empíricos y se basan en experimentos realizados en una población, para medir la percepción subjetiva de los grados de pertenencia a la clase conceptual que se quiere modelar. Existen varios métodos [3]:

1. Evaluación subjetiva: un individuo asigna un grado de pertenencia subjetivo a cada elemento; normalmente esta evaluación la realizan expertos en el tema o aplicación de que se trate.

2. Métodos psicológicos: para aplicaciones complejas se suelen aplicar métodos psicológicos, como medir el tiempo de respuesta requerido para clasificar un elemento (respuestas más rápidas se considera que indican grados de pertenencia mayores).

3. Frecuencias o probabilidades: estadísticas basadas en histogramas o el porcentaje de respuestas afirmativas y negativas sobre la pertenencia de un elemento al conjunto.

4. Funciones ad-hoc: en los sistemas difusos de control se suele utilizar un pequeño conjunto de sencillas funciones (por ejemplo funciones triangulares o en forma de trapecio) como funciones de pertenencia. De este modo, el problema se reduce a la elección de unos pocos parámetros en dichas funciones.

A los conjuntos difusos en los que la función de pertenencia asigna a sus elementos valores de pertenencia que son números reales, se les denomina conjuntos difusos de tipo 1. Es posible extender el concepto de conjunto difuso a los grados de pertenencia para construir así conjuntos difusos de tipo 2, en los que los grados de pertenencia de sus elementos serían, a su vez, conjuntos difusos. Aplicando de forma recursiva esta idea, se podrían construir, de forma general, conjuntos difusos de tipo L [3].

3.3.3 Variables lingüísticas y valores lingüísticos

Sea $X = \text{"edad"}$, entonces podemos definir conjuntos difusos "joven", "edad media" y "viejo", eso es caracterizado por MFs $\mu_{joven}(x)$, $\mu_{edadmedia}(x)$, and $\mu_{viejo}(x)$, respectivamente. Tal como una variable puede considerar varios valores, la variable lingüística "edad" puede adoptar diferentes valores lingüísticos, tal como "joven", "edad media", y "viejo" en este caso. Si "edad" adquiere el valor de joven, entonces se tiene la expresión "edad es joven", y así sucesivamente para otros valores. Típicas MFs para estos valores lingüísticos se muestran en la Figura 3.1, donde el universo de discusión X es totalmente cubierto por las MFs y la transición de un MF al otro es lisa y gradual [6].

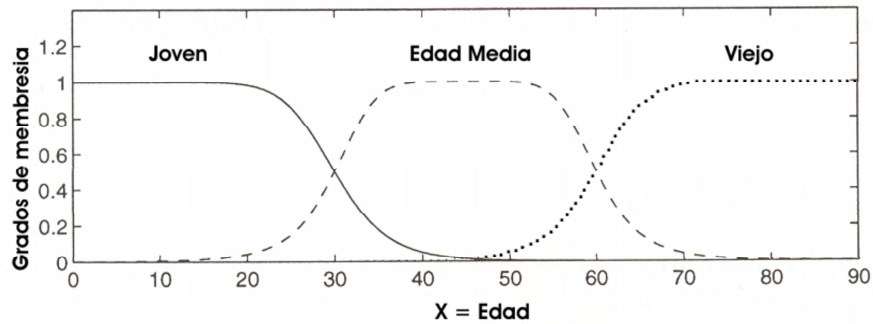


Figura 3.1: Típica MFs de valores lingüísticos "joven", "edad media" y "viejo".

Un conjunto difuso únicamente es especificado por su función pertenencia, en la siguiente sección se define la nomenclatura usada en la literatura [6].

3.3.4 Definiciones básicas

Soporte. El Soporte (*Support*) de un conjunto difuso A es el conjunto de todos los puntos de x en X tales que $\mu_A(x) > 0$:

$$\text{support}(A) = \{x | \mu_A(x) > 0\} \quad (3.3.2)$$

Núcleo. El Núcleo (*Core*) de un conjunto difuso A es el conjunto de todos los puntos x en X tales que $\mu_A(x) = 1$:

$$\text{core}(A) = \{x | \mu_A(x) = 1\} \quad (3.3.3)$$

Normalidad. (*Normality*) Un conjunto difuso A es normal si su núcleo es no vacía. En otras palabras, podemos siempre encontrar un punto $x \in X$ tal que $\mu_A(x) = 1$.

Punto de Cruce. Un Punto de cruce (*Crossover Point*) de un conjunto difuso A es un punto $x \in X$ en el cual $\mu_A(x) = 0.5$:

$$\text{crossover}(A) = \{x | \mu_A(x) = 0.5\} \quad (3.3.4)$$

Singleton Difuso. (Fuzzy Singleton) Es un conjunto difuso cuyo soporte es un punto singular en X con $\mu_A(x) = 1$.

Las Figuras 3.2 (a) y 3.2 (b) ilustran el Núcleo, Soporte, y Punto de Cruce de la función pertenencia que representa "edad media" y el Singleton Difuso "45 años" [6].

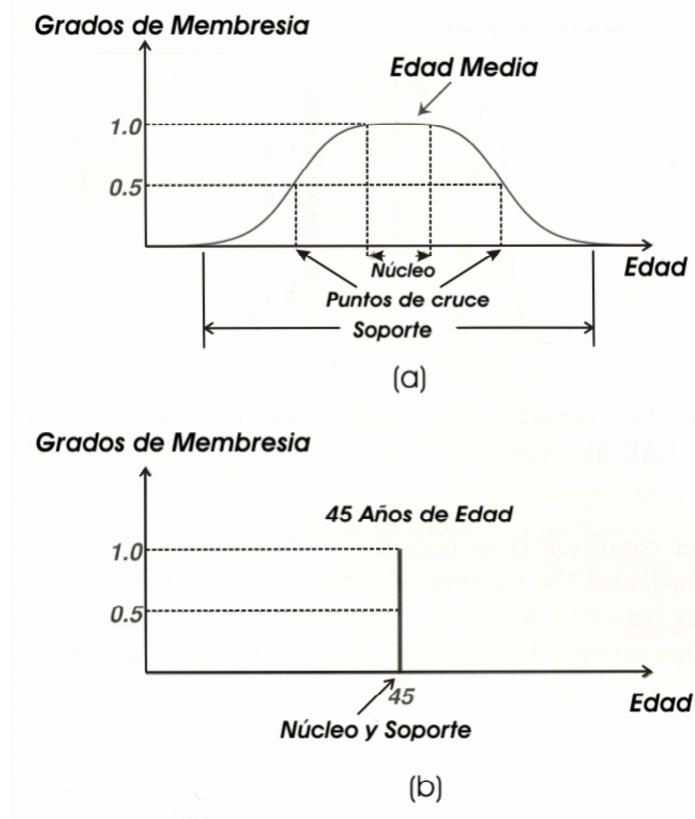


Figura 3.2: Núcleo, Soporte, y Punto de Cruce de (a) el conjunto difuso "edad media" y (b) el singleton difuso "45 años".

3.4 Operaciones básicas

La unión, intersección, y complemento son las operaciones básicas en conjuntos clásicos. En los conjuntos difusos se tienen operaciones similares, los cuales fueron definidas inicialmente por Zadeh [6]. Antes de definir estas tres operaciones de conjuntos difusos, primero se define la noción de contención, que juega un papel central tanto en conjuntos ordinarios como en conjuntos difusos .

Contención o subconjunto. Un conjunto difuso A está contenido en un conjunto difuso B (o, equivalentemente, A es subconjunto de B , o A es más pequeño que/o igual que B) sí y sólo sí $\mu_A(x) \leq \mu_B(x)$ para todo x . La Figura 3.3 representa el concepto de $A \subseteq B$.

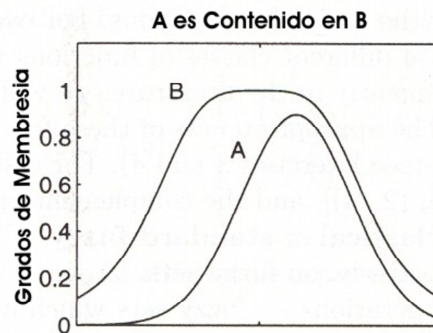


Figura 3.3: El concepto de $A \subseteq B$.

Unión (disyunción). La unión de dos conjuntos difusos A y B es un conjunto difuso C , escrito como $C = A \cup B$ o $C = A$ OR B , cuya MF es relacionado con aquellos de A y B por:

$$\mu_C(x) = \max(\mu_A(x), \mu_B(x)) = \mu_A(x) \vee \mu_B(x) \quad (3.4.1)$$

Como indicó Zadeh, una definición más intuitiva pero equivalente de unión, es el conjunto difuso "más pequeño" que contiene tanto a A como a B . O bien, si D es cualquier

conjunto Difuso que contiene tanto A como a B, entonces esto también contiene $A \cup B$. La intersección de conjunto difuso puede ser definida análogamente.

Intersección (conjunción). La intersección de dos conjuntos difusos A y B es un conjunto difuso C , escrito como $C = A \cap B$ o $C = A \text{ AND } B$, cuyo MF es es relacionado con aquellos de A y B por:

$$\mu_C(x) = \min(\mu_A(x), \mu_B(x)) = \mu_A(x) \wedge \mu_B(x) \quad (3.4.2)$$

Como en el caso de union, es obvio que la intersección de A y B es el conjunto difuso "más grande", el cual es contenido tanto por A como por B . Esto se reduce a la operación de intersección ordinaria si tanto A como B son no difusos.

Complemento (negación). El complemento de un conjunto difuso A , denotado por \bar{A} ($\neg A$, NOT A) es definido como:

$$\mu_{\bar{A}}(x) = 1 - \mu_A(x) \quad (3.4.3)$$

La Figura 3.4 demuestra estas tres operaciones básicas; la Figura 3.4 (a) ilustra dos conjuntos difusos A y B ; la Figura 3.4 (b) es el complemento de A ; la Figura 3.4 (c) es la unión de A y B ; y la Figura 3.4 (d) es la intersección de A y B .

Las ecuaciones de las operaciones unión, intersección, y complemento funcionan exactamente como la operación correspondiente para conjuntos ordinarios si los valores de la función pertenencia son restringidos a 0 ó 1 [6].

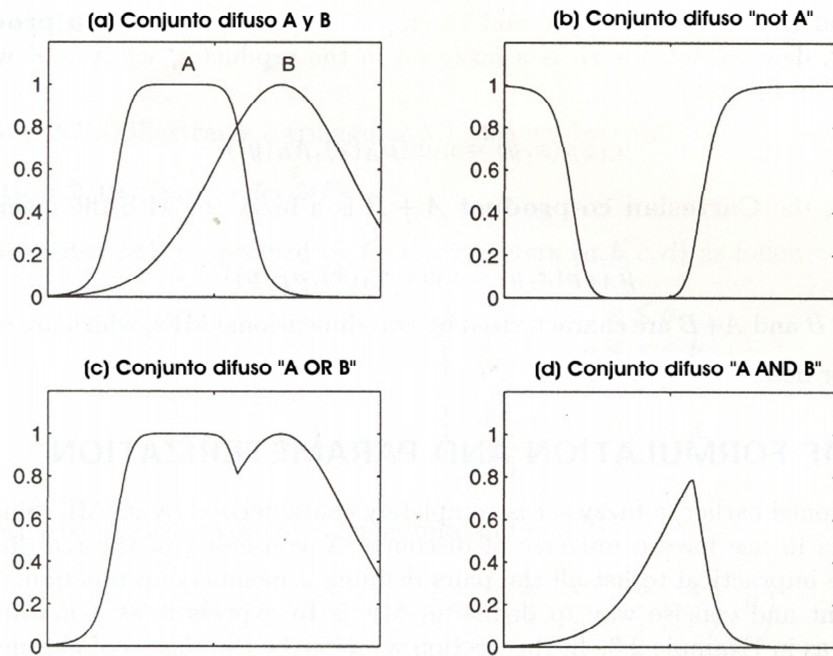


Figura 3.4: Operaciones de conjuntos difusos: (a) conjuntos difusos A y B ; (b) $\text{not } A$; (c) $A \text{ OR } B$; (d) $A \text{ AND } B$.

Estas tres operaciones definidas para conjuntos difusos cumplen, al igual que en la teoría clásica de conjuntos, asociatividad, conmutatividad y distributividad así como las leyes de Morgan.

Sin embargo, también es necesario destacar que existen dos leyes fundamentales de la teoría clásica de conjuntos como son el Principio de contradicción; $A \cup \bar{A} = U$, y el Principio de exclusión; $A \cap \bar{A} = \emptyset$ (donde U es el conjunto universo y \emptyset es el conjunto vacío), que no se cumplen en la teoría de conjuntos difusos; de hecho una de las formas para describir en que se diferencia la teoría clásica de conjuntos de la teoría difusa es explicar que estas dos leyes en términos de Lógica difusa no se cumplen [6].

3.4.1 Intersección y unión difusos

Las funciones que definen la unión y la intersección de conjuntos difusos pueden generalizarse, a condición de cumplir ciertas restricciones. Las funciones que cumplen estas condiciones se conocen como **Conorma Triangular (T-Conorm)** (o *S-norm*) y **Norma Triangular (T-Norm)**. Los principales operadores que cumplen las condiciones para ser *T-conorm* son el operador máximo y la suma algebraica [$\mu_{A \cup B}(x) = \mu_A(x) + \mu_B(x) - \mu_A(x)\mu_B(x)$] y los principales operadores que cumplen las condiciones para ser *T-norm* son el operador mínimo y el producto algebraico [$\mu_{A \cap B}(x) = \mu_A(x)\mu_B(x)$]. En la mayoría de las aplicaciones a la ingeniería de la lógica difusa se usan como *T-conorm* el operador máximo y como *T-norm* los operadores mínimo o producto [17].

Un conjunto difuso es completamente caracterizado por sus MF. Algunas clase de funciones pertenencia con una entrada son: MFs triangulares, MFs trapezoidales, campana generalizada (generalized bell), MFs gaussianas (es la que se utilizará en el presente trabajo); ver Figura 3.4.1 [6].

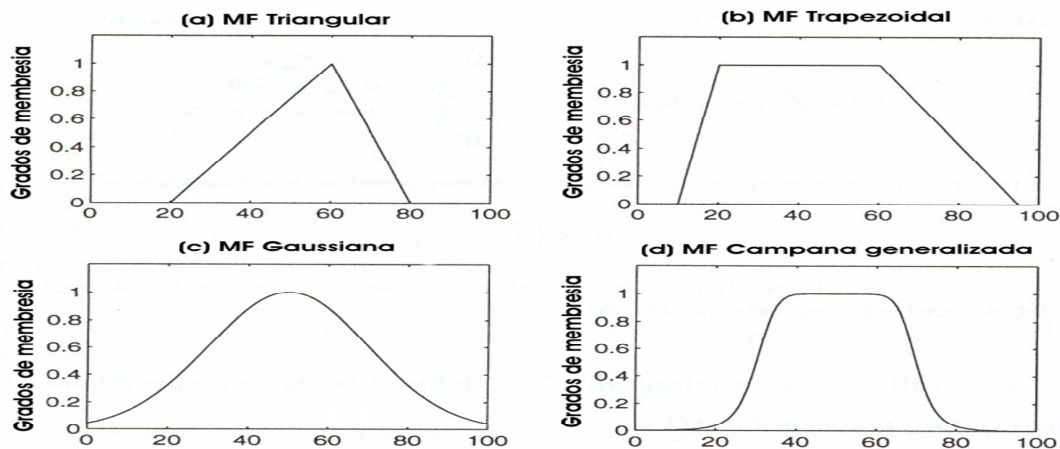


Figura 3.5: Ejemplo de cuatro MFs parametrizadas: (a) triangular($x,20,60,80$); (b) trapezoidal($x,10,20,60,95$); (c) gaussiana($x,50,20$); (d) campana($x,20,4,50$).

3.5 Reglas y razonamiento difusos

Las reglas difusas y razonamiento difuso son la espina dorsal de los sistemas de inferencia difusa (FIS), los cuales son las herramientas más importantes de modelado basado en teoría de conjuntos difusos. Ellos han sido satisfactoriamente aplicados en una amplia gama de áreas, tales como control automático, sistemas expertos, reconocimiento de patrones, predicción de series de tiempo, y clasificación de datos entre otros [6].

3.5.1 Principio de extensión y relaciones difusas

A continuación se definirán el principio de extensión y las relaciones difusas, las cuales son el fundamento del razonamiento difuso.

Principio de extensión

El principio de extensión es un concepto básico de teoría de conjuntos difusos, que proporciona un procedimiento general para ampliar el dominio determinista de expresiones matemáticas para el dominio difuso. Este procedimiento generaliza un mapeo común punto a punto de una función $f(\cdot)$ a un mapeo entre conjuntos difusos [6].

Relaciones difusas

Una relación difusa representa el grado de presencia o ausencia de asociación, interacción o interconexión entre elementos de dos o más conjuntos difusos, por ejemplo: " x es mayor que y ". Supongamos X e Y dos universos de discurso, la relación difusa $R(X, Y)$ es un conjunto difuso en el espacio producto $X \times Y$ que se caracteriza por la función de pertenencia $\mu_R(x, y)$ donde x pertenece a X e y pertenece a Y , es decir:

$$R(X, Y) = \{((x, y), \mu_R(x, y)) | (x, y) \in X \times Y\} \quad (3.5.1)$$

en el caso de las relaciones difusas $\mu_R(x, y) \in [0, 1]$ y en caso de las relaciones clásicas $\mu(x, y) = 0$ ó 1 [17].

3.5.2 Reglas difusas

Las técnicas convencionales para el análisis de sistemas son inapropiadas para tratar con sistemas no deterministas, cuyo comportamiento se encuentra bajo la influencia del juicio humano, la percepción y las emociones. Debido a esto, Zadeh propuso el concepto de variables lingüísticas como un acercamiento alternativo al modelado del pensamiento humano, acercamiento que, en una manera aproximada, sirve para resumir la información y expresarlo en términos de conjuntos difusos en vez de números deterministas [6].

Reglas difusas IF-THEN

Se le llama regla difusa al conjunto de proposiciones IF-THEN (conocida también como implicación difusa, condiciones de declaración difusas) la cual adquiere la forma:

$$\textit{if } x \textit{ is } A \textit{ then } y \textit{ is } B,$$

donde A y B son valores lingüísticos definidos por conjuntos difusos en universos de discusión X e Y , respectivamente. A menudo el primer término de la regla " x is A " es llamado el **antecedente** o **premisa**, mientras que el segundo " y is B " es llamado **consecuente** o **conclusión**. Una regla expresa un tipo de relación entre los conjuntos A y B cuya función característica sería $\mu_{A \rightarrow B}(x, y)$ y representa lo que se conoce como implicación lógica. La elección apropiada de esta función característica está sujeta a reglas de lógica proporcional. Los ejemplos de reglas difusas IF-THEN están en nuestras expresiones lingüísticas diarias, tales como las siguiente [6, 17]:

- Si la velocidad es alta, entonces aplicar el freno un poco.
- Si el tomate es rojo, entonces está maduro.

Implicación difusa

Al igual que para describir las nociones básicas de la teoría de conjuntos difusos podemos establecer un paralelismo con la teoría clásica de conjuntos; también los fundamentos de la teoría de la lógica difusa parten y toman los conceptos fundamentales de la lógica clásica.

Las reglas difusas IF-THEN son utilizadas para modelar y analizar sistemas. En términos de teoría de lógica difusa, la proposition "If x is A , THEN y is B ", algunas veces abreviada como $A \rightarrow B$, donde $x \in X$ e $y \in Y$, tiene asociada una función característica $\mu_{A \rightarrow B}(x, y)$ que toma valores en el intervalo $[0,1]$. Es decir, cada una de las reglas o proposiciones IF-THEN es a su vez un conjunto difuso con su función característica que mide el grado de verdad de la relación de implicación entre x e y [17].

Razonamiento difuso

La regla básica de inferencia en la lógica tradicional de dos valores es el *modus ponens*, según el cual se puede deducir la verdad de una proposición B de la verdad de A y de la implicación $\mu_{A \rightarrow B}(x, y)$. Por ejemplo si A es identificado como "el tomate es rojo" y B como "el tomate está maduro" entonces si es verdadero que "el tomate es rojo", es también verdadero que "el tomate está maduro". Descrito tenemos: Premisa 1 (hecho): x is A ; Premisa 2 (regla): if x is A then y is B ; Consecuente (conclusión): y is B .

Al involucrarse el juicio humano al anterior procedimiento de inferencia es llamado **razonamiento aproximado** o **razonamiento difuso**; también se le conoce como **modus ponens generalizado** (GMP).

Puesto que la parte antecedente de la regla difusa es construida por el conectivo "AND", $w_1 \wedge w_2$ es llamado esfuerzo de disparo o grado de cumplimiento de la regla difusa, ver Figura 3.6, que representa el grado a el cual la parte antecedente de la regla se satisface [6].




Figura 3.6: Razonamiento aproximado para múltiples antecedentes.

Cuando una regla difusa dada adopta la forma "if x is A or y is B then z is C ", entonces el esfuerzo de disparo se da como el máximo del grado de concordancia en la parte antecedente para una condición dada. Esta regla difusa es equivalente a la unión de las dos reglas difusas "if x is A then z is C " and "if y is B then z is C ."

Múltiples reglas con múltiples antecedentes

La interpretación de reglas múltiples se toma generalmente como la unión de las relaciones difusas que corresponden a las reglas difusas. Por lo tanto, para un problema de GMP se escribe por ejemplo como como:

Premisa 1 (hecho): x is A' and y is B' ,

Premisa 2 (regla): if x is A_1 and y is B_1 then z is C_1 ,

Premisa 3 (regla): if x is A_2 and y is B_2 then z is C_2 ,

Consecuente (conclusión): z is C' ,

se puede emplear el razonamiento difuso demostrado en la Figura 3.7 como procedimiento de la inferencia para derivar el conjunto difuso de salida resultante C' .

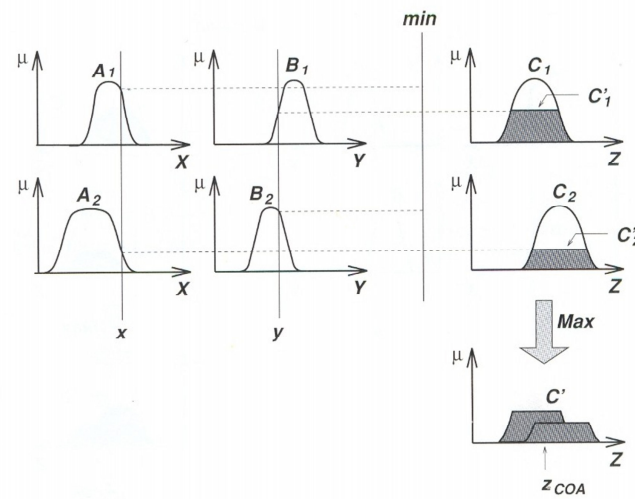


Figura 3.7: Razonamiento difuso para múltiples reglas con múltiples antecedentes.

En la Figura 3.7, los conjuntos difusos A' y B' no tienen por qué ser necesariamente los mismos que los conjuntos difusos A y B del antecedente de la regla y el conjunto difuso C' tampoco tiene por qué ser necesariamente el mismo que el conjunto difuso C que aparece en el consecuente de la regla.

En lógica clásica, una regla se ejecuta sólo si la primera premisa es exactamente la misma que el antecedente de la regla y el resultado de cada regla ejecutada es exacto al consecuente; en cambio en lógica difusa, una regla se ejecuta si existe un grado de similaridad distinto de cero entre la primera premisa y el antecedente de la regla y el resultado de la ejecución de la regla es un consecuente que tiene un grado de similaridad distinto de cero con el consecuente de la regla [17].

En resumen, el proceso del razonamiento difuso o del razonamiento aproximado se puede dividir en cuatro pasos [6]:

- **Grados de Compatibilidad (Grado de Cumplimiento).** Compara los hechos conocidos con los antecedentes de reglas difusas para encontrar los grados de compatibilidad con respecto a cada MF antecedente.

- **Esfuerzo de Disparo (*Firing Strength*)**. Al combinar los grados de compatibilidad (o grados de cumplimiento) con respecto a MFs antecedentes en una regla usando operadores difusos AND o OR se forma un esfuerzo de disparo que indica el grado al cual la parte antecedente de la regla está satisfecha.
- **Calificado (inducido.) MFs consecuente**. Aplica el esfuerzo de disparo a la MF consecuente de una regla para generar una MF consecuente calificada. (Las MFs calificadas representan como el esfuerzo de disparo es propagado y usado en una declaración de implicación difusa.)
- **MF de Salida total**. Agrega a todas las MFs calificadas para obtener una MF de salida total.

3.6 Sistema de inferencia difusa

El **Sistema de Inferencia Difusa** (FIS) es una estructura computacional usual basado en los conceptos de teoría de conjuntos difusos, reglas difusas IF-THEN, y razonamiento difuso. Existen aplicaciones de este tipo de sistemas en control automático, clasificación de datos, análisis de decisión, sistemas expertos, predicción de series de tiempo, robótica, y reconocimiento de patrones, entre otras áreas. Debido a su naturaleza multidisciplinaria, el FIS es conocido por distintos nombres, tales como **sistemas basados en reglas difusas** (fuzzy-rule-based system), **sistemas expertos difusos** (fuzzy expert system), **modelos difusos** (fuzzy models), **memoria asociativa difusa**, (fuzzy associative memory), **controles de lógica difusa** (FL controller), o simplemente **sistemas difusos** (fuzzy system) [6].

La estructura básica de un FIS consiste en tres componentes conceptuales: una **base de reglas**, la cual contiene una selección de reglas difusas; una **base de datos** (o diccionario), el cual define la función pertenencia usadas en las reglas difusas; y un **mecanismo de razonamiento**, que realiza el procedimiento de inferencia sobre las reglas y hechos dados para obtener una salida razonable o la conclusión [6].

Los sistemas de inferencia difusa básicos pueden tomar entradas difusas o entradas *crisp* (concretas, que es visto como singleton difuso), pero las salidas son conjuntos casi siempre difusos. A veces es necesario tener una salida *crisp*, sobre todo en una situación donde un sistema de inferencia difuso es usado como un regulador. Por lo tanto se necesita un método de defuzificación definido más adelante, para extraer un valor *crisp* que mejor representa un conjunto difuso. Un sistema de inferencia difusa con una salida *crisp* es mostrado en la Figura 3.8, donde la línea punteada indica un sistema de inferencia básico difuso con la salida difusa y el bloque de defuzificación sirve con el objetivo de transformar una salida representada por un conjunto difuso en un valor *crisp* único.

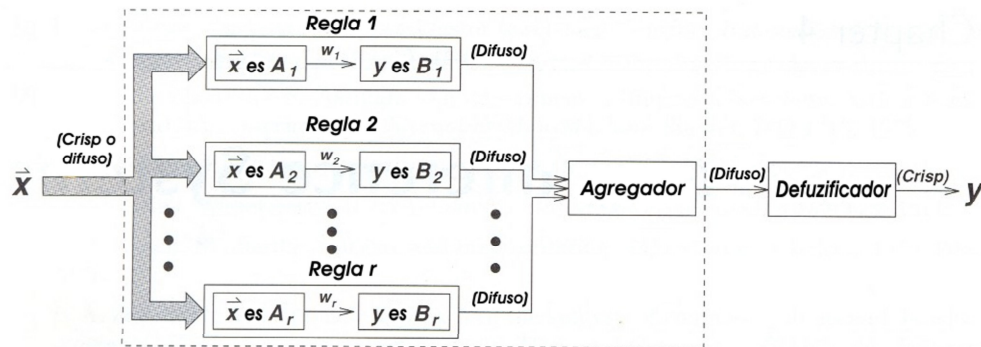


Figura 3.8: Diagrama de bloques para un FIS.

Con entradas y salidas *crisp*, un FIS implementa un mapeo no lineal de su espacio de entrada a su espacio de salida. Este mapeo es logrado por un número de reglas difusas IF-THEN, donde cada una de estas describe el comportamiento local del mapeo. En particular, el antecedente de una regla define una región difusa en el espacio de entrada, mientras el consecuente especifica la salida en la región difusa.

A continuación se introducirá dos tipos de sistemas de inferencia difusas que han sido empleados extensamente en varias aplicaciones. Las diferencias entre estos dos FIS yace en el consecuente de sus reglas difusas, y así su agregación y procedimientos de defuzificación se diferencian en consecuencia [6].

3.6.1 Modelo Fuzzy Mamdani

El **Sistema de inferencia Mamdani** fue propuesto como el primer intento de controlar un motor de vapor y la combinación de caldera por un conjunto de reglas de control lingüísticas obtenidas de personal operador experimentado. La Figura 3.7 es una ilustración de como un sistema de inferencia Mamdani difuso de dos reglas provee la salida total z cuando es sometido a dos entradas *crisp* (concretas) x e y . La planta toma valores sólo *crisp* como entradas, y se utiliza un defuzificador para convertir un conjunto difuso a un valor *crisp* (Z_{COA}) [6].

Defuzificación

Defuzificación se refiere al modo que un valor *crisp* es extraído de un conjunto difuso como un valor representativo. En general, existen cinco métodos para defuzificar un conjunto difuso A a un universo de discurso Z las cuales son: centroide de área, bisector de área, media del máximo, más pequeña del máximo, y el más grande del máximo. Esto se muestra en la Figura 3.9 (el conjunto difuso A es representado por una MF de salida agregada, como C' en la Figura 3.7).

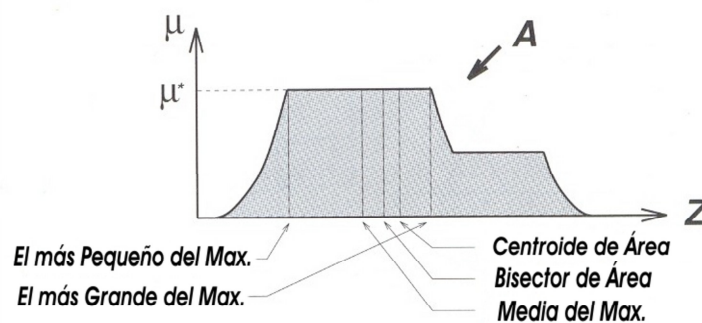


Figura 3.9: Varios esquemas de defuzificación para obtener una salida *crisp*.

El bloque defuzificador realiza la función contraria al difusor. La entrada al bloque defuzificador es el conjunto difuso de salida, resultado del bloque de inferencia y la salida es un valor concreto de la variable de salida. Para obtener, a partir del conjunto difuso de salida que resulta de la agregación de todas las reglas, un resultado escalar, se aplican los métodos matemáticos mencionados [6].

Otras variantes

En consideración a la eficiencia de cómputo o tratabilidad matemática, un sistema de inferencia difusa en la práctica puede tener un cierto mecanismo de razonamiento que no sigue la definición estricta de la regla compositiva de inferencia. Por ejemplo, se podría usar el producto para calcular esfuerzo de disparo (para reglas con el antecedente AND), mínimos para cálculos competentes en MFs consecuentes, y el máximo para agregárselos en una MF salida total. Por lo tanto, para especificar completamente la operación de un sistema de inferencia Mamdani difusa, tenemos que asignar una función para cada uno de los operadores siguientes [6]:

- **Operator AND** (usualmente T-norm) para calcular el esfuerzo de disparo de una regla con antecedentes AND.
- **Operator OR** (usualmente T-conorm) para calcular el esfuerzo de disparo de una regla con antecedentes OR.
- **Operator de Implicación** (usualmente T-norma) para calcular MFs consecuentes clasificadas basadas en esfuerzos de disparo dados.
- **Operator de Agregación** (usualmente T-conorma) para que se agreguen MFs consecuentes clasificadas para generar una MF salida total.
- **Operator de Defuzificación** para transformar una MF de salida a un valor de salida singular *crisp* (concreto).

3.6.2 Modelo difuso Sugeno

El **Modelo difuso Sugeno** (también conocido como **modelo difuso TSK**) fue propuesto por Takagi, Sugeno, y Kang en un esfuerzo de desarrollar una aproximación sistemática a la generación de reglas difusas de un conjunto de datos entrada-salida dado. Este método es similar al método Mamdani en muchos aspectos. Las dos primeras partes del proceso de inferencia difusa, fuzificación de las entradas y aplicación de operador difuso, son exactamente los mismos. La diferencia principal entre Mamdani y Sugeno es que las MFs de salida Sugeno son lineales o constantes [10, 20]. Una regla difusa típica en un modelo difuso Sugeno tiene la forma

$$\text{if } x \text{ is } A \text{ and } y \text{ is } B \text{ then } z = f(x, y),$$

donde A y B son conjuntos difusos en el antecedente, mientras que $z = f(x, y)$ es una función *crisp* en el consecuente. Usualmente $f(x, y)$ es un polinomio en las variables de la entrada x e y , pero puede ser cualquier función mientras pueda describir apropiadamente la salida del modelo dentro de la región difusa especificada por el antecedente de la regla. Cuando el $f(x, y)$ es un polinomio de primer orden, el sistema de inferencia difuso resultante es llamado **Modelo difuso Sugeno de primer orden**. Cuando f es constante, entonces se tiene un **Modelo difuso Sugeno de orden-cero**, el cual puede ser visto como cualquier caso especial de un sistema de inferencia difusa Mamdani, en el cual cada regla consecuente es especificado por un singleton difuso (o un predefuzificador consecuente).

La Figura 3.10 muestra el procedimiento de razonamiento difuso para un modelo difuso Sugeno de primer-orden. Ya que cada regla tiene una salida *crisp*, la salida total es obtenida vía el **promedio ponderado**, evitando así el proceso de defuzificación que consume gran cantidad de recursos computacionales requeridos en un modelo Mamdani. En la práctica, el operador ponderado medio a veces es substituido por el **operador de suma ponderado** (es decir $z = w_1z_1 + w_2z_2$) para simplificar el cómputo, sobre todo en el entrenamiento de un sistema de inferencia difusa.




Figura 3.10: Modelo difuso Sugeno.

Para un modelo Sugeno orden-cero, el nivel de salida z es constante ($p = q = 0$). El nivel de salida z_i de cada regla es ponderado por el esfuerzo de disparo w_i de la regla. Para una regla AND con entrada 1 = x y entrada 2 = y , el esfuerzo de disparo es:

$$w_i = \text{AndMethod}(F_1(x), F_2(y)) \quad (3.6.1)$$

donde $F_{(1,2)}(\cdot)$ son las funciones pertenencia para las entradas 1 y 2. La salida final del sistema es el promedio ponderado de todas las salidas de la regla, calculado como [10]:

$$\text{Salida Final} = \frac{\sum_{i=1}^N w_i z_i}{\sum_{i=1}^N w_i} \quad (3.6.2)$$

Ya que la única parte difusa de un modelo Sugeno está en su antecedente, es fácil demostrar la distinción entre un conjunto de reglas difusas y no difusas [6].

3.6.3 Modelo difuso Sugeno dos-entradas una-salida

La Figura 3.11 (a) traza las funciones pertenencia de entrada X e Y , y la figura 3.11 (b) es el diagrama resultante de superficie de entrada-salida. El diagrama de superficie es complejo, pero es todavía obvio que la superficie es compuesta de cuatro planos, cada uno del cual es especificado por la ecuación de salida de una regla difusa.

A diferencia del modelo difuso Mamdani, el modelo difuso Sugeno puede seguir la regla compositiva de inferencia estrictamente en su mecanismo de razonamiento difuso. Esto plantea algunas dificultades cuando las entradas a un modelo difuso Sugeno son difusas.

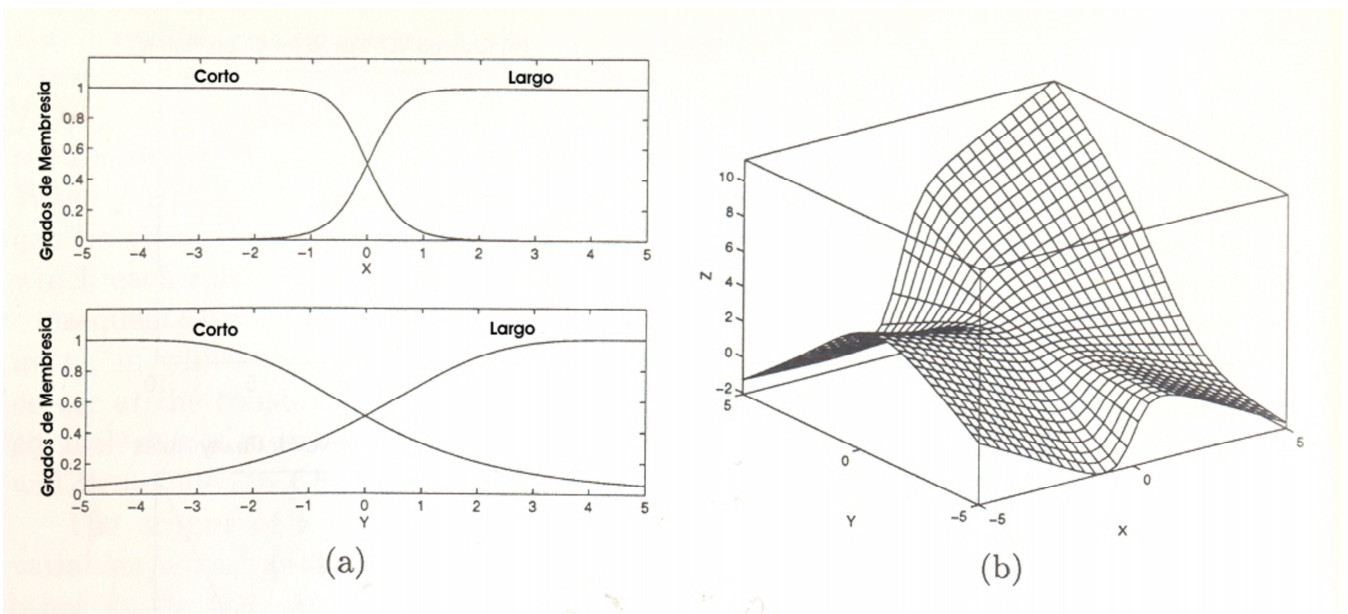


Figura 3.11: Dos-entradas una-salida Modelo difuso Sugeno: (a) MFs antecedente y consecuente; (b) diagrama de superficie entrada-salida total.

Sin la operación de defuzificación, que consume mucho tiempo en operaciones matemáticas, el modelo difuso Sugeno es en gran medida el candidato más apropiado para modelado difuso basado en muestreo de datos [6].

3.7 Conclusiones

En este capítulo se describió la teoría de los sistemas lógicos difusos, así como los usos que tiene esta rama de la inteligencia artificial en una amplia variedad de campos. Además, se describen las definiciones básicas, las terminologías, y las operaciones utilizadas en conjuntos difusos. Es descrito el sistema difuso Mamdani y el Sugeno, estos dos sistemas responden a entradas crisp (concretas), ambos realizan las dos primeras partes del proceso de inferencia difusa, por otro lado la diferencia principal recae en que las funciones pertenencia de salida Sugeno son lineales o constantes, y en cambio Mamdani necesita una etapa de defuzificación para obtener la salida *crisp*.

Capítulo 4

MODELADO DE LA TEMPERATURA DE ENTRADA AL SB MEDIANTE LÓGICA DIFUSA

4.1 Introducción

Como se mencionó en el capítulo anterior 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 este capítulo se realiza un modelado de la temperatura a la entrada de descascarado utilizando lógica difusa, en el cual se explotan sus características descritas en el Capítulo 3.

Además, se describe el modelo físico utilizado en planta, así como los datos que se utilizarán para los experimentos y simulaciones, también las arquitectura de los diferentes sistemas de lógica difusa que se proponen para la estimación de la temperatura, los cuales son sistemas de inferencia tipo Mamdani, Sugeno, y Sistema de Inferencia Neuro Difuso Adaptativo (por sus siglas en inglés ANFIS), este último se describirá posteriormente. También serán presentados

los resultados obtenidos de simulación en el ToolBox de Fuzzy Logic de Matlab para cada sistema y la comparación de éstos entre sí.

4.2 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, en planta 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, esta configuración se describe en la Figura 4.1.

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.

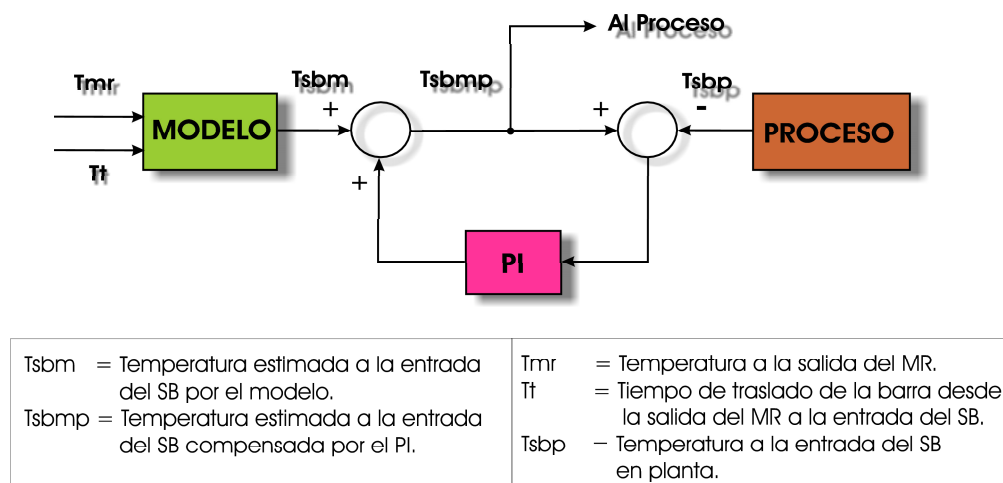


Figura 4.1: Estimación de temperatura con modelo de planta compensado con PI.

4.3 Datos para la experimentación

Las entradas requeridas 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 la comparación 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 No.1 de HYLISA, y éstos consisten en un total de 748 rollos de diferentes grados de acero. Originalmente, el modelo físico fue programado para llevar a cabo una estimación por cada ejecución, debido a esto, se llevó a cabo una modificación en la estructura del programa para que el modelo llevara a cabo las predicciones en una sola ejecución.

4.4 Modelos difusos Mamdani y Sugeno

Para el caso de sistemas difusos Mamdani y Sugeno se propone el esquema mostrado en la Figura 4.2 para estimar la temperatura a la entrada del SB, teniendo como entradas al sistema temperatura y tiempo de la misma manera que el sistema físico, y como salida del sistema la temperatura estimada.

Inicialmente se utilizaron 25 reglas como en [11-13], posteriormente se simplificaron a 9 para observar el impacto de estas en la estimación. A continuación se describen los sistemas difusos desarrollados en este trabajo: Mamdani nueve y veinticinco reglas, y Sugeno de nueve y veinticinco reglas.

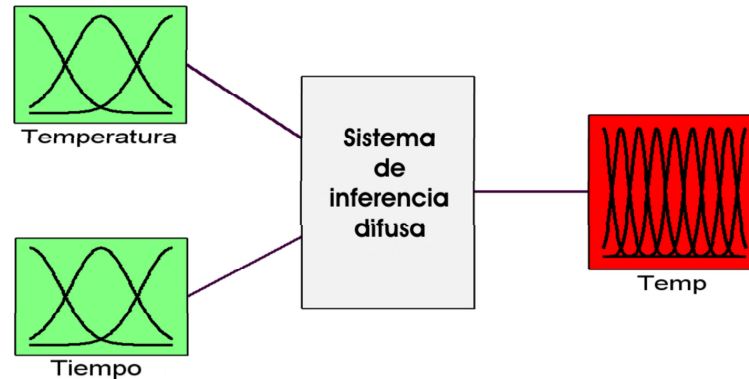


Figura 4.2: Esquema de sistema Mamdani y Sugeno en ToolBox de Matlab.

4.4.1 Modelo difuso Mamdani 9 y 25 reglas

Modelo difuso Mamdani 9 reglas

Para este sistema Mamdani de 9 reglas se propone para cada entrada tres funciones pertenencia (posibles casos) [13], para entrada Temperatura, Figura 4.3(a), se tiene MF con etiquetas lingüísticas de "Baja", "TempMedia", "TempAlta", con un rango de $[988^{\circ}C \ 1124^{\circ}C]$.

Para la entrada Tiempo, Figura 4.3(b), se tiene, "Corto", "TimeMedio", "Largo", con un rango de $[23 \ 162]$.

Para la salida Temp Figura 4.3(c) se tiene nueve MF, tres para cada nivel en su correspondiente etiqueta lingüística "Baja", "Media", "Alta", con rango de $[810^{\circ}C \ 1027^{\circ}C]$, los rangos de entrada y salida se definieron de acuerdo a los datos, y las funciones pertenencia de entrada y salida son de tipo gaussiana y se muestran en la Figura 4.3. Para la MF temperatura se utilizó una desviación estándar de 14.44, y medias de 1022, 1057, 1090. Para la MF Tiempo se consideró una desviación estándar de 14.76, y medias de 57.75, 92.5, 127.3. Fueron utilizadas para la MF de salida una desviación estándar de 9, y medias distribuidas en el respectivo rango.




Figura 4.3: Gráfica de entradas Temperatura y Tiempo, y de salida Temp.

Para referencias futuras se establece que las desviaciones estándar utilizadas en los sistemas son calculadas por Matlab, de manera que el punto de cruce sea en un grado de pertenencia de 0.5, que se recomienda apropiado (ver Sección 3.3.4). Las medias son distribuidas de tal forma que las MF quedan centradas en el rango utilizado basado en las entradas y salidas.

Se propone el uso de funciones gaussianas como funciones pertenencia debido a los cambios suaves que estas representan, y los procesos físicos son mejor representados por este tipo de funciones. En base a estas entradas se realizan las posible combinación de sus funciones pertenencia asociada a cada una de las salidas, obteniendo así las nueve reglas difusas, ver Tabla 4.1.

Estas reglas difusas se cargan en el ToolBox de Fuzzy Logic de MatLab, las operaciones de inferencia difusa utilizadas son: método And (min), Implicación (prod), Agregación (max) y defuzificación (centroide).

Tabla 4.1: Tabla de 9 reglas Mamdani.

1.-	if	Temperatura	is	Baja	and	Tiempo	is	Corto	Then	Temperatura	is	Baja3
2.-	if	Temperatura	is	Baja	and	Tiempo	is	TimeMedio	Then	Temperatura	is	Baja2
3.-	if	Temperatura	is	Baja	and	Tiempo	is	Largo	Then	Temperatura	is	Baja1
4.-	if	Temperatura	is	TempMedia	and	Tiempo	is	Corto	Then	Temperatura	is	Media3
5.-	if	Temperatura	is	TempMedia	and	Tiempo	is	TimeMedio	Then	Temperatura	is	Media2
6.-	if	Temperatura	is	TempMedia	and	Tiempo	is	Largo	Then	Temperatura	is	Media1
7.-	if	Temperatura	is	TempAlta	and	Tiempo	is	Corto	Then	Temperatura	is	Alta3
8.-	if	Temperatura	is	TempAlta	and	Tiempo	is	TimeMedio	Then	Temperatura	is	Alta2
9.-	if	Temperatura	is	TempAlta	and	Tiempo	is	Largo	Then	Temperatura	is	Alta1

Modelo difuso Mamdani 25 reglas

Al igual que el modelo difuso Mamdani de 9 reglas se tienen 2 entradas con la diferencia de que cada entrada tiene 5 MF, Temperatura Figura 4.4(a): "MuyBaja", "Baja", "TempMedia", "Alta", "MuyAlta".

En cuanto a las MFs de la entrada Tiempo Figura 4.4(b) se tiene: "MuyCorto", "Corto", "TimeMedio", "Largo", "MuyLargo".

En las MFs de la salida Temp Figura 4.4(c) se tiene 5 niveles para cada nivel de temperatura, lo que da como resultado 25 MF de salida Figura 4.4. En la Tabla 4.2 se muestra como son establecidas las 25 reglas difusas. Para la MF temperatura se utilizó una desviación estándar de 9.626, y medias de 1011, 1033, 1056, 1079, 1101. Para la MF Tiempo se consideró una desviación estándar de 9.838, y medias de 46.17, 69.33, 92.5, 115.17, 138.8. Para la MF de salida se utilizó una desviación estándar de 3, y medias distribuidas en el respectivo rango, se utilizan funciones gaussianas para las MFs. Los rangos de entrada y salida se definieron de acuerdo a los datos.




Figura 4.4: Gráfica de entradas Temperatura, Tiempo y salida Temp. para Mamdani 25 reglas.

Tabla 4.2: Tabla de 25 reglas difusas Mamdani.

1.-	If	Temperatura	is	MuyBaja	and	Tiempo	is	MuyLargo	Then	Temperatura	is	1
2.-	If	Temperatura	is	MuyBaja	and	Tiempo	is	Largo	Then	Temperatura	is	2
3.-	If	Temperatura	is	Baja	and	Tiempo	is	MuyLargo	Then	Temperatura	is	3
4.-	If	Temperatura	is	Baja	and	Tiempo	is	Largo	Then	Temperatura	is	4
5.-	If	Temperatura	is	TempMedia	and	Tiempo	is	MuyLargo	Then	Temperatura	is	5
6.-	If	Temperatura	is	MuyBaja	and	Tiempo	is	TimeMedio	Then	Temperatura	is	6
7.-	If	Temperatura	is	MuyBaja	and	Tiempo	is	Corto	Then	Temperatura	is	7
8.-	If	Temperatura	is	Baja	and	Tiempo	is	TimeMedio	Then	Temperatura	is	8
9.-	If	Temperatura	is	MuyBaja	and	Tiempo	is	MuyCorto	Then	Temperatura	is	9
10.-	If	Temperatura	is	TempMedia	and	Tiempo	is	Largo	Then	Temperatura	is	10
11.-	If	Temperatura	is	MuyAlta	and	Tiempo	is	MuyLargo	Then	Temperatura	is	11
12.-	If	Temperatura	is	MuyAlta	and	Tiempo	is	Largo	Then	Temperatura	is	12
13.-	If	Temperatura	is	Baja	and	Tiempo	is	Corto	Then	Temperatura	is	13
14.-	If	Temperatura	is	Alta	and	Tiempo	is	MuyLargo	Then	Temperatura	is	14
15.-	If	Temperatura	is	Alta	and	Tiempo	is	Largo	Then	Temperatura	is	15
16.-	If	Temperatura	is	TempMedia	and	Tiempo	is	TempMedio	Then	Temperatura	is	16
17.-	If	Temperatura	is	Baja	and	Tiempo	is	MuyCorto	Then	Temperatura	is	17
18.-	If	Temperatura	is	TempMedia	and	Tiempo	is	Corto	Then	Temperatura	is	18
19.-	If	Temperatura	is	TempMedia	and	Tiempo	is	MuyCorto	Then	Temperatura	is	19
20.-	If	Temperatura	is	Alta	and	Tiempo	is	TimeMedio	Then	Temperatura	is	20
21.-	If	Temperatura	is	Alta	and	Tiempo	is	Corto	Then	Temperatura	is	21
22.-	If	Temperatura	is	Alta	and	Tiempo	is	MuyCorto	Then	Temperatura	is	22
23.-	If	Temperatura	is	MuyAlta	and	Tiempo	is	TimeMedio	Then	Temperatura	is	23
24.-	If	Temperatura	is	MuyAlta	and	Tiempo	is	Corto	Then	Temperatura	is	24
25.-	If	Temperatura	is	MuyAlta	and	Tiempo	is	MuyCorto	Then	Temperatura	is	25

4.4.2 Modelo difuso Sugeno 9 y 25 reglas

Para el sistema difuso Sugeno se establecen las mismas reglas difusas que en el sistema Mamdani, con la diferencia de que a la salida tenemos funciones lineales, y en Mamdani se tienen MF. Básicamente las gráficas de entradas de sistema Mamdani son semejantes a los de Sugeno debido a que se utilizan las mismas reglas.

Para observar el comportamiento que se tendrá en el sistema se generan las gráficas de superficie como se muestra en la Figura 4.5, donde se tienen las gráficas de los sistemas Mamdani y Sugeno.

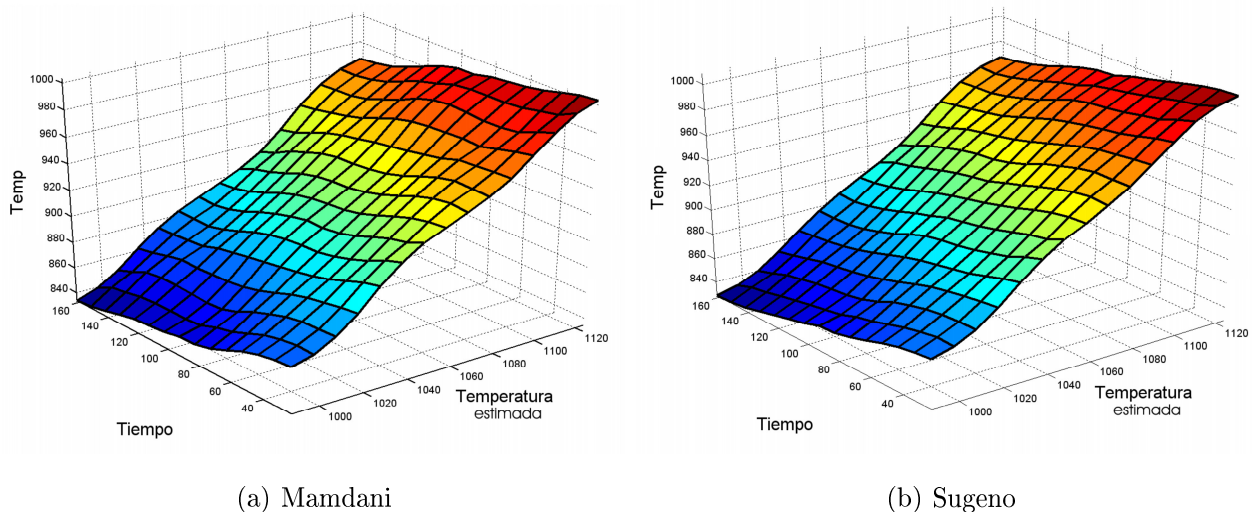


Figura 4.5: Gráfica de superficies de entradas Temperatura, Tiempo y salida Temp. para Mamdani y Sugeno de 9 reglas.

En las Tablas 4.1 y 4.2 se muestran las reglas difusas para los sistemas Mamdani (de 9 y 25 reglas respectivamente) y serán las mismas reglas para los sistemas Sugeno.

Los sistemas de inferencia difuso Sugeno que se utilizan en esta sección se pueden diseñar como los sistemas Mamdani, utilizando el ToolBox Fuzzy Logic de Matlab. Matlab realiza la conversión directa de un sistema Mamdani a un sistema Sugeno. Por defecto Matlab establece

el tipo de función que se tendrá a la salida de cada regla de sistema Sugeno, para estos sistemas se establecen funciones lineales de la forma $z_i = p_i x + q_i y + r_i$, en el cual $p_i = q_i = 0$, siendo por lo tanto un sistema Sugeno de cero-orden (Sección 3.6.2) y el nivel de salida de z_i es constante.

$$Z_{TOTAL} = \frac{w_1 z_1 + w_2 z_2 + \dots + w_i z_i}{w_1 + w_2 + \dots + w_i} \quad (4.4.1)$$

Los valores que se establecen a las constantes (r_i) corresponden a las medias de cada función de pertenencia correspondiente, dentro de un rango total de salida, donde estas se encuentran distribuidas.

4.5 Sistema de inferencia neuro difuso adaptativo (ANFIS)

4.5.1 Redes Neuronales difusas

Los sistemas híbridos que combinan lógica difusa, redes neuronales, algoritmos genéticos y sistemas expertos proporcionan los métodos más eficientes para resolver una gran variedad de problemas. Cada una de esas técnicas tiene propiedades computacionales particulares (por ejemplo: habilidad de aprender) que las hace óptimas para resolver ciertos problemas. Uno de estos sistemas híbridos corresponde a los sistemas Neuro-Difusos, que combinan las técnicas de redes neuronales artificiales y las técnicas de inferencia difusa [23].

La lógica difusa proporciona un mecanismo de inferencia sobre la incertidumbre y las redes neuronales ofrecen grandes ventajas computacionales, tales como el aprendizaje, la adaptación, la tolerancia a fallas, el paralelismo y la generalización. Las redes neuronales son usadas para representar los sistemas de inferencia difusa, los mismos que son empleados como sistemas de toma de decisiones. A pesar de que la lógica difusa puede codificar el conocimiento a través de etiquetas lingüísticas, usualmente toma mucho tiempo definir y ajustar las funciones de pertenencia. Las técnicas de aprendizaje de las redes neuronales pueden automatizar este proceso y reducir sustancialmente el tiempo y el costo de desarrollo al mejorar el desempeño del modelo [23].

En principio las redes neuronales y los sistemas difusos son equivalentes, pero en la práctica cada uno tiene sus propias ventajas y desventajas [23]. En las redes neuronales, el conocimiento se adquiere automáticamente por el algoritmo de retropropagación, pero el proceso de aprendizaje es relativamente lento (gran cantidad de épocas de entrenamiento) y el análisis de la red entrenada es difícil (modelo de caja negra). No es posible extraer el conocimiento estructural (reglas) de la red neuronal ni puede éste integrarse a la información especial sobre el problema en la red neuronal con el fin de simplificar el procedimiento de aprendizaje. Los sistemas difusos son más favorables porque su comportamiento puede ser explicado con base en reglas difusas y, de esta forma, su desempeño puede ser ajustado modificando estas reglas. Sin embargo, la adquisición del conocimiento es difícil, y además, el universo de discurso de cada variable necesita ser dividido en intervalos, por lo que las aplicaciones de los sistemas difuso se restringen a problemas en los cuales el conocimiento está disponible en un número de variables de entrada pequeño. Para superar el problema de la adquisición del conocimiento, las redes neuronales son extendidas para extraer automáticamente la reglas difusas de los datos numéricos [20, 23].

4.5.2 Arquitectura del modelo ANFIS

El modelo ANFIS propuesto por Jang [6], consiste de un sistema híbrido Neuro-Difuso, que es funcionalmente equivalente al mecanismo de inferencia Takagi-Sugeno (T-S) [6]. Para un sistema de inferencia T-S de primer orden, un conjunto de reglas difusas IF-THEN es el siguiente:

Regla 1: If x is A_1 and y is B_1 , then $f_1 = p_1x + q_1y + r_1$

Regla 2: If x is A_2 and y is B_2 , then $f_2 = p_2x + q_2y + r_2$

donde A_i y B_i son conjuntos difusos. La Figura 4.6(a) presenta este mecanismo de inferencia, los detalles se describirán más adelante.

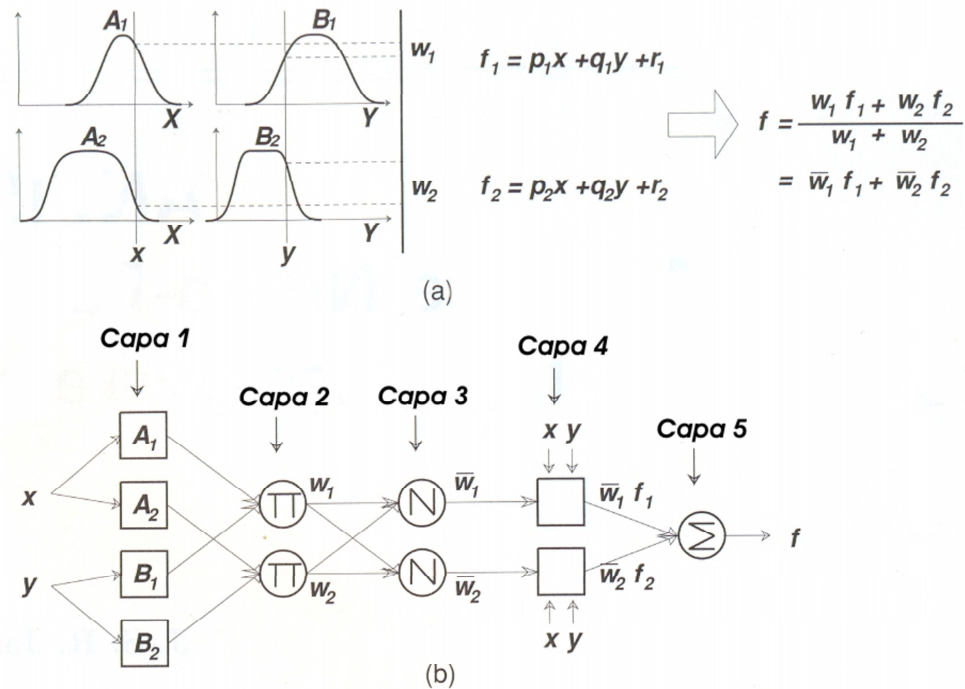


Figura 4.6: (a) Sistema de inferencia Takagi-Sugeno de primer orden; (b) Arquitectura ANFIS equivalente para inferencia Takagi-Sugeno de primer orden.

El esfuerzo de disparo o niveles de activación de las reglas se calculan como $w_i = A_i(x) \cdot B_i(y)$, $i = 1, 2$, donde el operador lógico AND (\cdot) puede ser modelado por una T-norma continua (producto). Las salidas individuales de cada regla son obtenidas como una combinación lineal entre los parámetros del antecedente de cada regla: $f_i = p_i x + q_i y + r_i$, $i = 1, 2$. La salida de control del modelo f se obtiene por la normalización de los grados de activación de las reglas y por la salida individual de cada una de ellas:

$$f = \frac{w_1 z_1 + w_2 z_2}{w_1 + w_2} \implies f = \bar{w}_1 z_1 + \bar{w}_2 z_2 \quad (4.5.1)$$

donde \bar{w}_1 y \bar{w}_2 son los valores normalizados de w_1 y w_2 con respecto a la suma ($w_1 + w_2$). La red Neuronal Híbrida que representa este tipo de inferencia es una red adaptable con 5 capas, donde cada capa representa una operación del mecanismo de inferencia difusa. Esta red se

muestra en la Figura 4.6(b).

En esta arquitectura, todos los nodos de una misma capa tienen la misma función (los nodos representados con cuadros son nodos adaptativos, es decir, sus parámetros son ajustables). La estructura de la red ANFIS consiste de cinco capas [6].

- **Capa 1:** Las entradas en esta capa corresponden a las entradas x e y , y la salida del nodo es el grado de pertenencia para el cual la variable de entrada satisface el término lingüístico asociado a este nodo. Este parámetro es referido como premisa. Cada nodo i en esta capa es un nodo adaptable con una función de nodo, donde x (o y) es la entrada para el nodo i y A_i (o B_{i-1}) es una etiqueta lingüística (como "corto" o "largo") asociada con ese nodo. En otras palabras, $O_{1,i}$ es el grado de pertenencia de un conjunto difuso A ($= A_1, A_2, B_1$ o B_2) y este especifica el grado a el cual la entrada x (o y) satisface el cuantificador A .

$$\begin{aligned} O_{1,i} &= \mu_{A_i}(x), \text{ para } i = 1,2, \text{ o} \\ O_{1,i} &= \mu_{B_{i-2}}(y), \text{ para } i = 3,4 \end{aligned} \quad (4.5.2)$$

- **Capa 2:** Cada nodo calcula el esfuerzo de disparo de la regla asociada a dicho nodo. Ambos nodos están representados con Π en la Figura 4.6(b), por el hecho de que ellos pueden representar cualquier T-norma para modelar la operación lógica AND. Los nodos de esta capa son conocidos como nodos de reglas.

$$O_{2,i} = \bar{w}_i = \mu_{A_i}(x)\mu_{B_i}(y), i = 1, 2 \quad (4.5.3)$$

- **Capa 3:** Cada nodo en esta capa está representado por N en la Figura 4.6, para indicar la normalización del esfuerzo de disparo. La salida del nodo es el esfuerzo de disparo normalizado (con respecto a la suma de los esfuerzos de disparo) de la regla i .

$$O_{3,i} = \bar{w}_i = \frac{w_i}{w_1 + w_2}, i = 1, 2 \quad (4.5.4)$$

- **Capa 4:** La salida de los nodos corresponde al producto entre el esfuerzo de disparo normalizado por la salida individual de cada regla. Este parámetro es referido como consecuente.

$$O_{4,i} = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i) \quad (4.5.5)$$

- **Capa 5:** El único nodo de esta capa calcula la salida total del sistema (agregación) como la suma de todas las entradas individuales de este nodo [6].

$$salidatotal = O_{5,1} = f = \sum_i \bar{w}_i f_i = \bar{w}_1 f_1 + \bar{w}_2 f_2 \quad (4.5.6)$$

La estructura de esta red adaptable no es única, se puede hacer una combinación de las capas 3 y 4 para obtener una red equivalente, con únicamente cuatro capas (para más detalle ver [6]).

4.5.3 Aprendizaje en el sistema ANFIS

El sistema ANFIS posee dos conjuntos de parámetros que deben ser entrenados: los parámetros del antecedente (constantes que caracterizan las funciones de pertenencia) y los parámetros del consecuente (parámetros lineales de la salida del modelo de inferencia). La estructura de aprendizaje del modelo ANFIS emplea algoritmos de gradiente descendiente para optimizar los parámetros del antecedente y el algoritmo de mínimos cuadrados para determinar los parámetros lineales del consecuente. Debido a esta combinación se lo conoce como **regla de aprendizaje híbrido** [6, 23].

Jang [6] describe que para aplicar el aprendizaje híbrido en grupo, en cada época de entrenamiento debe ejecutarse un paso *forward* y un paso *backward*, ver Tabla 4.3. En el paso *forward*, los parámetros de las funciones de pertenencia son inicializados y se presenta un vector de entrada-salida, se calculan las salidas del nodo para cada capa de la red y entonces los parámetros del consecuente son calculados usando el método de mínimos cuadrados. Una vez identificados los parámetros del consecuente, el error es calculado como la diferencia entre

la salida de la red y la salida deseada presentada en los pares de entrenamiento. Una de las medidas más usadas para el error de entrenamiento es la suma de errores cuadráticos (SEC), definida como [6, 23]:

$$SEC = \sum_{k=1}^N (d_k - z_k)^2 \quad (4.5.7)$$

donde d_k corresponde a los patrones de entrenamiento proporcionados (salidas deseadas) y z_k es la salida correspondiente de la red. En el paso *backward*, las señales de error son propagadas desde la salida, en dirección de las entradas; el vector gradiente es acumulado para cada dato de entrenamiento. Al final del paso *backward* para todos los datos de entrenamiento, los parámetros en la capa 1 (parámetros de las funciones de pertenencia) son actualizados por el método descendente [6, 23].

Tabla 4.3: Dos pasos en el procedimiento de aprendizaje híbrido para ANFIS.

	Paso Forward	Paso Backward
Parámetro Premisa:	Fijo	Gradiente descendiente
Parámetro Consecuente:	Estimador mínimos cuadrados	Fijo
Señales:	Salida de nodo	Señales de error

4.6 Medidas de desempeño de error de estimación

A continuación se darán a conocer los indicadores que serán la medida de desempeño del error de estimación, que son los que se utilizarán para todas las simulaciones en este trabajo.

Desviación estándar La desviación estándar (o desviación típica) es una medida de dispersión para variables de razón (relación o cociente) y de intervalo, de gran utilidad en la estadística descriptiva, es una medida de cuánto tienden a alejarse los valores puntuales

del promedio en una distribución. Esta medida es más estable que el recorrido y toma en consideración el valor de cada dato.

$$\sigma_e = \sqrt{\frac{\sum (x_e - \bar{x}_e)^2}{N - 1}} \quad (4.6.1)$$

donde x_e es el valor del dato, \bar{x}_e es la media, y N el total de datos.

Media. La media aritmética o promedio de una cantidad finita de números, es igual a la suma de todos ellos dividida entre el número de sumandos. Es uno de los principales estadísticos muestrales. Expresada de forma más intuitiva, podemos decir que la media (aritmética) es la cantidad total de la variable distribuida a partes iguales entre cada observación. Es decir, la media es una forma de resumir la información de una distribución suponiendo que cada observación tendría la misma cantidad de la variable.

$$\bar{x}_e = \frac{\sum x_e}{N} \quad (4.6.2)$$

donde x_e es el valor del dato, y N el total de datos.

Media Absoluta. La media absoluta es la Media aritmética o promedio, pero en este caso se utiliza únicamente sus valores absolutos de los datos.

$$|\bar{x}_e| = \frac{\sum |x_e|}{N} \quad (4.6.3)$$

RMS. En matemáticas, el valor cuadrático medio, media cuadrática o rms (del inglés *root mean square*) es una medida estadística de la magnitud de una cantidad variable. Puede calcularse para una serie de valores discretos o para una función variable continua. El nombre deriva del hecho de que es la raíz cuadrada de la media aritmética de los cuadrados de los valores. A veces la variable toma valores positivos y negativos, como ocurre, por ejemplo, en los errores de medida. En tal caso se puede estar interesado en obtener un promedio que no recoja los efectos del signo. Este problema se resuelve, mediante la denominada media cuadrática, que consiste en elevar al cuadrado todas las observaciones (así los signos negativos desaparecen), y obtener después su media aritmética y extraer, la raíz cuadrada de dicha media para volver a la unidad de medida original [15].

$$\bar{x}_{rms} = \sqrt{\frac{\sum x_e^2}{N}} \quad (4.6.4)$$

Banda de Tolerancia. No existe en planta una banda de tolerancia; de acuerdo con los fabricantes, en particular General Electric que es el de mayor participación en los molinos de laminación en caliente, en planta un $\pm 14^\circ C$ de error tiene un impacto de acarreo de 1 mm de error en el espesor, que se propaga en todo el molino. En este trabajo se considera $\pm 20^\circ C$ de tolerancia de banda de error. Además se calcula el porcentaje de cumplimiento dentro de la banda de tolerancia para cada sistema.

4.7 Experimentación y simulación de los sistemas

Para la experimentación y simulación del sistema, los 748 datos de los rollos se dividen en dos partes, 297 (40%) de los datos para realizar la validación del sistema y los restantes 451 (60%) para el entrenamiento. Estos datos están compuestos por dos entradas, la temperatura superficial medida a la salida del molino reversible y el tiempo de traslado del planchón, y una salida, la temperatura medida a la entrada del SB, la cual es la que se pretende estimar. En el caso de sistemas difusos puros Mamadani y Sugeno se utilizarán únicamente los datos de validación, esto para efecto de comparación con los resultados obtenidos por los diferentes sistemas puros y con entrenamiento (ANFIS), donde también se utiliza el 40 %.

La evaluación de los sistemas desarrollados se llevará a cabo aplicando las medidas de desempeño (mencionadas en la Sección 4.6) 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_{sbp} = Temperatura a la entrada del SB en planta.

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.

Dado que las medidas de desempeño se aplican sobre el error, el objetivo es reducirlos, excepto en el caso del porcentaje de cumplimiento dentro de la banda de tolerancia, donde se desea obtener un porcentaje mayor.

4.8 Análisis de resultados

Como se ha mencionado en este capítulo se establecieron diferentes estructuras o arquitectura de sistemas difusos: Mamdani y Sugeno nueve reglas, Mamdani y Sugeno 25 reglas, y ANFIS (Sección 4.5). Para el sistema ANFIS se utiliza el mismo sistema Sugeno de 25 y 9 reglas y se establecieron diferentes cantidades de épocas de aprendizaje; debido a que el mejor comportamiento se obtuvo con 10 épocas, los resultados son presentados con este número de épocas. En la Tabla 4.4 son presentados estos resultados, así como el modelo +PI utilizado actualmente en planta. En cada uno de estos, mientras el valor de cada medida de desempeño sea menor mejor es el desempeño, excepto en la banda de tolerancia ya que se busca un mejor porcentaje de cumplimiento.

Como se puede ver en la Tabla 4.4, el sistema de planta compensado +PI no es superado por los sistemas Mamdani, Sugeno (9 reglas) puros; en cuanto a los sistemas puros de 25 reglas, el compensado +PI fue superior, excepto en la media donde el sistema difuso mejoró considerablemente, lo cual produce un mayor porcentaje de cumplimiento. Todos los sistemas ANFIS superaron satisfactoriamente al modelo +PI. A continuación, en la Tabla 4.5, se describen un resumen de los resultados obtenidos para cada medida de desempeño, los números en paréntesis indican el número de reglas.

Tabla 4.4: Desviación estándar, Media, Media Absoluta, RMS, y Banda de tolerancia de las diferentes estructuras difusas, y Modelo +PI en términos de error de predicción.

Sistema	Reglas	Desv. estándar	Media	Media Absoluta	RMS	Banda Tol. %
Mamdani:	9	35.1154	25.5877	33.5725	43.4013	42.7609
Sugeno:	9	35.0539	25.662	33.564	43.3956	42.7609
ANFIS:	9	16.0068	-7.8763	14.3224	17.8155	73.4007
Mamdani:	25	28.1137	-0.5028	22.847	28.0709	50.1684
Sugeno:	25	28.0815	-0.4802	22.8181	28.0383	50.5051
ANFIS:	25	16.2819	-7.5311	14.4958	17.9144	73.064
Comp.+PI:	N/A	20.6479	-18.9096	23.3486	27.973	47.8114

Tabla 4.5: Resumen del desempeño en los indicadores de los sistemas.

Indicador	Mejor desempeño	Peor desempeño
Desviación estándar:	ANFIS (9)	Mamdani (9)
Media:	Sugeno (25)	Sugeno (9)
Media absoluta:	ANFIS (9)	Mamdani (9)
RMS:	ANFIS (9)	Mamdani (9)
Banda de tolerancia:	ANFIS (9)	Mamdani (9) Sugeno (9)

En la Figura 4.7 (a) se presentan histogramas que muestran el comportamiento de los sistemas difusos Mamdani y Sugeno de 9 y 25 reglas sin aprendizaje. Mientras que los sistemas con

9 reglas presentaron media y desviación estándar diferentes, aunque cercanos, los sistemas de 25 reglas presentaron resultados en estas medidas muy similares, como se mostró en la Tabla 4.4.

Como se puede observar en el histograma de la Figura 4.7 (b), los sistemas de 25 reglas sin aprendizaje Mamdani y Sugeno son comparados contra el modelo +PI, el cual tiene mejor desempeño en cuanto a desviación estándar; en cuanto a media y banda de tolerancia los sistemas difusos mencionados presentaron mejor desempeño.

En la Figura 4.7 (c) se observa un histograma del error de predicción de los modelos Mamdani y Sugeno sin aprendizaje de 25 reglas y ANFIS de 9 y 25 reglas con aprendizaje. Los sistemas ANFIS presentan un desempeño superior que los difusos sin aprendizaje, excepto en la media, pero ya que la desviación estándar es considerablemente menor para los ANFIS, su porcentaje de cumplimiento es mejor.

Por último, en la Figura 4.7 (d) se muestra un histograma del error de predicción de los modelos ANFIS 9 y 25 reglas y el Modelo +PI. En esta Figura se observa que el modelo ANFIS posee valores de media y desviación estándar de mejor desempeño que los obtenidos por el sistema compensado +PI. De este análisis se puede concluir que los sistemas ANFIS presentan un mejor desempeño para las condiciones probadas aquí.

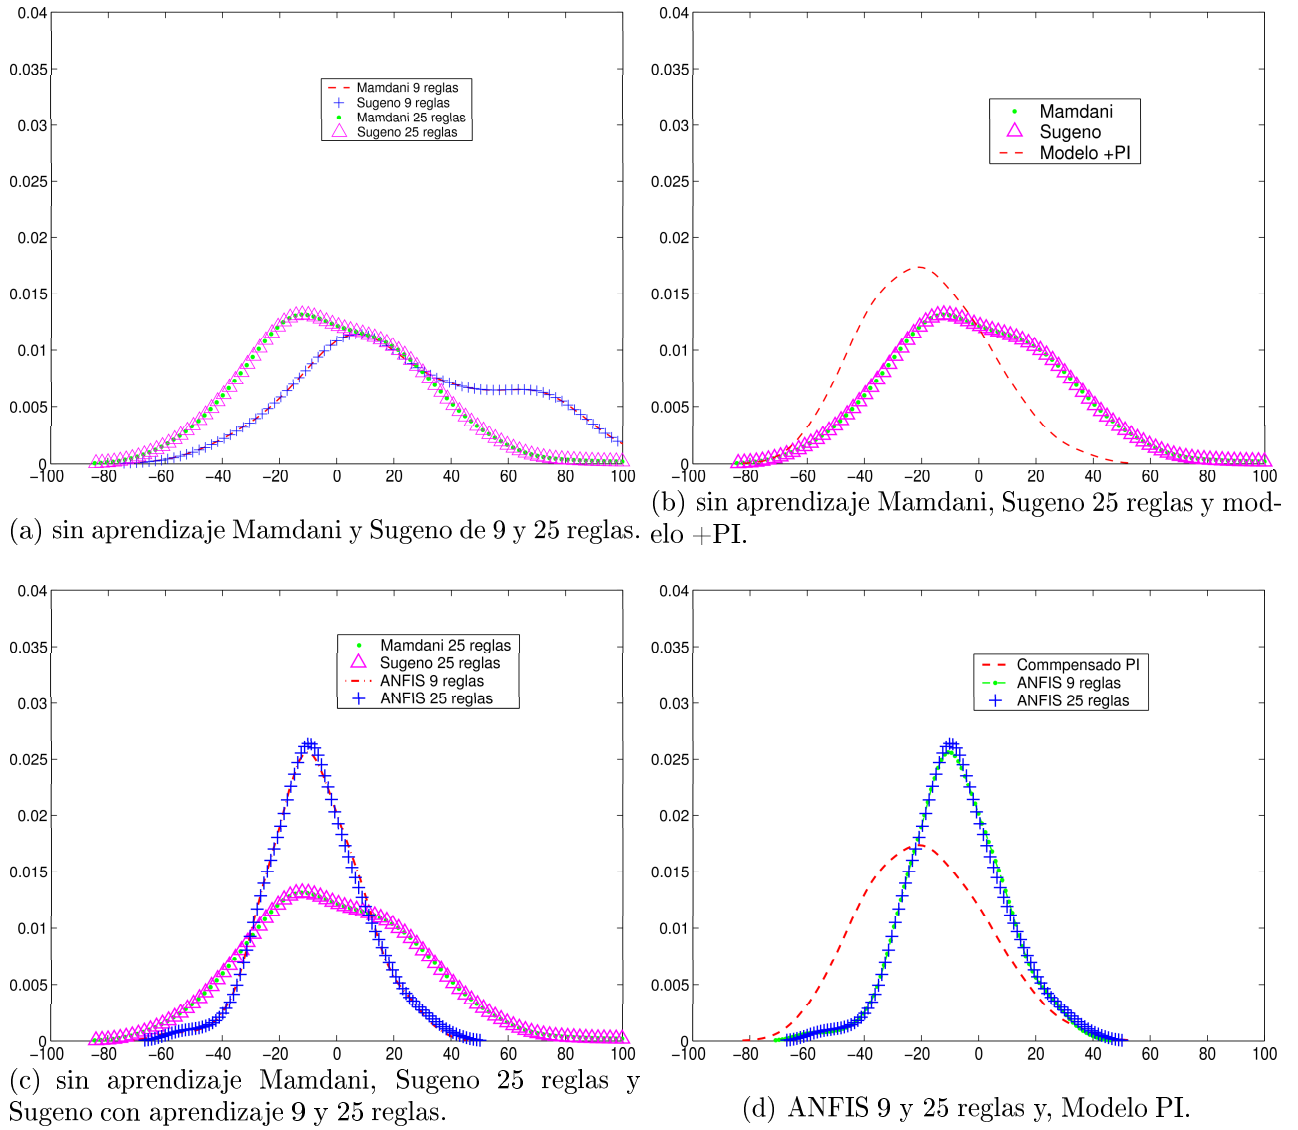


Figura 4.7: Histograma del error de predicción modelos: (a) sin aprendizaje Mamdani y Sugeno de 9 y 25 reglas; (b) sin aprendizaje Mamdani, Sugeno 25 reglas y modelo +PI; (c) sin aprendizaje Mamdani, Sugeno 25 reglas y Sugeno con aprendizaje 9 y 25 reglas; (d) modelos ANFIS 9 y 25 reglas y, Modelo PI.

4.9 Conclusiones

En este capítulo se presentaron diferentes modelos para estimar temperatura a la entrada del SB mediante lógica difusa, y se hizo mención acerca de los datos usados en los experimentos. Se presentaron los sistemas difusos Mamdani y Sugeno establecidos para 9 reglas y para 25, y se describió la arquitectura de sistemas ANFIS para estimar temperatura. Para el análisis de resultados fue necesario definir las medidas de desempeño a utilizar que sirven como indicadores.

Quedó demostrado que los sistemas Mamdani y Sugeno puros (9 reglas) no superan al modelo compensado +PI. En cuanto a Mamdani y Sugeno puros (25 reglas) superaron al modelo compensado +PI, en términos de media y porcentaje de cumplimiento. Todos los sistemas ANFIS propuestos superan con facilidad al modelo compensado +PI. Los sistemas ANFIS tienen mejor desempeño en general que los sistemas Mamdani y Sugeno puros, excepto en la media donde los sistemas puros resultan ser mejores, sin embargo el porcentaje de cumplimiento de los sistemas ANFIS fue mayor.

Capítulo 5

MODELADO SEMIFÍSICO PARA LA ESTIMACIÓN DE LA TEMPERATURA DE ENTRADA AL DESCASCARADO SECUNDARIO BASADO EN LÓGICA DIFUSA

5.1 Introducción

En este capítulo se propone el desarrollo de un sistema basado en una estructura semifísica, es decir, un sistema físico asistido por un sistema de lógica difusa, para la estimación de la temperatura a la entrada del descascarado secundario (SB).

La motivación al emplear un sistema semifísico recae en que éste al estar conformado por el sistema físico (el de planta) basado en un sistema de inteligencia artificial como lógica difusa (LD), conserva las características físicas del proceso.

5.1.1 Modelo semifísico

Un modelo semifísico es conocido y encontrado en la literatura también con el nombre de sistemas híbridos y cajas grises. Un sistema semifísico tiene la ventaja de abarcar una clase más grande de sistemas dentro de su estructura, teniendo más flexibilidad en el modelado de fenómenos dinámicos. Básicamente un sistema semifísico esta constituido por dos sistemas de diferente naturaleza, el primero considerado como sistema físico que podría ser un sistema utilizado por la planta, el segundo sistema considera diferente técnica al anterior por ejemplo inteligencia artificial. Para estos sistemas se pueden considerar dos estructuras, serie y paralelo. En este trabajo se considera al estructura en paralelo, como se ve en la Figura 5.1




Figura 5.1: Esquema de sistema semifísico aditivo en paralelo.

5.2 Modelado semifísico de la temperatura a la entrada del SB

Como se menciona anteriormente en este trabajo, se desarrolló un sistema físico apoyado por un sistema de LD. En este caso para el desarrollo de un sistema semifísico aditivo (en paralelo) como se muestra en la Figura 5.2, 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 modelos antes propuestos (Capítulo 4), que son sistemas basados solamente en LD para la estimación de temperatura.

5.2.1 Arquitectura del sistema semifísico difuso

Para implementar el sistema semifísico que se propone, es necesario también el diseño de un sistema difuso (entradas *temperatura* salida del RM y *tiempo* de transporte del RM a la tijera), que modela el *error* de estimación del modelo +PI. De la misma forma que los sistemas difusos propuestos anteriormente, las entradas al sistema semifísico son *temperatura* y *tiempo*, y a la salida *temperatura*. Los FIS utilizados al igual que el sistema ANFIS desarrollado en el Capítulo 4, son Mamdani 9 y 25 reglas, Sugeno de 9 y 25 reglas y ANFIS de 9 y 25 reglas.

En la Figura 5.2, \hat{E}_{FIS} es el error estimado por el sistema FIS o ANFIS; $\hat{T}_{mod.}$ es la temperatura estimada por el modelo físico; \hat{T}_{total} es la temperatura estimada por el sistema semifísico; T_{medida} es la temperatura medida en la planta; y E_{semi} es el error de estimación del sistema semifísico.

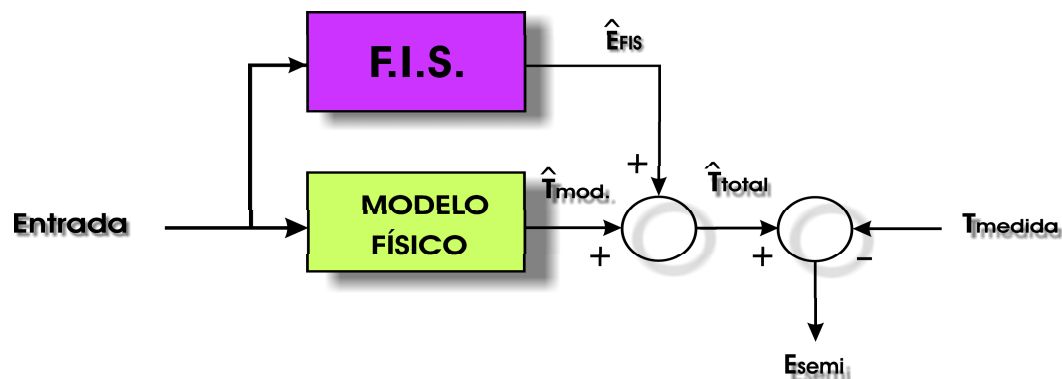


Figura 5.2: Esquema de sistema semifísico, cálculo de las medidas de desempeño a partir del error.

5.2.2 Modelo difuso Mamdani 9 y 25 reglas

Modelo difuso Mamdani 9 reglas

Para la entrada *Temperatura* se establecieron 3 funciones pertenencia: "Baja", "Media", "Alta", con rango de [988 1124] °C, Figura (5.2.2a).

Al igual con la entrada *Tiempo*: "Corto", "Medio", "Largo" con rango de [23 162], Figura (5.2.2b).

Y para la salida *Error* de estimación se tienen 9 funciones pertenencia "BajoBajo", "BajoMedio", "BajoAlto", "MedioBajo", "MedioMedio", "MedioAlto", "AltoBajo", "AltoMedio", "AltoAlto", con un rango de [-54 70], Figura (5.2.2c). Las funciones pertenencia de entrada y salida son de tipo gaussiana y se muestran en la Figura 5.2.2. Para la MF temperatura se utilizó desviación estándar de 14.44, y medias de 1022, 1057, 1090. Para la MF Tiempo se consideró desviación estándar de 14.76, y medias de 57.75, 92.5, 127.3. Para la MF de salida es utilizada una desviación estándar de 5.139, y medias distribuidas en el respectivo rango. Los rangos y parámetros de entrada y salida se definieron de acuerdo a los datos.




Figura 5.3: Funciones de pertenencia de entradas y salida para Mamdani 9 reglas.

Las operaciones de inferencia difusa utilizadas son: método And (min), Implicación (prod), Agregación (max) y defuzificación (centroide). Usando las posibles combinaciones de las funciones de pertenencia de las entradas y en base a conocimiento empírico y observación del comportamiento de los datos, se obtienen 9 reglas difusas. Estas quedan establecidas como se muestran en la Tabla 5.1.

Tabla 5.1: Tabla de 9 reglas Mamdani, predicción de error.

1.-	IF	Temperatura	is	<i>Baja</i>	And	Tiempo	is	<i>Largo</i>	Then	Error	is	<i>BajoBajo</i>
2.-	IF	Temperatura	is	<i>Baja</i>	And	Tiempo	is	<i>Medio</i>	Then	Error	is	<i>BajaMedio</i>
3.-	IF	Temperatura	is	<i>Baja</i>	And	Tiempo	is	<i>Corto</i>	Then	Error	is	<i>BajoAlto</i>
4.-	IF	Temperatura	is	<i>Media</i>	And	Tiempo	is	<i>Largo</i>	Then	Error	is	<i>MedioBajo</i>
5.-	IF	Temperatura	is	<i>Media</i>	And	Tiempo	is	<i>Medio</i>	Then	Error	is	<i>MedioMedio</i>
6.-	IF	Temperatura	is	<i>Media</i>	And	Tiempo	is	<i>Corto</i>	Then	Error	is	<i>MedioAlto</i>
7.-	IF	Temperatura	is	<i>Alta</i>	And	Tiempo	is	<i>Largo</i>	Then	Error	is	<i>AltoBajo</i>
8.-	IF	Temperatura	is	<i>Alta</i>	And	Tiempo	is	<i>Medio</i>	Then	Error	is	<i>AltoMedio</i>
9.-	IF	Temperatura	is	<i>Alta</i>	And	Tiempo	is	<i>Corto</i>	Then	Error	is	<i>AltoAlto</i>

Modelo difuso Mamdani 25 reglas


Para el sistema Mamdani 25 reglas, la entrada *Temperatura* posee 5 funciones pertenencia "MuyBaja", "Baja", "Media", "Alta", "MuyAlta", con rango de [988 1124] °C, Figura (5.4a).

De la misma manera la entrada *Tiempo*: "MuyCorto", "Corto", "Medio", "Largo", "MuyLargo" con rango de [23 162], Figura (5.4b).

Para la salida *Error* de estimación se tienen 25 funciones pertenencia, estas se dividen en 5 niveles de temperatura: "Muy Baja", "Baja", "Media", "Alta", "Muy Ata", con un rango de [-54 70], Figura (5.2.2c). Las 25 reglas difusas para el sistema Mamdani de 25 reglas se muestra en la Tabla 5.2. Para la MF temperatura se utilizó desviación estándar de 9.626, y medias de 1011, 1033, 1056, 1079, 1101. Para la MF Tiempo se consideró desviación estándar de 9.838, y medias de 46.17, 69.33, 92.5, 115.17, 138.8. Para la MF de salida es utilizada una desviación estándar de 1.714, y medias distribuidas en el respectivo rango. Los rangos y parámetros de entrada y salida se definieron de acuerdo a los datos disponibles.

Tabla 5.2: Tabla de 25 reglas Mamdani, predicción de error.

1.-	If	Temperatura	is	MuyBaja	And	Tiempo	is	MuyLargo	Then	Error	is	1
2.-	If	Temperatura	is	MuyBaja	And	Tiempo	is	Largo	Then	Error	is	2
3.-	If	Temperatura	is	Baja	And	Tiempo	is	MuyLargo	Then	Error	is	3
4.-	If	Temperatura	is	Baja	And	Tiempo	is	Largo	Then	Error	is	4
5.-	If	Temperatura	is	Media	And	Tiempo	is	MuyLargo	Then	Error	is	5
6.-	If	Temperatura	is	MuyBaja	And	Tiempo	is	Medio	Then	Error	is	6
7.-	If	Temperatura	is	MuyBaja	And	Tiempo	is	Corto	Then	Error	is	7
8.-	If	Temperatura	is	Baja	And	Tiempo	is	Medio	Then	Error	is	8
9.-	If	Temperatura	is	MuyBaja	And	Tiempo	is	MuyCorto	Then	Error	is	9
10.-	If	Temperatura	is	Media	And	Tiempo	is	Largo	Then	Error	is	10
11.-	If	Temperatura	is	MuyAlta	And	Tiempo	is	MuyLargo	Then	Error	is	11
12.-	If	Temperatura	is	MuyAlta	And	Tiempo	is	Largo	Then	Error	is	12
13.-	If	Temperatura	is	Baja	And	Tiempo	is	Corto	Then	Error	is	13
14.-	If	Temperatura	is	Alta	And	Tiempo	is	MuyLargo	Then	Error	is	14
15.-	If	Temperatura	is	Alta	And	Tiempo	is	Largo	Then	Error	is	15
16.-	If	Temperatura	is	Media	And	Tiempo	is	Medio	Then	Error	is	16
17.-	If	Temperatura	is	Baja	And	Tiempo	is	MuyCorto	Then	Error	is	17
18.-	If	Temperatura	is	Media	And	Tiempo	is	Corto	Then	Error	is	18
19.-	If	Temperatura	is	Media	And	Tiempo	is	MuyCorto	Then	Error	is	19
20.-	If	Temperatura	is	Alta	And	Tiempo	is	Medio	Then	Error	is	20
21.-	If	Temperatura	is	Alta	And	Tiempo	is	Corto	Then	Error	is	21
22.-	If	Temperatura	is	Alta	And	Tiempo	is	MuyCorto	Then	Error	is	22
23.-	If	Temperatura	is	MuyAlta	And	Tiempo	is	Medio	Then	Error	is	23
24.-	If	Temperatura	is	MuyAlta	And	Tiempo	is	Corto	Then	Error	is	24
25.-	If	Temperatura	is	MuyAlta	And	Tiempo	is	MuyCorto	Then	Error	is	25



(a) Temperatura

(b) Tiempo

(c) Error

Figura 5.4: Funciones de pertenencia para Mamdani 25 reglas.

5.2.3 Modelos difusos Sugeno 9 y 25 reglas

Se estableció que para los sistemas difusos Sugeno se utiliza la mismas base de reglas que en el sistema Mamdani. Las gráficas de entradas de sistema Mamdani son semejantes a los sistemas Sugeno (en este caso) debido a que se utilizan las mismas reglas.

El comportamiento que se tendrá en el sistema se observa generando las gráficas de superficie como se muestra en la Figura 5.5, donde se tienen las gráficas de los sistemas Mamdani y Sugeno. En este caso Mamdani y Sugeno al tener las mismas reglas (Tablas 5.1 y 5.2) tienen comportamiento similares, por este motivo se muestran las gráficas de los sistemas con diferentes reglas.

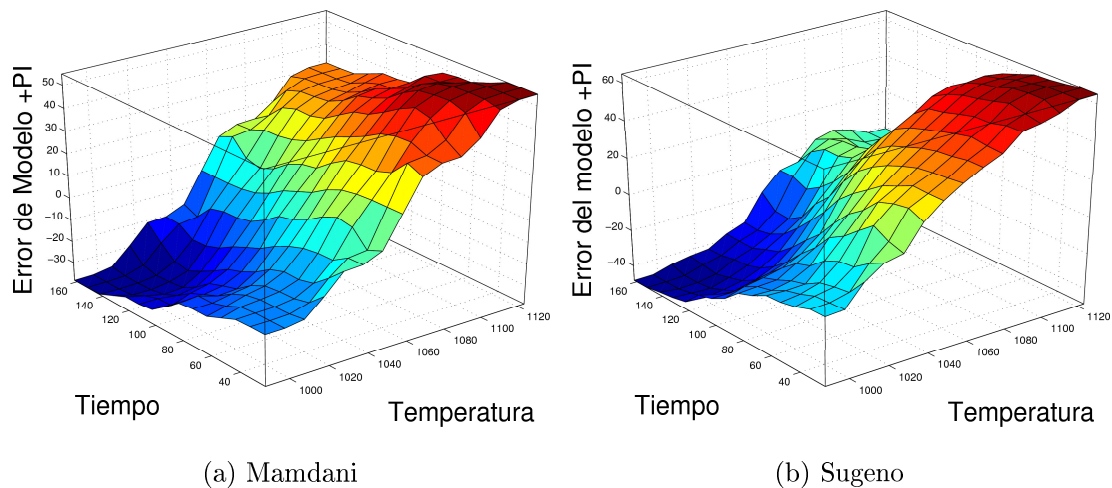


Figura 5.5: Gráfica de superficie entradas Temperatura, Tiempo y salida Error del modelo +PI para Mamdani 9 reglas y Sugeno 25 reglas.

Como se mencionó en la Sección 4.4.2, Matlab realiza la conversión directa de un sistema Mamdani a un sistema Sugeno. Así, las funciones de salida son generadas de la misma forma como se menciona en la Sección 4.4.2.

5.3 Experimentación y simulación de los sistemas

Para la experimentación y simulación se trabajó con los mismos 748 datos que se mencionaron en las Secciones 4.3 y en 4.7, de los cuales 451 (60%) datos se utilizan para entrenamiento del sistema y los restantes 297 (40%) para la validación. La evaluación de los sistemas desarrollados se llevará a cabo utilizando las medidas de desempeño mencionadas en la Sección 4.6, aplicadas al error de predicción del sistema semifísico que se muestra en la Figura 5.2.

La experimentación y simulación se divide en cuatro etapas, las cuales serán analizadas en la sección siguiente. Se presentará experimentación y simulación:

1. Para estimar temperatura con modelo semifísico, utilizando los sistemas Mamdani y Sugeno (9 y 25 reglas) sin aprendizaje.
2. De los sistemas para estimar temperatura con modelo semifísico, Sugeno, comparándolo con modelo compensado +PI
3. De los sistemas para estimar temperatura con modelo semifísico, sin aprendizaje Sugeno (9 y 25 reglas) para comparar con ANFIS (9 y 25 reglas).
4. Del sistema semifísico para estimar temperatura, Sugeno (9 reglas) y ANFIS (9 reglas) contra el modelo compensado +PI.

Al igual que en los sistemas presentados en el Capítulo 4, las medidas de desempeño se aplican sobre el error; se busca reducirlos excepto en el caso del porcentaje de cumplimiento dentro de la banda de tolerancia, donde se busca un porcentaje mayor, ya que es el número de barras cuya estimación estuvo dentro del rango de cumplimiento.

5.4 Análisis de los resultados

A continuación se presentan los resultados de los sistemas semifísicos, los cuales se muestran en la Tabla 5.3 y posteriormente se presentan histogramas exhibiendo resultados de acuerdo con

las cuatro etapas que se mencionan en la Sección 5.3.

Tabla 5.3: Desviación estándar, Media, Media Absoluta, RMS, y porcentaje de barras dentro de la Banda de tolerancia de las diferentes estructuras difusas, y Modelo +PI en términos de error de predicción.

Semifísico	Reglas	Desv. estándar	Media	Media Absoluta	RMS	Banda Tol. %
Mamdani:	9	16.823	-5.5751	13.858	17.696	77.104
Sugeno:	9	16.804	-5.5331	13.838	17.665	77.441
Mamdani:	25	17.021	-20.344	21.935	26.507	50.168
Sugeno:	25	17.026	-20.331	21.926	26.5	50.168
ANFIS:	9	15.998	7.8332	14.307	17.789	73.401
ANFIS:	25	16.308	7.4905	14.506	17.921	73.064
Comp.+PI:	N/A	20.6479	-18.9096	23.3486	27.973	47.8114

En la Tabla 5.3 se muestran los resultados obtenidos para los sistemas semifísicos, los cuales son: sistemas semifísico Mamdani y Sugeno (9 y 25 reglas puros); sistemas semifísico ANFIS (9 y 25 reglas), también se muestran los resultados del modelo +PI para su comparación. En negrita se muestran los mejores resultados para cada indicador.

La Tabla 5.3 muestra que los sistemas semifísicos Mamdani y Sugeno (9 reglas) presentan mejor desempeño que los sistemas semifísicos Mamdani y Sugeno (25 reglas). En el caso de los sistemas semifísicos ANFIS (9 y 25 reglas), ambos presentaron desempeños semejantes, pero menores a los obtenidos por los sistemas Mamdani y Sugeno sin entrenar. En general, todos los sistemas semifísicos difusos presentaron mejor desempeño que el sistema de planta compensado +PI. De acuerdo a los resultados en la Tabla 5.3, el sistema difuso Sugeno de 9 reglas presenta el mejor desempeño, aunque en general parecido al Mamdani de 9 reglas, y a excepción de la desviación estándar el cual es superado por las de sistema ANFIS.

En la Figura 5.6 (a), se presentan los histogramas del error de predicción para los sistemas Mamdani (9 y 25 reglas) y Sugeno (9 y 25 reglas). Se puede notar como los sistemas Mamdani y Sugeno (9 reglas), tienen desempeño semejantes y además son superiores a los sistemas Mamdani y Sugeno (25 reglas), como se puede apreciar también en la Tabla 5.3.

La Figura 5.6 (b) muestra los histogramas obtenidos de los sistemas Sugeno (9 y 25 reglas) comparándolo con el sistema de planta compensado +PI. No se muestra el sistema Mamdani de 9 reglas debido a que tiene comportamiento semejante al Sugeno de 9 reglas. Se observa como los dos sistemas semifísicos tienen mejor desempeño en cuanto a desviación estándar y media, resultando sobresaliente el sistema semifísico Sugeno (9 reglas), como también se aprecia en la Tabla 5.3.

En la Figura 5.6 (c) se muestra que el sistema semifísico Sugeno (9 reglas) es superior en desempeño a los sistemas Sugeno (25 reglas), y ANFIS (25 reglas), sólo superado en cuanto a desviación estándar por el sistema ANFIS de 9 reglas.

En la Figura 5.6 (d) se observa como los sistemas semifísico mostrados superan al modelo +PI y que el sistema que mejor resultados presenta en la estimación de la temperatura es el sistema semifísico apoyado por un sistema difuso Sugeno 9 reglas, debido principalmente a una media más cercana a cero, muy parecido a Mamdani de 9 reglas. Debido a que Sugeno no tiene defuzificación se reduce el uso de recurso computacional.

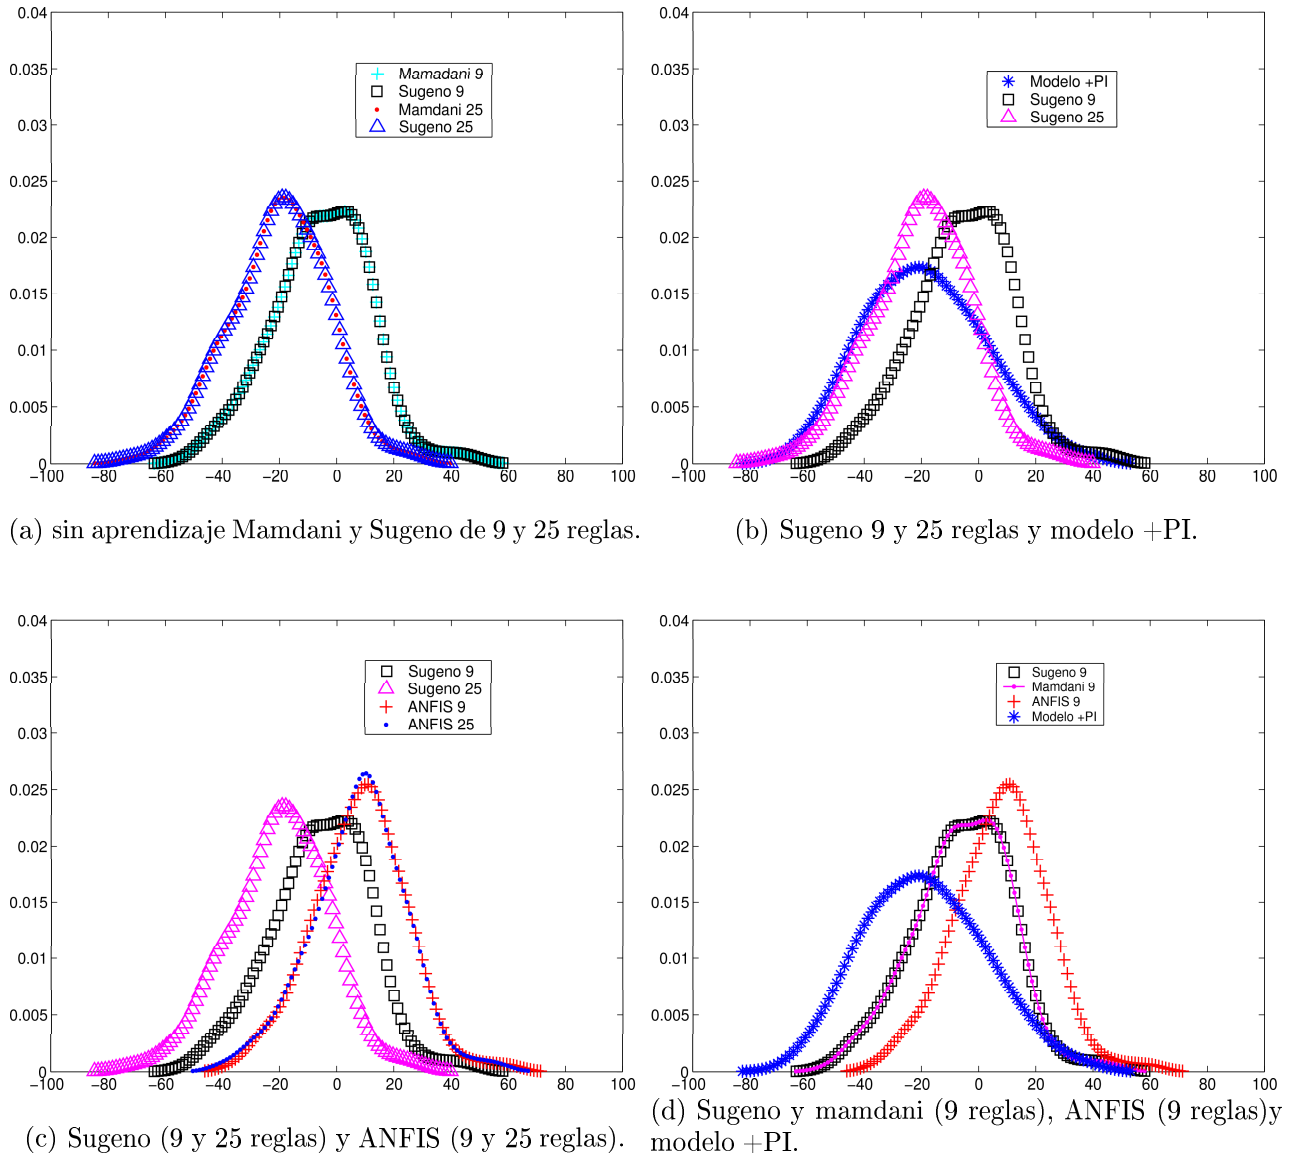


Figura 5.6: Histograma del error de predicción modelos semifisicos: (a) sin aprendizaje Mamdani y Sugeno de 9 y 25 reglas; (b) Sugeno 9 y 25 reglas y modelo +PI; (c) Sugeno (9 y 25 reglas) y ANFIS (9 y 25 reglas); (d) Sugeno y mamdani (9 reglas), ANFIS (9 reglas) y modelo +PI.

5.5 Comparación de resultados, estimación de temperatura con sistemas Difusos vs. sistemas Semifísicos

En esta sección se presentan los resultados representativos de los Capítulos 4 y 5, recordando que en el Capítulo 4 se experimentó con sistemas difusos estimando directamente temperatura, en cambio en el Capítulo 5 se trabajó con sistemas semifísicos basados en sistemas difusos, con el mismo objetivo de estimar temperatura. Los resultados más sobresalientes de estos dos casos son presentados a continuación en la Tabla 5.4.

Tabla 5.4: Desviación estándar, Media, Media Absoluta, RMS, y Banda de tolerancia, para la comparación de los sistemas Difusos, Semifísicos y Modelo +PI en términos de error de predicción.

Sistema	Reglas	Desv. estándar	Media	Media Absoluta	RMS	Banda Tol. %
Semif.Sugeno:	9	16.804	-5.5331	13.838	17.665	77.441
Semif.ANFIS:	9	15.998	7.8332	14.307	17.789	73.401
ANFIS:	9	16.0068	-7.8763	14.3224	17.8155	73.4007
ANFIS:	25	16.2819	-7.5311	14.4958	17.9144	73.064
Comp.+PI:	N/A	20.6479	-18.9096	23.3486	27.973	47.8114

En la Tabla 5.4 podemos observar que los sistemas propuestos difusos y semifísicos tienen mejor desempeño que el modelo compensado +PI, en términos de desviación estándar, media, media absoluta, RMS, y banda de tolerancia. Al realizar la comparación entre los sistemas difusos y semifísicos el que presenta el mayor desempeño es el sistema semifísico apoyado por un FIS Sugeno, el cual produce una media de -5.5331 y una banda de tolerancia de 77.441 % que es uno de los factores decisivos, lo cual nos indica el porcentaje de barras que se encontraron en el margen de error permitido, considerado en este estudio.

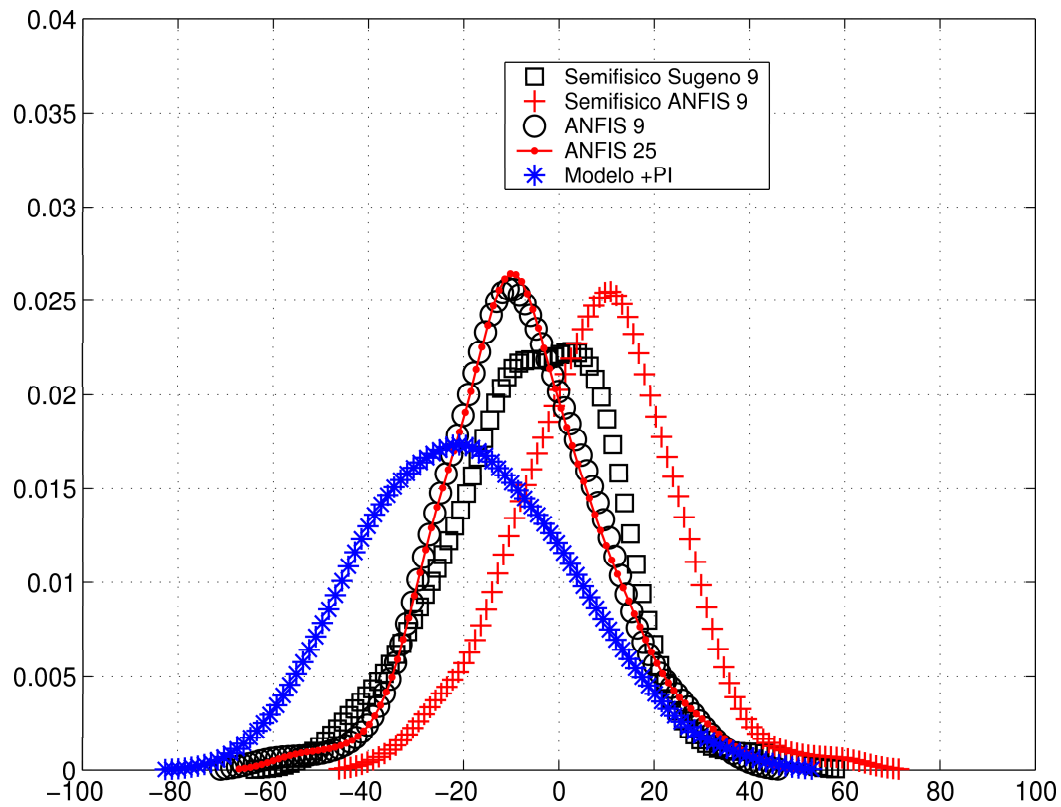


Figura 5.7: Histograma del error de predicción de los sistemas difusos, semifísicos y compensado +PI.

En la Figura 5.7 se puede observar el histograma de los sistemas difusos, semifísicos y compensado +PI. Se puede observar como los sistemas ANFIS (9 y 25 reglas) presentan comportamientos similares. En cuanto a los semifísicos Sugeno y ANFIS de 9 reglas, ambos presentan buen desempeño en cuanto a media y desviación estándar, aunque el mejor comportamiento lo presenta el modelo semifísico Sugeno de 9 reglas, como puede verse en la Tabla 5.4.

5.6 Conclusiones

En este capítulo se presentaron diferentes modelos semifísicos difusos para estimar temperatura a la entrada del SB. Se expusieron sistemas Mamdani y Sugeno (9 y 25 reglas), con la finalidad de estimar el error de predicción del modelo +PI, el cual se usa como factor de compensación aditivo en la estructura semifísica paralela, usada en este estudio. Se realizó una comparación para los sistemas difusos y semifísicos y se generaron tablas e histogramas para observar sus compartimientos.

Las principales observaciones derivadas del análisis son:

- De los sistemas Mamdani y Sugeno (9 y 25 reglas) para estimar el error de predicción, resultó ser mejor el sistema Sugeno 9 reglas. Por ese motivo se utiliza para hacer la compensación.
- En cuanto a los sistemas semifísicos probados, el que mejor desempeño presentó fue el sistema semifísico difuso Sugeno de 9 reglas, de acuerdo a los indicadores de desempeño utilizados aquí, excepto la desviación estándar donde es superado por una cantidad mínima por el ANFIS 9 reglas. El sistema semifísico difuso Sugeno de 9 reglas obtuvo el mayor porcentaje en cuanto a barras dentro del rango de tolerancia.
- Todos los sistemas semifísicos propuestos superan al modelo compensado +PI.
- De la comparación de los sistemas difusos y semifísicos, el sistema semifísico Sugeno 9 reglas resultó con mejor desempeño.
- Debido a que no existe defuzificación en Sugeno, el uso de recursos computacionales es menor.

Capítulo 6

CONCLUSIONES Y RECOMENDACIONES

6.1 Conclusiones

Un modelo semifísico es todo aquel modelo físico que es compensado por una técnica de inteligencia artificial, en este caso lógica difusa. Los sistemas semifísicos tienen implementación más segura y mantienen una interpretación física del proceso. En este trabajo se desarrollaron y evaluaron diferentes estructuras para la predicción de la temperatura de entrada al SB en un HSM: Sistemas de inferencia difusa Mamdani, Sugeno, y ANFIS, sistemas semifísico difuso Mamdani y Sugeno, y ANFIS; todos estos sistemas se simularon para 9 y 25 reglas.

En el presente trabajo se propone un grupo de sistemas para la estimación de temperatura basados por sistemas de inferencia difusa Mamdani, Sugeno, y ANFIS. Así mismo se proponen varios sistemas semifísicos apoyados por sistemas difusos (con y sin entrenamiento), los cuales fueron establecidos bajo las mismas condiciones. Además se consideró, para fines de comparación, agregar a esta serie de experimentos, la respuesta del modelo físico compensado con +PI.

Para las condiciones establecidas, los esquemas Semifísico y ANFIS presentan mejor desempeño que el modelo compensado +PI y que los puramente difusos en términos de desviación estándar, media, media absoluta, RMS y banda de tolerancia. Los experimentos fueron llevados

a cabo usando datos reales de planta, de diferentes grados de acero y espesor.

El hecho de resultar con mejor desempeño el sistema Sugeno sugiere que se podría considerar tener linealidad alrededor de diferentes puntos de operación de acuerdo a los datos probados aquí. Además, ya que los FIS Sugeno no tienen defuzificación se tiene menor uso de recurso computacional.

En este trabajo se demostró que, para las condiciones establecidas, el esquema semifísico presenta un desempeño muy cercano e incluso mejor que los de lógica difusa pura en términos de la media, media absoluta, desviación estándar, RMS, y banda de tolerancia del error de predicción, teniendo claro las ventajas del sistema semifísico, ya que este al tener la parte física (modelo de planta), conserva características del proceso, y proporcionan un comisionamiento seguro. Ambos sistemas presentan mayor desempeño comparado con el modelo compensado +PI.

6.2 Aportaciones

En el presente trabajo quedaron demostradas las ventajas de los esquemas de estimación de la temperatura a la entrada del SB, basándose en sistemas de lógica difusa. Se estableció el diseño, y se desarrollaron esquemas semifísicos, basados en sistemas difusos, exponiendo las propiedades particulares de cada uno, además de establecer ventajas con respecto a los sistemas físicos tradicionales y los basados únicamente en lógica difusa.

6.3 Recomendaciones

En base a los resultados que se obtuvieron de la aplicación de los sistemas semifísicos a la reducción de la incertidumbre de la medición de la temperatura se recomienda:

- Mejorar las reglas difusas para la obtención de un mejor desempeño, extrayendo la base de reglas directamente de los datos. Esto mediante la utilización de alguna técnica como redes

neuronales, razonamiento inductivo difuso, algoritmos difuso CMeans (fuzzy clustering FCM), y algoritmos genéticos, entre otros.

- Realizar la comparación de los resultados obtenidos de los sistemas semifísicos difusos con los basados en redes neuronales.
- Realizar la implementación y evaluación de un sistema semifísico serie (en este trabajo se utilizó paralelo), al igual que un sistema Mamdani adaptable para analizar su comportamiento en comparación con el sistema ANFIS, que utiliza un Sugeno adaptable.
- Debido a que en el presente trabajo únicamente se analizó la estimación de la temperatura a la entrada de la caja de descascarado secundario, se recomienda continuar con la estimación de la temperatura en el resto de los castillos del molino continuo.

Bibliografía

- [1] J.S. Anderson, T.J. McAvoy, and O.J.Hao, *Use of hybrid models in wastewater systems*, Industrial and Engineer Chemistry Research **39** (2000), 1694–1704.
- [2] Min-You Chen, *Material property prediction using neural fuzzy network*, IEEE, Proceedings of the 3rd World Congress on Intelligent Control and Automation **2** (2000), 1092–1097.
- [3] 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.
- [4] 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 (2005), 1–18.
- [5] 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** (1999), 131–138.
- [6] J.-S.R. Jang, C.-T. Sun, and E. Mizutani, *Neuro-fuzzy and soft computing*, 1997.
- [7] M. Kantrowitz, E. Horstkotte, and C. Joslyn, *Answers to frequently asked questions about fuzzy logic and fuzzy expert systems*.
- [8] P. Lauret, H.Boyer, and J.C.Gatina, *Hybrid modelling of the sucrose crystal growth rate*, International Journal of Modelling and Simulation **21** (2001), no. 1, 23–29.
- [9] D. A. Linkens, J. H. Beynon, and C. M. Sellars, *Grey box modelling methodologies and their application to materials processing*, Australasia Pacific Forum **12** (1997), 676–682.
- [10] MatLab, *Fuzzy logic toolbox user’s guide*, 2 ed., marzo 2006.
- [11] 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** (2006), no. 6, 583–596.
- [12] G.M. Mendez, Lopez-Juarez, L.A. Leduc, R. Soto, and A. Cavazos, *Temperature prediction in hot strip mill bars using a hybrid type-2 fuzzy algorithm*, I.J of Simulation **6** (2005), no. 9.

- [13] Gerardo Maximiliano Méndez, *Modelado mediante sistemas inteligentes del proceso de pérdida de calor en una placa de acero: Aplicación a predicción de temperatura en laminación en caliente*, Tesis doctoral, CIDESI, Queretaro, 2005.
- [14] Guillermo Morales-Luna, *Introducción a la lógica difusa*, Centro de Investigación y Estudios Avanzados del IPN (CINVESTAV-IPN) (2002), 1–12.
- [15] JR. Peyton Z. Peebles, *Probability, random variables, and random signal principles*, 1987.
- [16] Primož Potocnik, Igor Grabec, and Marko Setinc, *Neural net based hybrid modeling of the methanol synthesis process*, Kluwer Academic Publishers **11** (2000), no. 3, 219–228.
- [17] Rosanna Pérez Pueyo, *Procesado y optimización de espectros raman mediante técnicas de lógica difusa: Aplicación a la identificación de materiales pictóricos*, Tesis doctoral, Universitat Politècnica de Catalunya, Barcelona, 2004.
- [18] Paul E. Rooke and Hong Wang, *Applying combined neural network and physical modelling to the retention process in papermaking*, *Appita journal* **55** (2002), no. 4, 281–286.
- [19] Martin Schlanga, B. Langb, T. Runklerb T. Poppeb, and K. Weinzierlc, *Current and future development in neural computation in steel processing*, *Control Engineering Practice* **9** (2001), no. 9, 975–986.
- [20] James A. Freeman/David M. Skapura, *Neural networks, algorithms, applications, and programming techniques*, 1992.
- [21] 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).
- [22] 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** (2003), no. 17, 5051–5062.
- [23] Andrés Zúñiga and Carlos Jordán, *Aplicación de redes adaptables y sistemas de inferencia fuzzy para la previsión de caudales afluentes en centrales hidroeléctricas*, Reporte de proyecto, Escuela superior politécnica del litoral, Guayaquil, Ecuador, Julio 2005.