



**UNIVERSIDAD DE CONCEPCIÓN
FACULTAD DE INGENIERÍA
DEPARTAMENTO DE INGENIERÍA ELÉCTRICA**



**DESARROLLO DE TÉCNICAS DE SINTONIZACIÓN PARA ESTRATEGIAS DE
CONTROL DIFUSO MIMO APLICABLE A ESPESADORES DE RELAVE.**

POR

Benjamín Alejandro Araneda Muñoz

Memoria de Título presentada a la Facultad de Ingeniería de la Universidad de Concepción para
optar al título profesional de Ingeniero Civil Electrónico

Profesor Guía

Juan Pablo Segovia Vera

Profesores comisión evaluadora

Mario Rubén Medina Carrasco

Gabriel Alejandro Saavedra Mondaca

Julio 2025

Concepción (Chile)

©2025 Benjamín Alejandro Araneda Muñoz

©2025 Benjamín Alejandro Araneda Muñoz

Se autoriza la reproducción total o parcial, con fines académicos, por cualquier medio o procedimiento, incluyendo la cita bibliográfica del documento.

Sumario

El eficiente uso del agua en la industria minera es un desafío crucial, especialmente en la operación de espesadores de relaves, cuyos procesos de separación sólido-líquido son complejos, no lineales y multivariantes. Las estrategias de control convencionales y la sintonización manual de sistemas expertos a menudo no logran optimizar la recuperación de agua ni estabilizar la operación de forma robusta. Esta memoria de título se enfoca en el diseño y desarrollo de técnicas de sintonización automática para estrategias de control difuso MIMO (Múltiples Entradas, Múltiples Salidas) aplicables a espesadores de relaves. El objetivo principal es estabilizar la concentración de sólidos en la descarga, considerando variables críticas del proceso como el torque de la rastra, la dosificación de floculante y maximizando la recuperación de agua.

La metodología propuesta se desarrolló en etapas: primero, se diseñó un Controlador Lógico Difuso MIMO, cuyas reglas de inferencia se derivaron del conocimiento de modelos matemáticos ARMA del proceso. Luego, se aplicó el algoritmo de Optimización por Enjambre de Partículas (PSO) para sintonizar automáticamente los factores de escala del FLC, explorando dos filosofías de control mediante funciones de costo diferenciadas por sus pesos: la minimización del error cuadrático medio (MSE) y la minimización de los sobrepasos de las variables controladas. Finalmente, los datos generados por los FLC optimizados se utilizaron para entrenar controladores Adaptativos Neuro-Difusos (ANFIS), buscando un refinamiento adicional y mayor adaptabilidad. Todas las simulaciones y validaciones se realizaron en Matlab, utilizando datos históricos de un espesador industrial.

Los resultados demostraron la efectividad del PSO para sintonizar los FLC según los objetivos de control. Los FLC sintonizados para minimizar el error lograron una alta recuperación de agua, aunque presentaron un sobrepaso en los sólidos. Por otro lado, los FLC optimizados para minimizar los sobrepasos tuvieron un desempeño excelente en este aspecto, tanto en sólidos como en torque, aunque la recuperación de agua fue algo menor. Además, se demostró que los controladores ANFIS fueron capaces de aprender y replicar con éxito el comportamiento de los FLC optimizados. Los ANFIS entrenados para cada objetivo mantuvieron las características deseadas, logrando una buena recuperación de agua o bajos sobrepasos, respectivamente. Las pruebas de robustez con perturbaciones invertidas indicaron una buena capacidad de generalización de los ANFIS.

Summary

The efficient use of water in the mining industry is a crucial challenge, especially in the operation of tailings thickeners, whose solid-liquid separation processes are complex, nonlinear, and multivariable. Conventional control strategies and manual tuning of expert systems often fail to optimize water recovery or robustly stabilize operation. This thesis focuses on the design and development of automatic tuning techniques for MIMO (Multiple-Input, Multiple-Output) fuzzy control strategies applicable to tailings thickeners. The main objective is to stabilize the solids concentration in the discharge, considering critical process variables such as rake torque, flocculant dosage, and maximizing water recovery.

The proposed methodology was developed in stages: first, a MIMO Fuzzy Logic Controller (FLC) was designed, whose inference rules were derived from knowledge of ARMA mathematical models of the process. Then, the Particle Swarm Optimization (PSO) algorithm was applied to automatically tune the FLC's scaling factors, exploring two control philosophies using cost functions differentiated by their weights: minimizing the mean squared error (MSE) and minimizing the overshoots of the controlled variables. Finally, the data generated by the optimized FLCs were used to train Adaptive Neuro-Fuzzy Inference Systems (ANFIS) controllers, seeking further refinement and greater adaptability. All simulations and validations were performed in Matlab, using historical data from an industrial thickener.

The results demonstrated the effectiveness of PSO in tuning the FLCs according to the control objectives. FLCs tuned to minimize error achieved high water recovery, although they exhibited some overshoot in solids. On the other hand, FLCs optimized to minimize overshoots performed excellently in this aspect, for both solids and torque, although water recovery was somewhat lower. Furthermore, it was shown that ANFIS controllers were capable of successfully learning and replicating the behavior of the optimized FLCs. The ANFIS trained for each objective maintained the desired characteristics, achieving good water recovery or low overshoots, respectively. Robustness tests with inverted disturbances indicated a good generalization capability of the ANFIS.

Tabla de contenido

Sumario	iii
Summary	iv
Abreviaciones	viii
Lista de tablas	ix
Lista de figuras	x
1. Introducción	1
1.1. Introducción general	1
1.2. Trabajos previos.....	1
1.3. Planteamiento del problema	2
1.4. Objetivos	2
1.5. Alcances y Limitaciones	2
1.6. Metodología	2
2. Revisión bibliográfica.....	3
2.1. Espesadores.....	3
2.2. Floculante	5
2.3. Lógica difusa	6
2.3.1. Conceptos básicos de lógica difusa	6
2.3.1.1. Conjuntos difusos	6
2.3.1.2. Variables lingüísticas.....	7
2.3.1.3. Sentencia condicional difusa	8
2.3.1.4. Mecanismos de inferencia	9
2.4. Sistemas de control de espesadores	9
2.5. Métodos de sintonización automático aplicable a controladores lógico- difusos.....	17
2.5.1. Arquitectura ANFIS.....	18
2.5.2. Métodos de optimización global para sintonizar controladores lógico- difusos.....	19
2.6. Modelo del espesador	20
3. Justificación de la metodología y herramientas seleccionadas	22
3.1. Estrategia de control MIMO	22

3.1.1.	Entradas y salidas del controlador	22
3.1.2.	Etapas de fusificación.....	23
3.1.3.	Etapas de defusificación:.....	26
3.2.	Sintonización del controlador	27
3.2.1.	Temas de dimensionalidad	27
3.2.2.	Optimización de los factores de escala mediante enjambre de partículas	28
3.2.3.	Diseño de la función de costo para PSO.....	29
3.3.	Desarrollo del controlador Adaptativo Neuro-Difuso (ANFIS).....	31
3.3.1.	Motivación para la implementación de ANFIS	31
3.3.2.	Estrategia de entrenamiento: utilización de los datos generados por el FLC con factores de escala óptimos	31
4.	Resultados.....	33
4.1.	Presentación de los resultados de simulación del FLC.....	33
4.1.1.	Simulación del proceso minimizando el error cuadrático medio (caso 1).....	33
4.1.2.	Simulación del proceso minimizando sobrepasos (caso 2)	36
4.2.	Presentación del entrenamiento, simulación y rendimiento de ANFIS	38
4.2.1.	Simulación del proceso usando ANFIS minimizando el error cuadrático medio (caso 1).....	45
4.2.2.	Simulación del proceso usando ANFIS minimizando los sobrepasos (caso 2)	48
4.3.	Evaluación comparativa.....	50
4.3.1.	Comparación de ANFIS con su FLC óptimo de entrenamiento.....	50
4.3.2.	Comparación de distintos objetivos de control.....	52
4.4.	Robustez y generalización de ANFIS	54
5.	Conclusiones.....	56
5.1.	Resumen del trabajo y alcance de los objetivos	56
5.2.	Síntesis de la metodología y contribuciones.....	56
5.3.	Análisis y discusión de los resultados obtenidos	57
5.4.	Cumplimiento de objetivos.....	59
5.5.	Limitaciones	59
5.6.	Trabajos futuros	59

Referencias.....	61
Anexo.....	64

Abreviaciones

Mayúsculas

ANFIS	: Sistema de Inferencia Neuro-Difuso Adaptativo.
ARMA	: Modelos de Medias Móviles Autorregresivos.
FLC	: Controlador Lógico Difuso.
GA	: Algoritmos Genéticos.
MIMO	: Múltiples Entradas, Múltiples Salidas.
MISO	: Sistema de Varias Entradas y Una Salida (Multiple Inputs Single Output).
MPC	: Control Predictivo Basado en Modelos.
MSE	: Error Cuadrático Medio.
O/F	: Overflow (Flujo Superior).
PI	: Proporcional-Integral.
PSO	: Optimización por Enjambre de Partículas.
PV	: Process Variable (Variable de Proceso).
RMSE	: Raíz del Error Cuadrático Medio.
SP	: Set Point (Punto de Ajuste).
T-S	: Takagi-Sugeno.
U/F	: Underflow (Flujo Inferior).

Minúsculas

kp	: Constante proporcional.
ki	: Constante integral.
ek	: Error en el paso k.
Δe_k	: Cambio en el error en el paso k.
eC	: Error de concentración de sólidos.
deC	: Cambio en el error de concentración de sólidos.
eT	: Error de torque.
deT	: Cambio en el error de torque.

Letras griegas

μ	: Función de pertenencia.
α	: Coeficiente modelo ARMA.
β	: Coeficiente modelo ARMA.

Lista de tablas

Tabla 2.1: Reglas de inferencia.....	12
Tabla 2.2: Reglas de inferencia del U/F	14
Tabla 2.3: Reglas expertas de control.....	15
Tabla 2.4: Variables del proceso.....	20
Tabla 3.1: Reglas del motor de inferencia para válvulas de descarga.....	25
Tabla 3.2: Reglas del motor de inferencia para dosis de floculante.....	25
Tabla 3.3: Detalle de los factores de escala y su influencia.....	30
Tabla 3.4: Pesos y factores de escala óptimos para ambos casos.....	29
Tabla 4.1: Índices de rendimiento de los controladores FLC optimizados con PSO.....	33
Tabla 4.2: Errores de entrenamiento y validación ANFIS.....	42
Tabla 4.3: Índices de rendimiento de los controladores ANFIS entrenados con diferentes datos de FLC experto.....	45
Tabla 4.4: Rendimiento comparativo: FLC vs ANFIS.....	51
Tabla A.1: Detalle de los factores de escala y su influencia.....	64

Lista de figuras

Figura 2.1: Espesador real.....	3
Figura 2.2: Espesador y sus partes.....	4
Figura 2.3: Zonas de un espesador.....	4
Figura 2.4: Espesador continuo ideal.....	5
Figura 2.5: Acción del floculante.....	6
Figura 2.6: Tres funciones de pertenencia en universo de discurso.....	8
Figura 2.7: Diagrama de bloques de un Controlador Lógico Difuso (FLC).....	8
Figura 2.8: PI&D de espesador con instrumentación adicional.....	10
Figura 2.9: Estructura de control PI de J.P. Segovia, F. Concha y D. Sbárbaro.....	11
Figura 2.10: Estructura de control MISO de J.P. Segovia, F. Concha y D. Sbárbaro.....	12
Figura 2.11: Estructura de control Fuzzy de control del espesador.....	13
Figura 2.12: Conjuntos difusos de U/F.....	14
Figura 2.13: Histograma de porcentaje de sólidos.....	16
Figura 2.14: Histograma de torque de la rastra.....	16
Figura 2.15: Histograma de porcentaje de solidos re-sintonizado.....	17
Figura 2.16: Modelo ANFIS.....	18
Figura 2.17: Modelo real y estimado solidos de descarga.....	20
Figura 2.18: Modelo real y estimado torque medio.....	21
Figura 2.19: Modelo real y estimado agua recuperada.....	21
Figura 3.1: Diagrama de bloques de la estrategia de control experto propuesta.....	23
Figura 3.2: Funciones de pertenencia de las variables de entrada.....	24
Figura 3.3: Topología MFLC.....	24
Figura 3.4: Superficie de control para las válvulas de descarga entre error % sólido y error % de torque.....	26
Figura 3.5: Superficie de control para floculante entre el porcentaje de sólidos y la derivada del porcentaje de error de solidos.....	26
Figura 3.6: Mejor valor de la función de costo por iteración minimizando error cuadrático medio.....	31
Figura 3.7: Mejor valor de la función de costo por iteración minimizando sobrepasos.....	31
Figura 3.8: Zoom de la figura 3.7.....	31

Figura 4.1: Gráfico general del proceso con FLC optimizado con PSO minimizando error cuadrático medio.....	34
Figura 4.2 Histograma de error en porcentaje de solidos de descarga (caso 1).....	34
Figura 4.3: Histograma de error del porcentaje de torque de la rastra (caso 1).....	35
Figura 4.4: Histograma de diferencia de acción de control de válvulas de descarga (caso 1).....	35
Figura 4.5: Histograma de diferencia de acción de control de dosis de floculante (caso 1).....	36
Figura. 4.6: Grafico general del proceso con FLC optimizado con PSO minimizando sobrepaso..	36
Figura 4.7: Histograma de distribución de errores de porcentaje de solidos (caso 2).....	37
Figura 4.8: Histograma de distribución de errores de porcentaje de torque (caso 2).....	37
Figura 4.9: Histograma de diferencia de acción de control de válvulas de descarga (caso 2).....	38
Figura 4.10: Histograma de diferencia de acción de control del floculante (caso 2).....	38
Figura 4.11: Estructura del ANFIS para control de válvulas de descarga.....	39
Figura 4.12: Estructura del ANFIS para control de dosis de floculante.....	39
Figura 4.13: Superficie de control del ANFIS para control de válvulas de descarga.....	40
Figura 4.14: Superficie de control del ANFIS para control de dosis de floculante.....	40
Figura 4.15: Curva de aprendizaje ANFIS válvula de descarga caso 1.....	41
Figura 4.16: Curva de aprendizaje ANFIS floculante para caso 1.....	41
Figura 4.17: Curva de aprendizaje ANFIS válvula para caso 2.....	41
Figura 4.18: Curva de aprendizaje ANFIS floculante para caso 2.....	42
Figura 4.19: Válvula: ANFIS vs FLC (datos de validación) minimizando error y error de predicción.....	43
Figura 4.20: Floculante: ANFIS vs FLC (validación) minimizando error y error de predicción....	43
Figura 4.21: Válvula: ANFIS vs FLC (validación) minimizando sobrepaso y error de predicción.....	44
Figura 4.22: Floculante: ANFIS vs FLC (validación) minimizando sobrepaso y error de predicción.....	44
Figura 4.23: Grafico general del proceso con ANFIS entrenado con FLC PSO minimizando error cuadrático medio.....	46
Figura 4.24: Histograma de errores de porcentaje de solidos de descarga ANFIS.....	46
Figura 4.25: Histograma de errores de porcentaje de error del torque ANFIS.....	47
Figura 4.26: Histograma de diferencia de acción de control para válvula ANFIS.....	47

Figura 4.27: Histograma de diferencia de acción de control para dosis de floculante ANFIS.....	48
Figura 4.28: Grafico general del proceso con ANFIS entrenado con FLC optimizado para minimizar sobrepaso.....	48
Figura 4.29: Histograma de error de porcentaje de torque ANFIS.....	49
Figura 4.30: Histograma de errores de porcentaje de torque ANFIS.....	49
Figura 4.31: Histograma de diferencia de acción de control válvula ANFIS.....	50
Figura 4.32: Histograma de diferencia de acción de control de floculante ANFIS.....	50
Figura 4.33: Control de porcentaje de solidos usando ANFIS con distintos objetivos de control.....	52
Figura 4.34: Control de porcentaje de torque usando ANFIS con distintos objetivos de control.....	52
Figura 4.35: Histograma de comparación de distribución de solidos entre ANFIS.....	53
Figura 4.36: Histograma de comparación de distribución de solidos entre ANFIS.....	53
Figura 4.37: Grafico general del proceso con perturbaciones invertidas con ANFIS min. error....	54
Figura 4.38: Grafico general del proceso con perturbaciones invertidas con ANFIS min. sobrepaso.....	55

1. Introducción

1.1. Introducción general

El consumo de agua en procesos de minería es un problema importante por la ubicación geográfica de las plantas [1]. El consumo de agua de la industria minera en Chile en 2016 llegó a los 576.2 Mm³ presentando un aumento del 47% respecto al año 2012 [12]. Esto equivale al consumo de más de 1.4 millones de casas. Estas cifras reflejan la urgencia de implementar estrategias más eficientes para el manejo y reutilización de los recursos hídricos en procesos industriales.

Han aumentado los esfuerzos para recuperar la máxima cantidad de agua en el proceso de separación solido-líquido a través de los espesadores de relaves. El control manual ni las técnicas convencionales de control han sido efectivas estabilizando la operación del proceso. Esto pues las características dinámicas del proceso son altamente no lineales, además de tener parámetros distribuidos.

Esta memoria aborda la problemática del control de espesadores de relaves, enfocándose en el diseño y desarrollo de técnicas de sintonización automática para sistemas de control experto MIMO. Se busca establecer y validar estrategias que consideren variables cruciales del proceso, como el torque de la rastra y la dosificación de floculante, con el fin de estabilizar la concentración de sólidos en la descarga y optimizar la recuperación de agua. Para ello, se explorará la aplicación de controladores lógicos difusos y su posterior refinamiento mediante Sistemas de Inferencia Neuro-Difusos Adaptativos, utilizando algoritmos de optimización global como la optimización por enjambre de partículas para la sintonización de parámetros clave.

1.2. Trabajos previos

En la literatura se encuentran diversas estrategias de control para espesadores de relave. Se tiene por ejemplo el uso de estructura de control usando controlador PI con “selector de mayor” para el control de nivel de interfaz y concentración de flujo inferior al mismo tiempo [1]. Además, se mostró en [4] que los set-points óptimos de un controlador PI para el caudal de flujo inferior pueden ser calculados haciendo uso de un modelo dinámico de balance de masas.

Segovia, Concha y Sbárbaro [2] realizaron una comparación entre distintas estrategias de control sobre un modelo fenomenológico calibrado a los parámetros de un espesador industrial. Las simulaciones arrojaron que el error medio cuadrado fue menor con la estrategia de control experto.

En [3] se ha presentado la combinación de controladores Fuzzy y PI aplicados a una planta real de concentración de hematita mostrando la efectividad del método propuesto, teniendo como resultado que las fluctuaciones del set-point estén dentro de los rangos deseados.

Reciente investigación [9] han diseñado un control predictivo por modelo y desarrollan un modelo lineal dinámico del espesador con datos históricos. Con resultados exitosos en de control en la simulación de las variables a controlar.

1.3. Planteamiento del problema

Es posible mejorar el control de espesadores mediante la simulación con nuevos y robustos modelos dinámicos del proceso de sedimentación – consolidación. Los estudios existentes no toman en consideración restricciones del proceso como el torque o velocidad de la rastra o el efecto de floculantes en el proceso. Por lo que se verá el efecto de esta particularidad del proceso del espesador al momento de desarrollar nuevas estrategias de control. Además, la sintonización manual de los sistemas expertos lleva tiempo y es complicado.

1.4. Objetivos

Diseñar y desarrollar técnicas de sintonización automáticas para un sistema de control experto MIMO, aplicable a espesadores de relaves, considerando torque de rastra, floculante, flujo de alimentación, estabilizando la concentración de descarga y volumen de agua recuperada

1.5. Alcances y Limitaciones

- El control y sintonización se desarrollará considerando datos históricos de un espesador.
- Las técnicas de sintonización se implementarán en Matlab.
- Las pruebas dinámicas se realizarán en Matlab.

1.6. Metodología

Se estudia del proceso de espesamiento basándose en la literatura disponible. A partir del modelo matemático del espesador se realiza un análisis para ver el comportamiento de las variables como la concentración y flujos para obtener las reglas del motor de inferencia. Al analizar los resultados se propone, integra y prueba un sistema de control experto. Se define una función de costo para optimizar el sistema de control experto mediante enjambre de partículas. Finalmente se usan los datos generados por el sistema experto optimizado para entrenar un ANFIS, luego se simula el proceso usando el nuevo controlador ANFIS, probando también su robustez ante cambios de perturbaciones. Todo esto mediante simulación en Matlab.

2. Revisión bibliográfica

2.1. Espesadores

La minería utiliza diferentes procesos para la explotación de minerales, algunos de estos procesos involucran la separación sólido-líquido usando equipos de proceso continuo [15]. Esto es, se busca lograr la separación de una suspensión de pequeñas partículas suspendidas en un líquido viscoso en sus componentes sólido y líquido bajo la acción de la fuerza de gravedad [16]. Este proceso se lleva a cabo en un equipo mecánico llamado espesador. La figura siguiente muestra una fotografía de un espesador real:



Fig. 2.1 Espesador real [obtenido de <https://www.flickr.com/photos/codelco/9729363013/in/photostream/> (Acceso 10 de mayo del 2024)]

Estos equipos son tanques cilíndricos de área seccional variable, y sus elementos se ven en la siguiente figura:




Fig. 2.2 Espesador y sus partes [16]

Un espesador se divide en tres zonas según [16]:

- Zona I de Clarificación: esta se ubica en la parte superior del tanque donde se encuentra las aguas claras libres de sólidos de concentración cercana a cero.
- Zona II de Sedimentación: posee concentraciones que varían entre cero y concentración crítica, siendo la concentración crítica cuando cierta altura de la interfaz agua-suspensión se encontrará con la interfaz suspensión-sedimento.
- Zona III de compresión: esta se ubica en el fondo del tanque. Aquí se encuentran suspensiones superiores a la crítica. Además, aquí ocurre el desaguado por compresión

Las zonas de forma visual se representan de la siguiente forma:




Fig. 2.3 Zonas de un Espesador [16]

Sobre el comportamiento y modelos fenomenológicos del proceso en [13] publicaron para una dimensión espacial una ecuación diferencial parcial hiperbólica de primer orden para la decantación y una ecuación diferencial parcial parabólica de segundo orden para la consolidación del sedimento.

Y en [14] se simula en comportamiento transiente de suspensiones floculadas en un espesador ideal con la solución numérica de la ecuación parabólica-hiperbólica de la teoría fenomenológica de sedimentación.




Fig. 2.4 Espesador continuo ideal [13]

2.2. Floculante

En la dinámica que permite la separación de sólidos y líquidos mediante el proceso de sedimentación, intervienen dos tipos de fuerzas: la gravedad y el empuje. La gravedad hace que las partículas sólidas se desplacen hacia el fondo del estanque, mientras que el empuje es una fuerza en sentido opuesto ejercida por el fluido sobre un objeto sumergido [17].

Para que la partícula sedimente hacia el fondo del espesador, la gravedad específica de tal partícula debe ser tal para que la fuerza de gravedad supere a la de empuje. Para esto los espesadores incorporan el concepto de floculación, asociado a la adición de este compuesto químico para favorecer la sedimentación de las partículas, en especial de las más finas [18].

Según [19] el espesador es un dispositivo dinámico que debe operar en estado estacionario. Además, la correcta floculación es el factor más importante en la operación de un espesador. El diagrama siguiente muestra una molécula de floculo de cadena larga cargado negativamente combinándose con una partícula cargada positivamente para aglomerar y formar un coloide más pesado que sedimente más rápido.




Fig. 2.5 Acción de floculante [19]

2.3. Lógica difusa

En 1965 Lofti Zadeh, logra manipular de forma eficiente la imprecisión y la ambigüedad del razonamiento humano en términos lingüísticos a través de su lógica difusa. Esto es de utilidad para el caso del control de espesadores, ya que un sistema experto se basa en la experiencia que se ha acumulado un especialista en algún área, donde el experto tiene habilidades y/o conocimientos para identificar problemas y controlar los procesos de manera rápida y eficiente.

Estos sistemas expertos presentan ventajas ante la operación manual de los procesos. Se tiene por ejemplo la confiabilidad en la toma de decisiones, pues no presentan cansancio como un humano que afecte sus decisiones, se tiene también que el desarrollo de un sistema experto considera el conocimiento de más de un especialista. También según [10] cree que ninguna otra filosofía de control puede proveer resultados tan inmediatos como un sistema basado en lógica difusa.

2.3.1. Conceptos básicos de lógica difusa

2.3.1.1. Conjuntos difusos

Para representar el conocimiento lingüístico en un lenguaje matemático se usa la teoría de conjuntos difusos. Así se puede asignar valores “difusos” a cuantificadores lingüísticos que se usan comúnmente como “mucho” o “poco”. Por ejemplo, el término "alto" en el contexto de la temperatura puede estar representado por una función de membresía que asigna valores más altos a temperaturas que se consideran "altas" con diferentes grados de pertenencia.

Un conjunto difuso puede ser definido como un conjunto F en un universo de discurso U está caracterizado por una función de pertenencia μ_F que toma valores en el intervalo $[0,1]$

$$\mu_F: U \rightarrow [0,1]$$

Así un conjunto difuso F en un universo de discurso U se representa como un par ordenado de sus elementos u y su grado de pertenencia $\mu_F(u)$ de la siguiente manera:

$$F = \{(u, \mu_F(u)) / u \in U\}$$

Cuando el universo de discurso de U es discreto su representación es como se muestra a continuación:

$$F = \sum_{i=1}^n \frac{\mu_F(u_i)}{u_i}$$

Operaciones sobre conjuntos difusos

Existen varias operaciones definidas sobre los conjuntos difusos, aquí se definen las dos más usadas. Sean A y B dos conjuntos difusos en U con funciones de pertenencia μ_A y μ_B respectivamente.

1. Unión: La unión de dos conjuntos difusos se denota por $A \cup B$ y su función de pertenencia $\mu_{A \cup B}$ se define según Chuen Chien Lee como:

$$\mu_{A \cup B} = \max\{\mu_A(u), \mu_B(u)\} \forall u \in U$$

El operador conectivo “or” se puede interpretar como unión.

2. Intersección: La intersección de dos conjuntos difusos se denota por $A \cap B$ y su función de pertenencia $\mu_{A \cap B}$ se define según Chuen Chien Lee como:

$$\mu_{A \cap B} = \min\{\mu_A(u), \mu_B(u)\} \forall u \in U$$

El operador conectivo *and* se puede interpretar como intersección.

2.3.1.2. Variables lingüísticas

Las variables lingüísticas son un componente fundamental en la lógica difusa, utilizadas para manejar información que es imprecisa o vaga. A diferencia de las variables numéricas, las variables lingüísticas se expresan en términos de palabras o frases en lugar de números exactos. Por ejemplo, en un sistema de control de temperatura, la variable lingüística "x=Temperatura" puede tomar conjunto de términos $T(x) = \{Frío, Tibio, Caliente\}$.




Fig. 2.6 Tres funciones de pertenencia en universo de discurso [21]

2.3.1.3. Sentencia condicional difusa

Las reglas difusas son el conjunto de proposiciones IF-THEN que describen el problema a resolver. El bloque de inferencia es donde se realiza la traducción matemática de las reglas heurísticas basadas en el conocimiento experto. La forma de estas reglas heurísticas es:

IF (un conjunto de condiciones son satisfechas) THEN (un conjunto de consecuencias puede ser inferido)

A continuación, se muestra la estructura básica de un controlador lógico difuso, el cual consta de cuatro bloques esenciales.




Fig. 2.7 Diagrama de bloques de un Controlador Lógico Difuso (FLC) [21]

- **Interfase fusificadora:** Aquí se mide el valor de las variables de entrada, se escalan dentro el universo de discurso y se desarrolla la función fusificadora para convertir el dato de entrada en una variable lingüística.
- **Base de conocimiento:** Consiste en una base de datos y una base de reglas de control difusas. La base de datos provee las definiciones necesarias para definir las reglas de control lingüístico y la base de reglas caracteriza el objetivo del control y el curso del control a través de un conjunto de reglas de control lingüísticas.
- **Lógica de toma de decisión:** este es el núcleo del FLC y simula el comportamiento de toma de decisión de un experto basándose en conceptos difusos. Y más importante permite inferir acciones de control utilizando implicaciones difusas.
- **Interfase defusificadora:** Aquí se convierten las variables difusas en un escalar y se escalan las variables de salida dentro del universo de discurso.

2.3.1.4. Mecanismos de inferencia

Existen principalmente dos tipos de sistemas de inferencia difusa:

Mamdani: Tanto los antecedentes como los consecuentes de las reglas son conjuntos difusos. La salida de cada regla es un conjunto difuso, y estos se agregan para formar un conjunto difuso de salida global, que luego se defusifica.

Takagi-Sugeno (T-S): Los antecedentes son conjuntos difusos, pero los consecuentes son funciones de las variables de entrada. Los modelos T-S son ampliamente utilizados debido a su capacidad para manejar sistemas altamente no lineales con gran exactitud y una comprensión relativamente sencilla.

2.4. Sistemas de control de espesadores

Según Gupta y Yan [6] el control de la operación del espesador se busca obtener un flujo superior claro tan rápido como sea posible. La tasa de sedimentación suele ser acelerada con la adición de floculantes. La adición de floculante varía dependiendo de los minerales presentes en la suspensión, su composición y características de superficie. Además, es necesario mantener baja turbulencia en el punto de entrada del tanque, para esto, el nivel de flujo superior se mantiene suficientemente alto sobre el nivel de alimentación para asegurar una concentración de sólidos aceptable en el flujo superior.




Fig. 2.8 P&ID de espesador con instrumentación adicional [11]

En [6] se dan pautas sobre estrategias de control. El control de contenidos sólidos en el flujo superior e inferior son las bases del control del espesador. La densidad promedio de la cama (inventario de sólidos) debe ser controlada por el caudal de flujo inferior y la adición de floculante a la suspensión. Con esto resume el esquema de control como sigue:

Nivel 1: el lazo principal (#1) es para control de flujo inferior. El segundo lazo principal (#2) es para el control de flujo floculante. Para cada lazo menciona las mediciones esenciales para el proceso.

Nivel 2: La intención del nivel 2 es mantener un nivel de cama de flujo inferior cercano al set-point. Para esto el set-point del nivel de cama es controlado por el controlador de nivel de cama. Sin embargo, en la práctica se encuentra que el nivel de cama puede ser perturbado por alta densidad de la cama, lo que podría resultar en altos torques en la rastra.

Nivel 3: involucra la optimización de la operación del espesador.

En [6] se habla sobre sistemas expertos. Mencionando que, en las operaciones de procesamiento de mineral, los operadores generalmente usan su sentido común para controlar los procesos a través

de conocimientos y habilidades adquiridas. Y que, si bien el conocimiento es propiedad intelectual obtenida por la experiencia, esta puede ser cuantificada. Con este sistema lingüístico desarrollado por experiencia se puede traspasar a lenguajes de programación.

Se propuso un controlador PI en [2]. A continuación, se muestra una figura con la estructura de control.




Fig. 2.9 Estructura de control PI de J. P. Segovia, F. Concha y D. Sbárbaro [2]

En este estudio [2] las condiciones operacionales óptimas fueron determinadas con el rendimiento en estado estacionario y con el sistema de control automático utilizado para estabilizar la operación. También se habla sobre las variables medibles en la práctica, está siendo: densidad de flujo de sólidos de alimentación, concentración de flujo inferior, nivel de sedimento, presión de la cama, torque de la rastra, turbidez del flujo superior y corriente de la bomba de flujo inferior.

En el mismo artículo implementan una estrategia basada en controladores PI, regida por la siguiente ecuación:

$$u(k+1) = u_w(k) + k_p \Delta e(k) + k_i e(k)$$

donde $e(k) = y_{sp}(k) - y(k)$, $\Delta e(k) = e(k) - e(k-1)$ y k_p, k_i son las constantes de la parte proporcional e integral respectivamente. Además de esto, se implementó una estrategia de anti-windup.

En [2] se implementó un controlador Fuzzy PI definido como

$$u(k+1) = u(k) + F(k_e e(k), k_\Delta \Delta e(k))$$

Donde F es una función no lineal dependiendo de las reglas de inferencia. Esta estrategia también necesita un anti-windup.

Un ejemplo de las reglas de inferencia para usadas controlar en [2] son las siguientes:

TABLA 2.1 Reglas de inferencia [2]

		$\Delta e(k)$					
		NH	NM	Z	PM	PH	
$e(k)$	NH	NH	NH	NH	NM	Z	
	NM	NH	NM	NM	Z	PM	
	Z	NH	NM	Z	PM	PH	
	PM	NM	Z	PM	PM	PH	
	PH	Z	PM	PH	PA	PH	

Se desarrolló en [2] un controlador Fuzzy MISO que considera 60 reglas. La estructura se ve en la figura siguiente




Fig. 2.10 Estructura de control MISO de J. P. Segovia, F. Concha y D. Sbárbaro [2]

Las reglas del controlador siguen una lógica como la siguiente: “IF Underflow concentration is above target and Bed level in below target and Bed level is Rising then increase Underflow flowrate”

Con este ejemplo se puede notar que se usó el error en “above target” y la derivada del error en “is Rising” para crear las reglas.

Este esquema de control fue el que rindió de mejor manera frente a estrategias PI con selector. Sin embargo, este estudio no se consideró el efecto de floculantes para simplificar el análisis. Y si bien en [5] se menciona que en Chile se ha propuesto a operar los espesadores usando un sistema experto los cuales tienen un rendimiento mejor a la operación manual, los sistemas expertos dependen en reglas y conocimiento de expertos que pueden estar incompletos o desactualizados. También que estos sistemas son diseñados para aplicaciones específicas y no son fácilmente adaptables a

condiciones cambiantes, resultando en dificultades al lidiar con incertidumbre y variaciones en el proceso [7].

Se tienen antecedentes de la implementación de un sistema experto en una planta real en [10] donde sus autores hablan sobre el tiempo que les tomó. Entre el conocimiento del ingeniero y un operador experimentado les tomó 8 horas crear las reglas del motor de inferencia y la sintonización les tomó otro día de trabajo. Donde se establecieron dos lazos de control: uno para el control de la densidad de flujo inferior variando el caudal de la pulpa del flujo inferior y el segundo para regular la turbidez del flujo superior ajustando la adicción de floculante. Y las reglas son derivadas de conocimiento de un operador experimentado de la planta.




Fig. 2.11 Estructura de control Fuzzy de control del espesador [10]

En el artículo [10] se habla sobre Fuzzy Associative Map y se deduce que hablan sobre el motor de inferencia. Se observa que se toman en consideración 7 variables para poder controlar estas dos salidas.

Muestran una tabla de las reglas del controlador, y de igual forma se toma el error y la derivada del error para formarlas.

TABLA 2.2 Reglas de inferencia del U/F [10]

U/F ERROR DENSIDA D	CAMBIO DE DENSIDAD U/F				
	NB	NS	ZE	PS	PB
NB	PB	PB	PB	PB	PS
NS	PB	PS	PS	PS	PVS
NVS	PS	PVS	PVS	PVS	ZE
ZE	ZE	ZE	ZE	ZE	ZE
PVS	ZE	NVS	NVS	NVS	NS
PS	NVS	NS	NS	NS	NB
PB	NS	NB	NB	NB	NB

Ejemplos de reglas en esta implementación vienen siendo “If recommended U/F flowrate is too high, then set U/F flowrate at maximum” o “if O/F turbidity is high and current flocculant addition is máximo and U/F flowrate is not high then U/F setpoint must be reduced”

Los conjuntos fuzzy de U/F se muestran a continuación:




Fig. 2.12 Conjuntos difusos de U/F [10]

De estas reglas se infiere que la turbidez de O/F tiene relación positiva con la adición de floculante y una relación positiva con caudal de U/F, es decir, al disminuir el U/F, la turbidez del O/F también debería disminuir.

En [4] se muestra un sistema de control inteligente para controlador PI, donde las constantes de sintonización varían dependiendo de reglas las cuales dependen de los estados medidos del espesador. También se consideran muchas medidas de seguridad y control para la rastra como: cuando el torque llega a un estado de estabilidad, se requieren cambios en la operación para aliviar el torque. Si el torque continúa aumentando sobre un límite, el motor se apagará para proteger el mecanismo. Por lo que acciones correctivas como aumentar el caudal de flujo inferior deberían ser tomadas en antemano para prevenir una sobrecarga.

En esta estrategia, el sistema experto entrega set-points de caudal de flujo inferior y dosis de floculante a los controladores ya existentes, intentando optimizar la operación.

Las reglas expertas del control del espesador se muestran a continuación:

TABLA 2.3 Reglas Expertas de control [4]

ϕ_U	L_{Bed}	DR_{FlocSP}	Q_{USP}
On target	Above target	DR_{Floc}	$Q_{USP}^* + K * \Delta V_U$
On target	On target	DR_{Floc}	Q_{USP}^*
On target	Below target	DR_{Floc}	$Q_{USP}^* + K * \Delta V_U$
Above target	Above target	DR_{Floc}	$Q_{USP}^* + 1.1 K * \Delta V_U$
Above target	On target	$0.9 * DR_{Floc}$	$Q_{USP}^* + K * \Delta V_U$
Above target	Below target	$0.8 * DR_{Floc}$	$Q_{USP}^* + K * \Delta V_U$
Below target	Above target	$1.2 * DR_{Floc}$	$Q_{USP}^* + K * \Delta V_U$
Below target	On target	$1.1 * DR_{Floc}$	$Q_{USP}^* + K * \Delta V_U$
Below target	Below target	DR_{Floc}	$Q_{USP}^* + 0.9 K * \Delta V_U$

Donde $Q_{USP}(t)$ es el set point de caudal de flujo inferior, que es calculado de la siguiente forma:

$$Q_{USP}(t) = Q_{USP}^*(t) + \frac{m(t) - m_0}{\Delta t} * \frac{1}{C_U(t)\phi_U(t)}$$

Se debe tener en consideración también que según [20] con set-point fijo en el porcentaje de solidos de descarga causa una frecuente fluctuación en el caudal de flujo de salida, provocando perturbaciones en los procesos siguientes. Por lo que permitir que el porcentaje de solidos de la salida cambie dentro de un rango, reduce la variación en la variable manipulada, con ello disminuye la perturbación en los procesos siguientes.

En [3] se generaron valores de referencia de la tasa de flujo usando un modelo estático en un esquema de control en cascada para estabilizar la densidad de sedimento del flujo inferior y la tasa de flujo. Y en [8] se propuso el uso de un modelo dinámico, pero este método se satura sobre un angosto rango de operación de densidad de sedimento y tasa de flujo y además no considera restricciones del proceso como turbidez del flujo superior, nivel de cama ni torque de la rastra.

En [12] presenta un sistema experto para un espesador industrial donde se reduce el consumo de floculante y operación más estable, considerando además el torque de la rastra como condición de emergencia. Se compara el sistema experto con el sistema de control antiguo. Donde se puede ver que el promedio de porcentaje de sólidos en el flujo inferior incrementa a la vez que la varianza disminuya mientras el sistema experto funcionaba como se ve en la figura 2.15. Esto representa un incremento de al menos un 10% de aumento en el agua recuperada. El torque de la rastra aumentó generando un mayor tiempo de residencia de sólidos como se ve en la figura 2.16.




Fig. 2.13 Histograma de porcentaje de sólidos (Sistema experto en negro, control antiguo en blanco) [12]




Fig. 2.14 Histograma de torque de la rastra (Sistema experto en negro, control antiguo en blanco) [12]

Luego en [12] se volvió a sintonizar el sistema experto, pues las condiciones impuestas del torque eran muy restrictivas y por consiguiente la distribución del porcentaje de solidos era muy amplia.




Fig. 2.15 Histograma de porcentaje de sólidos re-sintonizado (Sistema experto en negro, control antiguo en blanco) [12].

Para concluir de esta sección se puede decir que los FLC ofrecen un marco intuitivo para el diseño de controladores, su rendimiento óptimo depende crucialmente de la correcta definición de sus componentes: las funciones de pertenencia, la base de reglas y los factores de escala. La sintonización manual de estos elementos es un proceso iterativo, que consume mucho tiempo y depende en gran medida de la experiencia y el conocimiento del diseñador experto [25]. Un FLC sintonizado manualmente puede exhibir un rendimiento óptimo solo dentro de un rango limitado de condiciones de operación o para un conjunto específico de entradas [24].

La sintonización automática surge como una necesidad para superar estas limitaciones. Su objetivo es optimizar el rendimiento del FLC de manera sistemática y, preferiblemente, autónoma, adaptándolo a las características dinámicas específicas del proceso a controlar y a los objetivos de rendimiento deseados [25]. Estos objetivos suelen incluir la minimización del error de seguimiento, la reducción del sobrepaso, el aumento de la robustez frente a perturbaciones e incertidumbres, y la optimización del esfuerzo de control.

2.5. Métodos de sintonización automático aplicable a controladores lógico-difusos

Este capítulo profundiza en las estrategias avanzadas para la sintonización automática de controladores lógico-difusos, yendo más allá de los enfoques manuales tradicionales. Se explorarán métodos que aprovechan el aprendizaje de datos y técnicas de optimización global.

2.5.1. Arquitectura ANFIS

ANFIS es funcionalmente equivalente a un sistema de inferencia difuso del tipo Takagi-Sugeno (T-S) [26]. Su arquitectura se estructura típicamente en cinco capas, cada una desempeñando una función específica en el proceso de inferencia difusa y aprendizaje [26]:

- Capa 1 (Capa de fusificación): Cada nodo en esta capa corresponde a una variable de entrada y genera los grados de pertenencia de la entrada a los conjuntos difusos asociados. Los parámetros de esta capa son adaptativos y se conocen como parámetros de premisa.
- Capa 2 (Capa de reglas): Cada nodo calcula la fuerza de disparo (o grado de activación) de una regla difusa, usualmente mediante una operación T-norma sobre los grados de pertenencia de la capa anterior.
- Capa 3 (Capa de normalización): Los nodos normalizan las fuerzas de disparo de las reglas, calculando la contribución relativa de cada regla a la salida total.
- Capa 4 (Capa de defusificación): Cada nodo calcula la salida de la regla multiplicando la fuerza de disparo normalizada por una función lineal de las entradas. Los parámetros de estas funciones lineales son adaptativos y se conocen como parámetros de consecuente.
- Capa 5 (Capa de salida total): Un único nodo calcula la salida global del sistema como la suma de las salidas de todas las reglas de la capa anterior.




Fig. 2.16 Modelo ANFIS [30]

Las ventajas de usar ANFIS incluyen su capacidad de aprendizaje a partir de datos, su habilidad para modelar sistemas no lineales complejos y su estructura interpretable [28]. Sin embargo, ANFIS no está exento de limitaciones, pues el número de reglas crece exponencialmente con el número de entradas si se usa una partición en rejilla y la dependencia de la calidad y cantidad de los datos de entrenamiento [23]. A pesar de esto, se ha demostrado que ANFIS puede superar a los FLC convencionales en términos de adaptabilidad y robustez, especialmente en sistemas dinámicos con perturbaciones significativas [27].

2.5.2. Métodos de optimización global para sintonizar controladores lógico-difusos

La sintonización de los parámetros de un FLC puede formularse como un problema de optimización. El objetivo es encontrar el conjunto de parámetros que minimice una función de costo predefinida o maximice un índice de rendimiento [25].

Los FLC, a pesar de su base heurística, poseen numerosos parámetros que deben ser ajustados para lograr un rendimiento óptimo. La interdependencia de estos parámetros y la naturaleza a menudo no lineal de la relación entre los parámetros y el rendimiento del controlador hacen que la función de costo sea compleja. Los algoritmos de optimización global están diseñados para explorar exhaustivamente este espacio de búsqueda y aumentar la probabilidad de encontrar la solución óptima global o una solución cercana a ella.

La elección del método de optimización global más adecuado para sintonizar un FLC depende de múltiples factores, incluyendo las características específicas del FLC, la naturaleza del problema de control (dimensionalidad del espacio de búsqueda, multimodalidad de la función de costo, disponibilidad de información del gradiente), y las restricciones prácticas (costo de evaluación de la función de costo, tiempo de cómputo disponible).

En la literatura ofrecen algunas pautas para la elección del método. Por ejemplo, se ha observado que PSO a menudo converge más rápidamente que GA en ciertos problemas, pero también puede ser más propenso a quedar atrapado en óptimos locales [29]. Los GA, por otro lado, pueden ser más robustos para explorar espacios de búsqueda muy amplios y son inherentemente buenos para problemas de optimización combinatoria como la selección de reglas.

Si bien PSO ha demostrado ser efectivo en la sintonización de los factores de escala para el controlador difuso en esta investigación, es importante reconocer, como señala la literatura reciente [31], que la técnica presenta desafíos. Entre ellos se incluyen la sensibilidad a la configuración de sus parámetros (como el tamaño del enjambre, los coeficientes cognitivo y social, y los criterios de paro)

y la posibilidad de estancamiento en óptimos locales, especialmente en espacios de búsqueda complejos.

2.6. Modelo del espesador

El modelo se obtuvo de [22], en este se explica y desarrolla la identificación de las variables relevantes del proceso mediante mínimos cuadrados para establecer un modelo tipo ARMA. Se identifican y validan los modelos a controlar, estos son: solidos de descarga, torque medio y agua recuperada. Con esto se obtuvieron los siguientes resultados, considerando las siguientes variables:

TABLA 2.4 Variables del proceso [22]

Variable	Descripción
$S_d(k)$	Sólido de descarga en el tiempo k-ésimo.
$zv(k)$	Sumatoria de apertura de válvulas en el tiempo k-esimo.
$q_f(k)$	Flujo de alimentación en el tiempo k-ésimo.
$f_l(k)$	Floculante en el tiempo k-ésimo.
$T(k)$	Torque de la rastra en el tiempo k-ésimo.
$m_{es}(k)$	Masa estimada en el tiempo k-ésimo.
$Q_w(k)$	Agua recuperada en el tiempo k-ésimo.

Solidos de descarga:

$$S_d(k) = \alpha_1 S_d(k-1) + \beta_1 zv(k-1) + \beta_2 q_f(k-11) + \beta_3(k-2)$$




Fig. 2.17 Modelo real y estimado solidos de descarga (real azul, estimado rojo) [22].

Los resultados del modelo presentan errores menores al 6% y cuyo error cuadrático es de 0.5637.

Torque medio:

$$T(k) = \alpha_1 T(k-1) + \beta_1 zv(k-1) + \beta_2 m_{es}(k-1) + \beta_3 f_l(k-1) + \beta_4 S_d(k-1)$$




Fig. 2.18 Modelo real y estimado torque medio (real azul, estimado rojo) [22].

Los errores por muestra presentan un error menor al 10% y el error cuadrático medio fue de 1.3734.

Agua recuperada: $Q_w(k) = \alpha_1 Q_w(k-1) + \beta_1 zv(k-1) + \beta_2 f_l(k-1) + \beta_3 q_f(k-1)$




Fig. 2.19 Modelo real y estimado agua recuperada (real azul, estimado rojo) [22]

En este caso el error es menor al 15% y el error cuadrático medio es de 75.6694.

3. Justificación de la metodología y herramientas seleccionadas

En estudios y aplicaciones industriales, se ha demostrado que el uso de controladores de lógica difusa en espesadores de relave mejora significativamente el rendimiento del proceso. Sin embargo, la sintonización de un FLC puede ser compleja y es crucial para asegurar su eficacia en aplicaciones prácticas. En el caso de un espesador de relaves, donde la variabilidad y complejidad de las condiciones operativas pueden ser significativas, es importante contar con un sistema de control bien sintonizado para mantener la eficiencia y estabilidad del proceso.

El presente capítulo tiene como objetivo proporcionar justificaciones de las decisiones metodológicas, así como para las herramientas seleccionadas para el diseño y desarrollo de la estrategia de control propuesta en esta memoria.

La propuesta consiste en:

1. Diseñar un FLC MIMO.
2. Crear las reglas del controlador a partir de los modelos matemáticos del proceso.
3. Encontrar factores de escala óptimos con el método de optimización global enjambre de partículas.
4. Modificar los pesos de la función de costo para lograr distintos objetivos (como minimizar error cuadrático medio, minimizar sobrepasos).
5. Usar los factores de escala óptimos en el FLC para entrenar un controlador ANFIS.
6. Probar el controlador ANFIS con distintas perturbaciones a las originales para calcular su rendimiento. (para la última comprobación del rendimiento del controlador puedo usar los mismos datos de qf, pero ordenando lo al revés, así tengo rangos de datos reales y cambios también reales.)

3.1. Estrategia de control MIMO

El controlador experto MIMO a sintonizar se conforma de la siguiente forma:

3.1.1. Entradas y salidas del controlador

- Entradas:
 1. Error del porcentaje de sólidos en el flujo de descarga.
 2. Derivada del error del porcentaje de sólidos en el flujo de descarga.
 3. Error del porcentaje de torque de la rastra.
 4. Derivada del error del porcentaje de torque de la rastra.

- Salidas:
 1. Set point de dosis de floculante.
 2. Porcentaje de apertura en las válvulas de descarga.




Fig. 3.1. diagrama de bloques de la estrategia de control experto propuesta

3.1.2. Etapa de fusificación

Para la etapa fusificadora del controlador difuso se usa el error (e_k) y la derivada del error (de_k) para ambas entradas.

$$e_k = swa(SP - PV)/S_e$$

$$de_k = [e_k - e_{k-1}]/S_{de}$$

S_e y S_{de} son parámetros de escalamiento de error y derivada del error que servirán luego para el escalamiento del error. Se agrega el switch de acción que puede tomar los valores 1 o -1.

Se definieron dos conjuntos difusos en los universos de discurso en las entradas

$$U_{in} = \{N, P\}$$

Para las salidas se usan tres conjuntos difusos

$$U_{out} = \{N, Z, P\}$$

El grado de pertenencia de las variables en los distintos conjuntos difusos es calculado mediante las funciones de pertenencia. En la figura 3.2, se muestran las funciones de pertenencia usadas para el error y derivada del error del porcentaje de solidos de descarga y porcentaje de torque en la rastra. El grado de pertenencia se denota con la letra griega μ .




Fig. 3.2 Funciones de pertenencia de las variables de entrada

La estrategia de control implementada se basa en la topología presentada en la Figura 4.2. Se seleccionó esta configuración porque asegura que cada salida del sistema sea influenciada por todas sus entradas. Adicionalmente, esta elección topológica es relevante para la gestión de la dimensionalidad, ya que, como se indica en [21], la estructura del controlador impacta directamente en la cantidad de reglas requeridas.




Fig. 3.3. Topología MFLC [21]

Las reglas formuladas para el motor de inferencia a partir de los modelos del proceso quedaron se muestran en la tabla 4.1 para el porcentaje de sólidos y en la tabla 4.2 para el control el porcentaje de torque en la rastra.

Tabla 3.1 Reglas del motor de inferencia para válvulas de descarga

	Rule	Weight	Name
1	If e%solido is N and de%solido is N and e%torque is N and de%torque is N then %PosVal is P	1	rule1
2	If e%solido is P and de%solido is N and e%torque is N and de%torque is N then %PosVal is P	1	rule2
3	If e%solido is N and de%solido is P and e%torque is N and de%torque is N then %PosVal is P	1	rule3
4	If e%solido is P and de%solido is P and e%torque is N and de%torque is N then %PosVal is P	1	rule4
5	If e%solido is N and de%solido is N and e%torque is P and de%torque is N then %PosVal is Z	1	rule5
6	If e%solido is P and de%solido is N and e%torque is P and de%torque is N then %PosVal is Z	1	rule6
7	If e%solido is N and de%solido is P and e%torque is P and de%torque is N then %PosVal is Z	1	rule7
8	If e%solido is P and de%solido is P and e%torque is P and de%torque is N then %PosVal is Z	1	rule8
9	If e%solido is N and de%solido is N and e%torque is N and de%torque is P then %PosVal is P	1	rule9
10	If e%solido is P and de%solido is N and e%torque is N and de%torque is P then %PosVal is P	1	rule10
11	If e%solido is N and de%solido is P and e%torque is N and de%torque is P then %PosVal is P	1	rule11
12	If e%solido is P and de%solido is P and e%torque is N and de%torque is P then %PosVal is P	1	rule12
13	If e%solido is N and de%solido is N and e%torque is P and de%torque is P then %PosVal is N	1	rule13
14	If e%solido is P and de%solido is N and e%torque is P and de%torque is P then %PosVal is N	1	rule14
15	If e%solido is N and de%solido is P and e%torque is P and de%torque is P then %PosVal is N	1	rule15
16	If e%solido is P and de%solido is P and e%torque is P and de%torque is P then %PosVal is N	1	rule16

Tabla 3.2 Reglas del motor de inferencia para dosis de floculante

	Rule	Weight	Name
1	If e%solido is N and de%solido is N and e%torque is N and de%torque is N then duk is N	1	rule1
2	If e%solido is P and de%solido is N and e%torque is N and de%torque is N then duk is Z	1	rule2
3	If e%solido is N and de%solido is P and e%torque is N and de%torque is N then duk is N	1	rule3
4	If e%solido is P and de%solido is P and e%torque is N and de%torque is N then duk is P	1	rule4
5	If e%solido is N and de%solido is N and e%torque is P and de%torque is N then duk is N	1	rule5
6	If e%solido is P and de%solido is N and e%torque is P and de%torque is N then duk is Z	1	rule6
7	If e%solido is N and de%solido is P and e%torque is P and de%torque is N then duk is N	1	rule7
8	If e%solido is P and de%solido is P and e%torque is P and de%torque is N then duk is P	1	rule8
9	If e%solido is N and de%solido is N and e%torque is N and de%torque is P then duk is N	1	rule9
10	If e%solido is P and de%solido is N and e%torque is N and de%torque is P then duk is Z	1	rule10
11	If e%solido is N and de%solido is P and e%torque is N and de%torque is P then duk is N	1	rule11
12	If e%solido is P and de%solido is P and e%torque is N and de%torque is P then duk is P	1	rule12
13	If e%solido is N and de%solido is N and e%torque is P and de%torque is P then duk is N	1	rule13
14	If e%solido is P and de%solido is N and e%torque is P and de%torque is P then duk is Z	1	rule14
15	If e%solido is N and de%solido is P and e%torque is P and de%torque is P then duk is N	1	rule15
16	If e%solido is P and de%solido is P and e%torque is P and de%torque is P then duk is P	1	rule16

Con estos conjuntos de reglas se obtienen las siguientes superficies de control, como se muestran en las figuras 4.3 y 4.4.

En este caso la optimización PSO no modifica la superficie de control de los controladores, sino mas bien va modificando la amplitud de la superficie. Entonces se puede obtener una superficie de control mas “plana” u otra mas “empinada” dependiendo de los valores que se le den a los factores de escala de salida.




Fig. 3.4 Superficie de control para las válvulas de descarga entre error % sólido y error % de torque




Fig. 3.5 Superficie de control para floculante entre el porcentaje de sólidos y la derivada de porcentaje de error de sólidos.

3.1.3. Etapa de defusificación:

Para defusificar la salida se aplica el método del centroide, calculado como:

$$du_k = \frac{M_{duk\ out}(P) - M_{duk\ out}(N)}{M_{duk\ out}(P) + M_{duk\ out}(Z) + M_{duk\ out}(N)}$$

Donde $M_{duk\ out}$ es el resultado de evaluar los distintos grados de pertenencia de un estado del sistema. Por ejemplo, para calcular $M_{duk\ floc}$ se tiene lo siguiente:

$$M_{duk\ Floc}(Z) = \max \begin{bmatrix} \min (\mu_{e\%solido}(P), \mu_{de\%solido}(N), \mu_{e\%torque}(N), \mu_{de\%torque}(N)) \\ \min (\mu_{e\%solido}(P), \mu_{de\%solido}(N), \mu_{e\%torque}(P), \mu_{de\%torque}(N)) \\ \min (\mu_{e\%solido}(P), \mu_{de\%solido}(N), \mu_{e\%torque}(N), \mu_{de\%torque}(P)) \\ \min (\mu_{e\%solido}(P), \mu_{de\%solido}(N), \mu_{e\%torque}(P), \mu_{de\%torque}(P)) \end{bmatrix}$$

Este cálculo corresponde a lo mostrado en la tabla 4.2.

Finalmente se multiplica por un factor de escala Sdu .

$$du_k = du_k * Sdu$$

3.2. Sintonización del controlador

La sintonización de controladores lógicos difusos es una tarea compleja como se ha estudiado en las secciones 2.4 y 2.5 de la presente memoria. A pesar de que los FLC ofrecen un marco intuitivo para el diseño de controladores, su rendimiento óptimo depende de manera crucial de la correcta definición de sus componentes: las funciones de pertenencia, la base de reglas y los factores de escala. A continuación, se desarrollará un enfoque más sistemático a la problemática de la sintonización de estos controladores.

3.2.1. Temas de dimensionalidad

Uno de los mayores obstáculos en la sintonización de FLC es el fenómeno conocido como la “maldición de la dimensionalidad”. Este término se refiere al crecimiento exponencial del número de parámetros a optimizar a medida que aumenta la complejidad del controlador, o en este caso la cantidad de parámetros que buscaremos optimizar. Para ilustrar este desafío, se considerarán algunos escenarios de optimización.

- Escenario 1: Se modifican exclusivamente los factores de escala.

Para el FLC diseñado se identifican seis factores de escala que requieren sintonización [$SeC, SdeC, SeT, SdeT, SduC, SduF$]. Si se considera una búsqueda exhaustiva y cada uno de estos parámetros pudiera tomar, por ejemplo, 10 valores discretos dentro de un rango de operación, el número total de permutaciones a evaluar serían 10^6 . Es una cifra considerable, pero manejable con algoritmos de optimización global.

- Escenario 2: Modificación de factores de escala y parámetros de funciones de pertenencia.

Al incluir los parámetros de las funciones de pertenencia, que son definidas por tres parámetros. Considerando las cuatro entradas del FLC, cada una con dos funciones de pertenencia, se tienen 4

entradas por 2 funciones de pertenencia por entrada por 3 parámetros por función de pertenencia. Con esto se tienen 24 parámetros adicionales solo para las funciones de pertenencia. Sumados los 6 factores de escala, el total asciende a 30 parámetros. Si cada uno de estos parámetros tomara 10 valores discretos, el número de permutaciones alcanzaría 10^{30} . Una cifra 24 órdenes de magnitud mayor.

Esta alta dimensionalidad obliga a recurrir a estrategias de optimización inteligentes, así como dejar fijos ciertos parámetros (aquellos que puedan ser obtenidos u optimizados desde la experiencia como es el caso de las reglas del motor de inferencia) e ir sintonizando por etapas. Esta memoria se enfocará en optimizar exclusivamente los seis factores de escala utilizando el algoritmo de optimización global enjambre de partículas (PSO). Esta simplificación estratégica reduce significativamente la complejidad del problema de optimización como se estudió en los escenarios anteriores. Este enfoque por etapas, donde primero se aborda una versión simplificada del problema y luego se considera el uso de herramientas más potente como ANFIS para un refinamiento que puede incluir la adaptación de las funciones de pertenencia, es una práctica común en ingeniería para abordar problemas complejos.

3.2.2. Optimización de los factores de escala mediante enjambre de partículas

La sintonización automática de los parámetros del FLC se formula como un problema de optimización, donde el objetivo es encontrar el conjunto de parámetros que minimice una función de costo predefinida. El espacio de búsqueda de los parámetros de un FLC puede ser complejo y con la posibilidad de existencia de óptimos locales. Por esto los algoritmos de optimización local son particularmente adecuados, ya que están diseñados para explotar el espacio de búsqueda y aumentar la probabilidad de encontrar la solución óptima global o una cercana a esta [32].

Se seleccionó la optimización por enjambre de partículas (PSO). PSO es una técnica de optimización estocástica basada en poblaciones, inspirada en el comportamiento social de las bandadas de aves. En la literatura se ha observado que PSO a menudo converge más rápidamente que otros algoritmos evolutivos, aunque puede ser más propenso a quedar atrapado en óptimos locales si la exploración no es adecuada.

En el caso de sintonizar los seis factores de escala, la velocidad de convergencia de PSO es una ventaja, permitiendo iteraciones de diseño más rápidas. Esta velocidad de iterar rápidamente permite lograr distintos objetivos al momento de modificar los distintos pesos en la función de costo a minimizar.

3.2.3. Diseño de la función de costo para PSO

La efectividad del PSO depende del diseño de la función de costo (J), la cual debe cuantificar el rendimiento del controlador de manera que su minimización se traduzca en un comportamiento deseado del sistema. Para esto la función de costo considera dos problemas principales en la operación del espesador: el error y los sobrepasos tanto del porcentaje de sólidos como del porcentaje de torque.

Para esto se definen unos sets point de 55% para el porcentaje de sólidos de descarga y 20% para el porcentaje de torque en la rastra.

La función de costo J se compone de varios términos ponderados:

1. Error cuadrático medio (MSE): este término penaliza las desviaciones cuadráticas medias de los sólidos de descarga y el torque respecto a sus sets points.

$$peso_{error} * (0.9 * MSE_{\%sólidos} + 0.1 * MSE_{\%torque})$$

2. Penalización por sobrepaso: este término penaliza las ocasiones donde el porcentaje de sólidos o torque exceden sus sets point. Su peso será denotado como $peso_{sobrepaso}$.

Con estos términos se consigue la siguiente función de costo J:

$$J = peso_{error} * (0.9 * MSE_{\%sólidos} + 0.1 * MSE_{\%torque}) + peso_{sobrepaso} * (penalizacion_{sobrepasosolido} + penalizacion_{sobrepasotoque})$$

Donde las penalizaciones son la sumas al cuadrado de las veces que se produce un sobrepaso tanto para los sólidos como para el torque. El $peso_{error}$ y $peso_{sobrepaso}$ son los valores modificables.

Los factores de ponderación específicos 0.9 y 0.1 fueron elegidos para darle una mayor importancia al error de porcentaje de sólidos de los sólidos de descarga. Estos valores fueron conseguidos mediante un proceso iterativo manual para conseguir los objetivos de control deseados. La elección de 1000 y 10 para los pesos de los casos 1 y 2 fueron definidos así para notar las diferencias entre el cambio entre las filosofías de control.

Se formarán dos casos: 1) donde se minimice el error cuadrático medio y 2) donde se minimice la cantidad de sobrepasos durante la operación del espesador.

Tabla 3.4 Pesos y factores de escala óptimos para ambos casos

	Peso error	Peso sobrepaso	J	Factores de escala óptimos [SeC SdeC SeT SdeT SduC SduF]
Caso 1	1000	10	3873	[0.01 0.01 34.40 2.20 44.47 2.85]
Caso 2	10	1000	122	[12.30 0.07 21.30 0.06 45.41 2.56]

Que en el caso 1 obtenga un numero bastante mayor al caso 2 no aporta demasiada información en términos de que tan bien se comporte el controlador comparado uno con otro. Ambos pudieron optimizar de buena manera la función de costo J . En el caso 2 por ejemplo, este pudo obtener un valor bajo de J lo que indica que no debería haber sobrepasos en la simulación que se hará en el capítulo siguiente.

En la figura 3.6 se muestra como converge a una solución el PSO en el caso 1 y en la figura 3.7 en el caso 2




Fig. 3.6 Mejor valor de la función de costo por iteración minimizando error cuadrático medio




Fig. 3.7 Mejor valor de la función de costo por iteración minimizando sobrepasos




Fig. 3.8 Zoom de la figura 3.7

Con estos gráficos podemos observar la rápida convergencia a una solución óptima usando PSO. En específico en la figura 3.7 se puede ver que en la segunda iteración el algoritmo ya logra acercarse a un valor optimo de los factores de escala para minimizar los sobrepasos. Mostrando así la velocidad de convergencia característica de el algoritmo de enjambre de partículas.

3.3. Desarrollo del controlador Adaptativo Neuro-Difuso (ANFIS)

La etapa siguiente consta de la implementación de un controlador neuro difuso usando ANFIS. Esto porque este sistema ofrece capacidades adicionales para el refinamiento y la adaptación del controlador.

3.3.1. Motivación para la implementación de ANFIS

ANFIS es una arquitectura que integra capacidades de aprendizaje de las redes neuronales con la interpretabilidad y estructura basada en reglas de los sistemas de inferencia difusa. La ventaja principal por explotar viene en su capacidad de aprender directamente de datos, adaptando los parámetros de las funciones de pertenencia de los antecedentes como los parámetros de las funciones de pertenencia de los consecuentes.

El FLC optimizado por PSO opera con funciones de pertenencia triangulares fijas y ANFIS puede superar esta limitación, aprendiendo funciones de pertenencia más adecuadas, que potencialmente puede llevar a un rendimiento superior o mayor robustez, especialmente ante perturbaciones.

3.3.2. Estrategia de entrenamiento: utilización de los datos generados por el FLC con factores de escala óptimos

La estrategia adoptada consiste en utilizar el FLC previamente optimizado por PSO como un “generador de conocimiento experto”. Específicamente, se simula el modelo del sistema controlador por el FLC con sus factores de escala óptimos que se encuentran en la tabla 3.4 para generar un conjunto de datos de entrenamiento. Estos datos ayudan a inicializar ANFIS de manera más efectiva que la inicialización aleatoria o un ANFIS puramente basado en datos de planta brutos, especialmente si no cubren todas las regiones operativas deseadas.

Las entradas para el sistema ANFIS durante el entrenamiento son los errores y derivada del error escalados que utilizaba el FLC. Las salidas objetivo que ANFIS debe aprender son las acciones de control normalizadas que el FLC optimizado por PSO habría generado para un conjunto de entradas.

La estructura inicial del sistema se genera utilizando el Fuzzy Logic Toolbox de Matlab. Se escogen tres funciones de pertenencia para las entradas tipo “campana generalizada” (gbellmf en Matlab) y salidas constantes. Es importante destacar que se entrenan dos controladores ANFIS separados, uno para controlar las válvulas de descarga y otro para controlar la dosis de floculante.

El uso de tres funciones de pertenencia por entrada y el uso de salidas tipo constante es debido al problema de dimensionalidad. La limitada cantidad de datos que se dispone obliga a usar una cantidad menor de funciones de pertenencia por entrada. Estando en un límite inferior de lo que sería una práctica recomendada. En el caso actual al usar partición de rejilla, se tienen $3^4 = 81$ reglas. Cada regla en un ANFIS tipo Sugeno con salidas constantes tiene al menos un parámetro ajustable para la salida. Además, las funciones de pertenencia de entrada también tienen parámetros ajustables: $4 \text{ entradas} * 3 \text{ MF} * 3 \text{ parámetros} = 36 \text{ parámetros de premisa}$. Esto suma un total de aproximadamente 117 parámetros a estimar.

4. Resultados

Este capítulo presenta los resultados experimentales obtenidos de la implementación y validación de las estrategias de control diseñadas, con la metodología descrita en el Capítulo 3. Se evaluará cuantitativa y cualitativamente el desempeño de los controladores desarrollados y validar la eficacia del enfoque de sintonización automática propuesto.

4.1. Presentación de los resultados de simulación del FLC

Tabla 4.1 Índices de rendimiento de los controladores FLC optimizados con PSO

Caso de optimización FLC	RMSE solido	RMSE torque	Sobrepaso Máx. %Sólidos (%)	Sobrepaso Máx. %Torque (%)	Esfuerzo de control válvula	Esfuerzo de control floculante	Agua Recuperada (m ³)
Caso 1	1.213	3.6041	5.115	7.846	1398	781.5	757609
Caso 2	2.658	7.983	0.5851	0	8740	435.8	648267

Esta tabla muestra directamente el impacto de la función de costo de PSO en el comportamiento del FLC, validando el proceso de sintonización descrito en el Capítulo 3. Presenta los índices de rendimiento reales obtenidos de estas simulaciones, no solo el valor de la función de costo, proporcionando una imagen clara de lo que logró cada sintonización del FLC.

4.1.1. Simulación del proceso minimizando el error cuadrático medio (caso 1)

La figura 4.1 muestra una visión general del FLC.




Fig. 4.1 Gráfico general del proceso con FLC optimizado con PSO minimizando error cuadrático medio

La figura 4.2 muestra un histograma de error en el porcentaje de solidos en la descarga y la figura 4.3 muestra un histograma de error en el porcentaje de torque de la rastra.




Fig. 4.2 Histograma de error en porcentaje de solidos de descarga (caso 1)




Fig. 4.3 Histograma de error del porcentaje de torque de la rastra (caso 1)

Como se puede ver en la figura 4.2, la distribución de los errores está centrada alrededor del cero. Cumpliendo así el objetivo de minimizar el error cuadrático medio.

La figura 4.3 tiene su distribución de error centrada lejos del cero, esto pues en la función de costo se le da prioridad a minimizar el error del porcentaje de solidos antes que minimizar el error del porcentaje de torque.

En la figura 4.4 se muestra un histograma de la diferencia de acción de control de las válvulas de descarga.




Fig. 4.4 Histograma de diferencia de acción de control de válvulas de descarga (caso 1)




Fig. 4.5 Histograma de diferencia de acción de control de dosis de flocculante (caso 1)

Es fácil notar que la acción de control de la válvula de descarga es más suave en comparación a la de la dosis de flocculante, puesto que en la figura 4.4 tiene una distribución uniforme, mientras la figura 4.5 muestra valores discretos de la variación de control calculada.

4.1.2. Simulación del proceso minimizando sobrepasos (caso 2)

La figura 4.6 muestra una visión general del proceso.




Fig. 4.6 Grafico general del proceso con FLC optimizado con PSO minimizando sobrepaso

Se puede notar como el controlador optimizado para minimizar sobrepaso cumple su objetivo. En la figura 4.6 se puede identificar que una vez alcanzado el set point de solidos el controlador evita que se produzca un sobrepaso, cuidando así la integridad de la distinta instrumentación del espesador.

También acudiendo a la tabla 4.1 se extrae que el sobrepaso máximo obtenido en la simulación es de un 0.58 %, incluso con grandes perturbaciones como la que ocurre alrededor de las 250 horas.

En la figura 4.7 se puede ver que la distribución del error en los sólidos de descarga ya no está centrada alrededor del cero. Además de confirmar nuevamente que los sobrepasos son mínimos. Por el lado del torque, al observar la figura 4.8, esta responde al error necesario para que en los sólidos no haya sobrepaso, si por ejemplo el set point de porcentaje de torque aumentara a 30%, los valores de proceso de torque se mantendrían. En este caso, el set point de solidos (55%) está “limitando” al torque, pues se le da prioridad a mantener el set point de sólidos.




Fig. 4.7 Histograma de distribución de errores de porcentaje de solidos (caso 2)




Fig. 4.8 Histograma de distribución de errores de porcentaje de torque (caso 2)

En el caso de la variación de control es importante ver que a pesar de que el FLC caso 1 y FLC caso 2 tengan las mismas reglas, el control es completamente diferente al estar optimizados con distintos objetivos.




Fig. 4.9 Histograma de diferencia de acción de control de válvulas de descarga (caso 2)




Fig. 4.10 Histograma de diferencia de acción de control del floculante (caso 2)

4.2. Presentación del entrenamiento, simulación y rendimiento de ANFIS

Se entrenaron controladores ANFIS basados en dos escenarios FLC (caso 1: error mínimo, caso 2: sobrepaso mínimo). Se presentan los resultados para cada uno de estos controladores ANFIS.

Estructura ANFIS: se muestran en número de reglas, funciones de pertenencia y parámetros para cada ANFIS.

Se ejecuta el entrenamiento con los datos generados y se obtienen los siguientes ANFIS:




Fig. 4.11 Estructura del ANFIS para control de válvulas de descarga




Fig. 4.12 Estructura del ANFIS para control de dosis de floculante

Estas estructuras son idénticas para ambos casos de entrenamiento. Luego se procede a ver las superficies de control aprendidas por los ANFIS:




Fig. 4.13 Superficie de control del ANFIS para control de válvulas de descarga

La figura 4.13 es equivalente a la figura 3.4 hecha con las 16 reglas derivadas de la relación de las variables en el modelo descrito en la sección 2.6. Se puede notar que, al tener ahora 3 funciones de pertenencia por entrada, la superficie de control puede ser más compleja en comparación a trabajar con solo 2 funciones de pertenencia. Lo mismo sucede con la figura 4.14 y 3.5.




Fig. 4.14 Superficie de control del ANFIS para control de dosis de floculante

Los datos fueron divididos entre datos de entrenamiento (418 datos) y datos de validación (179 datos). Con esto se capturaron los errores de entrenamiento validación para ver cómo evoluciona la raíz de error cuadrático medio del ANFIS para ambos casos.




Fig. 4.15 Curva de aprendizaje ANFIS válvula de descarga caso 1




Fig. 4.16 Curva de aprendizaje ANFIS floculante para caso 1




Fig. 4.17 Curva de aprendizaje ANFIS válvula para caso 2




Fig. 4.18 Curva de aprendizaje ANFIS floculante para caso 2

Estos gráficos se resumen en la tabla 4.2.

Tabla 4.2 Errores de entrenamiento y validación ANFIS

Métrica RMSE	ANFIS Min. error	ANFIS min. sobrepaso
RMSE Válvula (entrenamiento)	0.003817	0.00514
RMSE válvula (validación)	0.007134	0.01218
RMSE Floculante (entrenamiento)	0.0005343	0.004323
RMSE floculante (validación)	0.05934	0.02594

Los RMSE mayores en el caso de mínimo sobrepaso comprado con mínimo error muestra que a ANFIS le cuesta un poco más seguir la respuesta deseada, esto puede decir que mantener el sobrepaso mínimo requiere un mayor esfuerzo de control de parte del control de las válvulas de descarga como la dosis de floculante. Esto es confirmado también gracias a la tabla 4.1 donde se observa que el esfuerzo de control en el caso de minimizar sobrepaso es mayor que al minimizar el error.

Con los errores estudiados se procede a simular y graficar el comportamiento de los ANFIS usando los 179 datos de validación. Comparando la salida deseada versus la salida obtenida por ANFIS.




Fig. 4.19 Válvula: ANFIS vs FLC (validación) minimizando error y error de predicción (caso 1)




Fig. 4.20 Floculante: ANFIS vs FLC (validación) minimizando error y error de predicción (caso 1)




Fig. 4.21 Válvula: ANFIS vs FLC (validación) minimizando sobrepaso y error de predicción (caso 2)




Fig. 4.22 Floculante: ANFIS vs FLC (validación) minimizando sobrepaso y error de predicción (caso 2)

Como se habló anteriormente, es fácil notar que la variación de control en el caso de minimizar sobrepaso es mucho más agresiva, dificultando el entrenamiento en comparación al caso de minimizar error. De igual forma, al analizar los RMSE y al ver las figuras, el entrenamiento de ANFIS a partir de los FLC optimizados por PSO es satisfactorio.

A continuación, se muestra la tabla 4.3 que muestra distintos índices de rendimiento

Tabla 4.3 Índices de rendimiento de los controladores ANFIS entrenados con diferentes datos de FLC experto

Controlador ANFIS	RMSE %Sólidos	RMSE %Torque	Sobrepaso Máx. %Sólidos (%)	Sobrepaso Máx. %Torque (%)	Esfuerzo de control válvula	Esfuerzo de control floculante	Agua Recuperada (m3)
Caso 1 (Error Mín.)	1.203	3.565	5.152	7.431	1385	798.8	758106
Caso 2 (Sobrepaso Mín.)	2.601	7.793	1.055	0	8697	443.1	650739

Esta tabla es crucial para comprender cómo el "conocimiento experto" de los FLC sintonizados de manera diferente influye en los controladores ANFIS finales. Permite una comparación directa de los controladores ANFIS derivados de diferentes filosofías de control. Los resultados son los esperados, ambos casos se distinguen de manera significativa el uno del otro. Dependiendo de las necesidades de cada espesador o los objetivos operacionales se podría elegir una u otra filosofía de control.

4.2.1. Simulación del proceso usando ANFIS minimizando el error cuadrático medio (caso 1)

La figura 4.23 muestra una visión general del proceso.




Fig. 4.23 Grafico general del proceso con ANFIS entrenado con FLC PSO minimizando error cuadrático medio

Se puede ver como el controlador intenta minimizar el error cuadrático medio sacrificando sobrepasos en algunos momentos, sobre todo cuando hay grandes perturbaciones en el caudal de alimentación. Tanto el control de porcentaje de solidos como el control de torque son satisfactorios. El ANFIS ha aprendido de buena forma el comportamiento del FLC optimizado.




Fig. 4.24 Histograma de errores de porcentaje de solidos de descarga ANFIS (caso 1)




Fig. 4.25 Histograma de errores de porcentaje de error del torque ANFIS (caso 1)




Fig. 4.26 Histograma de diferencia de acción de control para válvula ANFIS (caso 1)




Fig. 4.27 Histograma de diferencia de acción de control para dosis de floculante ANFIS (caso 1)

Se confirma nuevamente el correcto aprendizaje y control de parte del ANFIS entrenado con el FLC optimizado para minimizar el error cuadrático medio. Tanto los errores como las variaciones de control obtenidas del ANFIS son similares al FLC, se logran los objetivos de control.

4.2.2. Simulación del proceso usando ANFIS minimizando los sobrepasos (caso 2)

La figura 4.28 muestra una visión general del proceso.




Fig. 4.28 Grafico general del proceso con ANFIS entrenado con FLC optimizado para minimizar sobrepaso

Se ve inmediatamente que el controlador logra su objetivo de evitar los sobrepasos, tanto del porcentaje de solidos como del porcentaje de torque, para esto la variación de control debe ser mucho más agresiva en los momentos que la variable de control se acerca a su set point respectivo.




Fig. 4.29 Histograma de error de porcentaje de sólidos ANFIS (caso 2)

Notar que la cantidad de escenarios donde hay sobrepasos son mínimos. Sacrificando de esta forma que la variable de proceso se acerque a su set point, y por lo tanto disminuyendo el agua recuperada.




Fig. 4.30 Histograma de errores de porcentaje de torque ANFIS (caso 2)




Fig. 4.31 Histograma de diferencia de acción de control válvula ANFIS (caso 2)

Se puede ver como el rango de la variación de control en ANFIS es mucho más grande, estando en el rango de $[-40, 20]$.




Fig. 4.32 Histograma de diferencia de acción de control de floculante ANFIS (caso 2)

Con la figura 4.32 queda a la vista que para minimizar los sobrepasos la dosis de floculante debe ser ajustada constantemente a diferencia del caso 1 donde como muestra la figura 4.27 la dosis de floculante no es cambiada en un buen porcentaje de las veces, donde la variación de control es cero.

4.3. Evaluación comparativa

4.3.1. Comparación de ANFIS con su FLC optimo de entrenamiento

Se compara el mejor FLC con su respectivo controlador ANFIS entrenado a partir de él.

Tabla 4.4 Rendimiento comparativo: FLC vs ANFIS

Escenario de Comparación	RMSE %Sólidos	RMSE %Torque	Sobrepaso %Sólidos (%)	Sobrepaso %Torque (%)	Esfuerzo de control válvula	Esfuerzo de control floculante	Agua Recuperada (m ³)
FLC Óptimo (Error Mín.)	1.213	3.6041	5.115	7.846	1398	781.5	757609
ANFIS (Entrenado con FLC Error Mín.)	1.203	3.565	5.152	7.431	1385	798.8	758106
FLC Óptimo (Sobrepaso Mín.)	2.658	7.983	0.5851	0	8740	435.8	648267
ANFIS (Entrenado con FLC Sobrepaso Mín.)	2.601	7.793	1.055	0	8697	443.1	650739

Esta tabla aborda directamente la efectividad de usar ANFIS para refinar el FLC. Muestra si la etapa adicional de ANFIS proporciona beneficios tangibles sobre el FLC optimizado por PSO. Compara al "maestro" (FLC) con el "alumno" (ANFIS).

Para el caso de minimizar error el FLC optimo tiene un rendimiento con 1.213 versus 1.203 de ANFIS, lo que es una ganancia marginal para ANFIS. Así, la cantidad de agua recuperada por ANFIS es mayor. Esto se puede deber a que tiene unos sobrepasos un poco mayores.

Para el caso de minimizar sobrepaso, ANFIS obtiene un mejor desempeño de error cuadrático medio frente al FLC óptimo. Sin embargo, el sobrepaso es un poco mayor. De igual forma el agua recuperada por ANFIS es más de 2000 m³ que el FLC óptimo.

4.3.2. Comparación de distintos objetivos de control

Para finalizar la sección 4.3 se comparan los controladores ANFIS con sus distintos objetivos de control.




Fig. 4.33 Control de porcentaje de sólidos usando ANFIS con distintos objetivos de control




Fig. 4.34 Control de porcentaje de torque usando ANFIS con distintos objetivos de control

Se puede ver claramente las diferencias de control al entrenar los ANFIS con FLC optimizados para lograr objetivos distintos. Cada controlador ANFIS cumple con sus objetivos de manera distinta consiguiendo los resultados esperados.




Fig. 4.35 Histograma de comparación de distribución de sólidos entre ANFIS

Es evidente como el ANFIS entrenador para minimizar error, lleva la variable de proceso cerca del set point. Si bien hay sobrepasos, las ocasiones donde estos son mayor al 1% son bajas. Por el lado del ANFIS entrenado para minimizar sobrepaso cumple su objetivo de manera excepcional, este ANFIS nunca la variable de proceso más allá de la banda de ruido del set point.




Fig. 4.36 Histograma de comparación de distribución de sólidos entre ANFIS

Es interesante ver que el ANFIS entrenado para evitar sobrepasos cumple con su objetivo completamente para el torque. Esto puede ser importante al momento de elegir los objetivos de control, si la rastra tiende a fallar al momento de haber un sobrepaso. Con este ANFIS esa situación se evitaría.

4.4. Robustez y generalización de ANFIS

La robustez es una cualidad clave de un buen controlador. Para probar la robustez de los ANFIS entrenados, se usarán los mismos datos de perturbación (flujo de alimentación) pero en orden inverso. Con esto se tendrán datos de perturbaciones en un mismo rango operacional y con cambios que pueden suceder en la planta.




Fig. 4.37 Gráfico general del proceso con perturbaciones invertidas con ANFIS min. Error

Podemos notar como el controlador, a pesar de enfrentarse a distintas perturbaciones este controla de manera satisfactoria, cumpliendo su objetivo de control. Obteniendo un RMSE de solidos de 1.2284, un RMSE de torque de 3.5227 y recuperando 759364 m³ de agua.

Para el caso del ANFIS entrenado para minimizar sobrepaso se tiene la figura 4.38.




Fig. 4.38 Grafico general del proceso con perturbaciones invertidas con ANFIS min. Sobrepasso

Los índices de rendimiento obtenidos para este caso son RMSE solidos de 2.6995, RMSE de torque de 8.0863 y el agua recuperada son 656397 m³. Se puede ver cómo se evita casi en su totalidad los sobrepasso aun con perturbaciones grandes.

5. Conclusiones

5.1. Recapitulación del trabajo y alcance de los objetivos

La optimización de la operación de espesadores de relave en la industria minera representa un desafío significativo debido a la naturaleza compleja, no lineal y multivariable del proceso, así como a la creciente necesidad de maximizar la recuperación de agua y asegurar una operación estable. Las estrategias de control convencionales y la sintonización manual de sistemas expertos a menudo resultan insuficientes para abordar estas complejidades de manera eficiente. En este contexto, la presente memoria de título se centró en el desarrollo y la evaluación de técnicas de sintonización automática para estrategias de control difuso de múltiples entradas y múltiples salidas aplicables a estos sistemas. Este capítulo final tiene como propósito sintetizar los hallazgos más relevantes de la investigación, evaluar el grado de cumplimiento de los objetivos propuestos y delinear posibles vías para trabajos futuros.

5.2. Síntesis de la metodología y contribuciones

La estrategia metodológica adoptada en esta memoria se caracterizó por un enfoque secuencial y progresivo, diseñado para abordar la complejidad del control del espesador de relaves de manera estructurada. Inicialmente, se procedió al diseño de un controlador lógico difuso MIMO, cuyas reglas de inferencia se derivaron a partir del conocimiento encapsulado en los modelos matemáticos del proceso, específicamente los modelos ARMA identificados para los sólidos de descarga, el torque y el agua recuperada. Esta etapa inicial aseguró que el conocimiento experto sobre la dinámica del proceso se integrara desde la creación del controlador.

Posteriormente, se abordó el desafío de la sintonización de los factores de escala del FLC mediante la aplicación de técnicas de optimización global. Se seleccionó el algoritmo de Enjambre de Partículas. Una contribución significativa en esta fase fue la exploración de distintas filosofías de control mediante la modificación de la función de costo utilizada por el PSO. Se definieron dos casos principales: la minimización del error cuadrático medio entre las variables de proceso y sus set point, y la minimización de los sobrepasos, permitiendo así adaptar el comportamiento del controlador a diferentes prioridades operativas.

Finalmente, como una etapa de refinamiento y con el objetivo de una mayor adaptabilidad, se desarrollaron y entrenaron controladores adaptativos neuro-difusos. Estos sistemas ANFIS se

inicializaron y entrenaron utilizando los conjuntos de datos de entrada-salida generados por las simulaciones de los FLC previamente optimizados con PSO.

Las contribuciones de esta memoria se resumen en:

- La propuesta y validación de una metodología sistemática y estructurada por etapas para el diseño y la sintonización automática de controladores difusos MIMO para espesadores de relave.
- La demostración de la eficacia del algoritmo PSO para la optimización de los factores de escala del FLC bajo diferentes criterios de desempeño.
- La implementación y validación exitosa de controladores ANFIS capaces de aprender y refinar el comportamiento de los FLC optimizados.

5.3. Análisis y discusión de los resultados obtenidos

El capítulo 4 de esta memoria presento una evaluación exhaustiva del desempeño de las estrategias de control propuestas, desde la sintonización inicial del FLC hasta el refinamiento con ANFIS y pruebas de robustez.

- Desempeño de los Controladores FLC Optimizados con PSO:

Los resultados cuantitativos de la sintonización de los FLC mediante PSO, presentados en la tabla 4.1, demuestran la efectividad de la metodología para alcanzar diferentes objetivos de control.

El FLC optimizado para minimizar el error cuadrático medio (caso 1) logró, como era de esperar, un menor RMSE para la concentración de sólidos (1.213) en comparación con el FLC optimizado para minimizar sobrepasos (caso 2, RMSE de 2.658). Esta mejora en la precisión se obtuvo a costa de un mayor sobrepaso en la concentración de sólidos (5.115% vs 0.5851%) y un esfuerzo de control de válvula considerablemente menor (1398 vs 8740). Notablemente, el caso 1 resultó en una mayor recuperación de agua (757609 m³ frente a 648267 m³). Por otro lado, el FLC del caso 2 cumplió eficazmente su objetivo de minimizar los sobrepasos, registrando solo un 0.5851% para sólidos y 0% para el torque, aunque esto implicó un RMSE mayor y una menor recuperación de agua.

- Eficacia y Adaptación de los Controladores ANFIS:

El proceso de entrenamiento de los controladores ANFIS, utilizando los datos generados por los FLC optimizados, demostró la capacidad de estos sistemas neuro-difusos para aprender comportamientos de control complejos. Las curvas de aprendizaje (Fig. 3.6, 3.7, 3.8) y los errores de validación indicaron un entrenamiento satisfactorio. Las superficies de control aprendidas por ANFIS (Fig.4.13, 4.14), al utilizar tres funciones de pertenencia por entrada en contraste con las dos del FLC,

mostraron la capacidad de ANFIS para capturar relaciones más complejas en comparación con las superficies de los FLC originales.

Analizando la tabla 4.3 se tiene que para el caso 1 (error mínimo), el ANFIS logró un RMSE en sólidos de 1.203 y un sobrepaso de 5.152%, con una recuperación de agua de 758106 m³. Para el caso 2 (sobrepaso mínimo), el ANFIS obtuvo un RMSE en sólidos de 2.601 y un sobrepaso de 1.055%, con 650739 m³ de agua recuperada. Estos resultados son consistentes con los objetivos de los FLC que sirvieron de base para el entrenamiento. La capacidad de ANFIS para aprender funciones de pertenencia y parámetros de consecuente más adecuados le confiere el potencial de no solo replicar, sino también de generalizar mejor o ser más robusto que el FLC original, especialmente considerando que este último opera con funciones de pertenencia triangulares fijas.

- Evaluación comparativa

La comparación directa entre el FLC óptimo y su respectivo controlador ANFIS, presentada en la Tabla 4.4.

Para el objetivo de error mínimo, el ANFIS mostró una ganancia marginal en el RMSE de sólidos (1.203 vs 1.213 del FLC) y una ligera mejora en la recuperación de agua (758106 m³ vs 757609 m³), con sobrepasos muy similares. En el caso de "sobrepaso mínimo", el ANFIS también logró un mejor desempeño en el RMSE de sólidos (2.601 vs 2.658 del FLC) y una mayor recuperación de agua (650739 m³ vs 648267 m³), aunque con un ligero incremento en el sobrepaso de sólidos (1.055% vs 0.5851%). La ligera superioridad o, en algunos casos, comparabilidad del ANFIS entrenado a partir del FLC-PSO frente al propio FLC-PSO indica que una parte sustancial de la definición de la estrategia de control y la optimización inicial se realiza eficazmente en las etapas de diseño del FLC y su sintonización con PSO.

- Robustez y generalización de ANFIS

Las pruebas de robustez, realizadas sometiendo a los controladores ANFIS a la misma secuencia de perturbaciones de flujo de alimentación, pero en orden inverso, arrojaron resultados alentadores. El ANFIS entrenado para minimizar error, bajo estas nuevas condiciones, obtuvo un RMSE de sólidos de 1.2284, muy cercano al 1.203 original, y recuperó 759364 m³ de agua, comparable a los 758106 m³ originales. Similarmente, el ANFIS para minimizar sobrepaso registró un RMSE de sólidos de 2.6995 (frente al 2.601 original) y recuperó 656397 m³ de agua, comparable a los 650739 m³ originales, manteniendo su capacidad de evitar sobrepasos significativos. Estos resultados demuestran una buena capacidad de generalización por parte de los controladores ANFIS entrenados. El hecho

de que mantengan un desempeño consistente frente a secuencias de perturbación no vistas durante la fase de entrenamiento, aunque dentro de un rango operacional similar, sugiere que los modelos ANFIS han capturado las dinámicas del sistema de manera efectiva y no están simplemente "memorizando" los datos de entrenamiento.

5.4. Cumplimiento de objetivos

La evaluación de los resultados obtenidos, respaldada por los análisis cuantitativos (Tablas 4.1, 4.3, 4.4) y cualitativos (figuras de simulación) presentados en el capítulo 4, permite afirmar el cumplimiento satisfactorio de los objetivos planteados para esta memoria de título. Se diseñaron y desarrollaron con éxito técnicas de sintonización automáticas para un sistema de control experto MIMO. Estas técnicas se aplicaron considerando variables cruciales del proceso de espesamiento como el torque de la rastra, la dosificación de floculante y el flujo de alimentación, logrando controlar la concentración de descarga y evaluar el impacto en el volumen de agua recuperada.

5.5. Limitaciones

A pesar de los resultados positivos, es fundamental reconocer las limitaciones inherentes al presente estudio:

- Dependencia de Datos Históricos y Entorno de Simulación: El desarrollo y la validación de los controladores se basaron exclusivamente en datos históricos de un espesador específico y se llevaron a cabo en el entorno de simulación Matlab. Si bien este enfoque permite un desarrollo y prueba controlados, los resultados necesitan una validación en condiciones operativas reales o en una planta piloto para confirmar su aplicabilidad y rendimiento en presencia de dinámicas no modeladas.
- Simplificaciones del Modelo del Espesador: Los modelos del proceso tipo ARMA, aunque derivados de datos reales del espesador, son por naturaleza simplificaciones de la compleja dinámica físico-química que ocurre en un espesador. Factores como variaciones no modeladas en la mineralogía de la alimentación, la distribución del tamaño de partícula, la eficiencia del floculante bajo diferentes condiciones, o los efectos de la temperatura, podrían no estar completamente capturados por estos modelos.

5.6. Trabajos futuros

Con base en los hallazgos y las limitaciones identificadas, se proponen las siguientes líneas de investigación y desarrollo futuro:

- Validación experimental: La recomendación más prioritaria es la validación de los controladores FLC-PSO y ANFIS desarrollados en un entorno más realista, ya sea una planta piloto o, idealmente, un espesador industrial.
- Exploración de otros algoritmos de optimización y aprendizaje:
 - Investigar la aplicación de otros algoritmos de optimización metaheurísticos para la sintonización de los FLC o incluso para la optimización directa de los parámetros de los sistemas ANFIS.
 - Explorar arquitecturas ANFIS más complejas o diferentes métodos de entrenamiento, incluyendo la posibilidad de adaptación online continua de los parámetros de ANFIS en respuesta a cambios lentos en las características del proceso
- Comparación con otras estrategias de control avanzado: Llevar a cabo estudios comparativos rigurosos del rendimiento de los controladores difusos y neuro-difusos desarrollados en esta memoria frente a otras técnicas de control avanzado aplicadas a espesadores, como el control predictivo basado en modelos.

Referencias

- [1] F. Betancourt, F. Concha y D. Sbarbaro, «Simple mass balance controllers for continuous sedimentation,» *Computers & Chemical Engineering*, vol. 54, pp. 34-43, 2013.
- [2] J. P. Segovia, F. Concha y D. Sbarbaro, «On the control of sludge level and underflow concentration in industrial thickeners,» *IFAC Proceedings Volumes*, vol. 44, nº 1, pp. 8571-8576, 2011.
- [3] T. Chai, H. Li y H. Wang, «An Intelligent Switching Control for the Intervals of Concentration and Flow-rate of Underflow Slurry in a Mixed Separation Thickener,» *IFAC Proceedings Volumes*, vol. 47, nº 3, pp. 338-345, 2014.
- [4] N. Xu, X. Wang, J. Zhou, Q. Wang, W. Fang y X. Peng, «An intelligent control strategy for thickening process,» *International Journal of Mineral Processing*, vol. 142, pp. 56-62, 2015.
- [5] R. J. a. F. You, «Application of Robust Model Predictive Control Using Principal Component Analysis to an Industrial Thickener,» *IEEE Transactions on Control Systems Technology*, vol. 32, nº 3, pp. 1-8, 2024.
- [6] A. Gupta. y. D. Yan, *Mineral Processing Design and Operations*, Elsevier eBooks, 2016.
- [7] R. Oulhiq, K. Benjelloun, Y. Kali, M. Saad, y H. Griguer, «Constrained model predictive control of an industrial high-rate thickener», *Journal Of Process Control*, vol. 133, p. 103147, Jan. 2024, doi: [10.1016/j.jprocont.2023.103147](https://doi.org/10.1016/j.jprocont.2023.103147).
- [8] T. Chai, Y. Jia, H. Li, y H. Wang, «An intelligent switching control for a mixed separation thickener process», *Control Engineering Practice*, vol. 57, pp. 61-71, Dic. 2016, doi: [10.1016/j.conengprac.2016.07.007](https://doi.org/10.1016/j.conengprac.2016.07.007).
- [9] R. Oulhiq, K. Benjelloun, Y. Kali, y M. Saad, «Identification and Control of an Industrial Thickener Using Historical Data», *International Multi-Conference On Systems, Signals & Devices*, Mar. 2021, doi: [10.1109/ssd52085.2021.9429523](https://doi.org/10.1109/ssd52085.2021.9429523).
- [10] R. R. Santos, J. A. Meech, y L. Ramos, «Thickener operations at Carajas using a fuzzy logic controller», 1995 IEEE International Conference On Systems, Man And Cybernetics. Intelligent Systems For The 21st Century, vol. 2, pp. 1636-1639, Nov. 1995, doi: [10.1109/icsmc.1995.538007](https://doi.org/10.1109/icsmc.1995.538007).

- [11] A. Mular, D. Halbe y D. Barret, *Mineral Processing Plant Design, Practice, and Control*. Society for Mining, Metallurgy and Exploration, 2002.
- [12] L. Bergh, P. Ojeda, y L. Torres, «Expert Control Tuning of an Industrial Thickener», *IFAC-PapersOnLine*, vol. 48, n.o 17, pp. 86-91, Jan. 2015, doi: 10.1016/j.ifacol.2015.10.083.
- [13] R. Bürger y F. Concha, «Mathematical model and numerical simulation of the settling of flocculated suspensions», *International Journal Of Multiphase Flow*, vol. 24, n.º 6, pp. 1005-1023, Sep. 1998, doi: 10.1016/s0301-9322(98)00026-3.
- [14] R. Bürger, M. C. Bustos, y F. Concha, «Settling velocities of particulate systems: 9. Phenomenological theory of sedimentation processes: numerical simulation of the transient behaviour of flocculated suspensions in an ideal batch or continuous thickener», *International Journal Of Mineral Processing*, vol. 55, n.º 4, pp. 267-282, Feb. 1999, doi: 10.1016/s0301-7516(98)00037-4.
- [15] S. Gonzales, «Diseño y fabricación de espesador de relaves de cobre de 15 metros diámetro», Tesis, UCSM, Arequipa, 2016.
- [16] G. Huzamán, «Diseño de Estrategias de Control para Espesadores», Memoria de Título, UdeC, Concepción, Septiembre de 2009.
- [17] H. D. Young, R. A. Freedman, and A. L. Ford, *University Physics with Modern Physics*, 14th ed. San Francisco, CA, USA: Pearson, 2015, pp. 350-351.
- [18] P. Ojeda Vásquez, «Diseño e Implementación Lógica de Control Experto en Espesador de Relaves - Planta Las Tórtolas», Memoria de Título, Universidad Técnica Federico Santa María, Valparaíso, Mayo de 2014.
- [19] *Metalliferous Mining - Processing Thickening Resource Book*, Australian Centre for Geomechanics, Perth, WA, 2016. [Online]. Disponible: <https://fddocuments.net/document/thickening-resource-book.html>
- [20] S. Magalhães and T. Euzébio, «Supervisory Fuzzy Controller for Thickener Underflow Solids Concentration on a Simulated Platform, » in *Proceedings of the Automining 2018 Conference*, Gecamin, Santiago, Chile, 2018.
- [21] J.P. Segovia “Apuntes Fundamentos de Lógica Difusa”.
- [22] V. Friz Romero, «Desarrollo e implementación de estrategias de control neurodifusas para espesadores de relave», Memoria de Título, UdeC, Concepción, Abril de 2013.

- [23] C. R. Bahamonde Reyes, «Controlador MIMO Basado en Identificación Neuro-Difusa», Informe de Memoria de Título, Universidad de Concepción, Facultad de Ingeniería, Departamento de Ingeniería Eléctrica, Concepción, Chile, Septiembre. 2006.
- [24] M. A. Majid, M. F. Rahmat, K. Ishaque, y H. Wahid, «Design of self-tuning fuzzy logic controller for the control of an unknown industrial process», *International Journal of Control Science and Engineering*, vol. 2, no. 5, pp. 107-113, 2012.
- [25] Bouallègue, J. H. Kallel, H. H. Abdallah, y T. Damak, «PID-type fuzzy logic controller tuning based on particle swarm optimization», *International Journal of Innovative Computing, Information and Control*, vol. 8, no. 10B, pp. 7123-7144, Oct. 2012.
- [26] A. A. Alqarni, A. M. Faid, M. Aly, y M. Alsharif, «Adaptive Neuro-Fuzzy Inference System (ANFIS) Tuned by Adam Optimizer and Particle Swarm Optimization (PSO) for Parkinson's Disease Prediction», *Applied Sciences*, vol. 14, no. 9, p. 3687, Apr. 2024.
- [27] M. S. Rahman and M. H. Ali, «Adaptive Neuro Fuzzy Inference System (ANFIS)-Based Control for Solving the Misalignment Problem in Vehicle-to-Vehicle Dynamic Wireless Charging Systems», *Electronics*, vol. 14, no. 3, Art. no. 507, Jan. 2025.
- [28] A. Pasha, S. T. Ahmed, R. K. Painam, S. K. Mathivanan, P. Karthikeyan, S. Mallik, and H. Qin, «Leveraging ANFIS with Adam and PSO optimizers for Parkinson's disease detection», *Heliyon*, vol. 10, no. 9, Art. no. e30241, Apr. 2024.
- [29] G. Tıkız and H. C. Güzeliş, «An adaptive neuro-fuzzy inference system based on a new hybrid particle swarm optimization algorithm for chaotic time series prediction», *Appl. Soft Comput.*, vol. 86, Art. no. 105822, Jan. 2020.
- [30] M. A. Askandar, M. N. Taib, and M. S. Mamat, «Neuro-Fuzzy Logic Controller for Switching Capacitor Banks in Power Factor Correction within the Manufacturing Industry», in *2013 IEEE International Conference on Control System, Computing and Engineering*, Penang, Malaysia, Nov. 2013, pp. 114-119. doi: 10.1109/ICCSCE.2013.6719943.
- [31] A. Askari, A. Gholampour, S. H. Khoshraftar, S. M. Sajadi, and M. H. Qomian, «Optimizing researcher mentorship matching: A particle swarm optimization-based recommendation model», *World Journal of Advanced Engineering Technology and Sciences*, vol. 12, no. 2, pp. 341-351, Dec. 2024. doi: 10.30574/wjaets.2024.12.2.0258.
- [32] Kennedy, J., and R. Eberhart. "Particle Swarm Optimization." *Proceedings of the IEEE International Conference on Neural Networks*. Perth, Australia, 1995, pp. 1942–1945.

Anexo

Tabla A.1: Detalle de los factores de escala y su influencia

Factor de Escala	Descripción	Impacto de un Valor Pequeño/Grande en la Respuesta del Controlador	Límites Usados en PSO [li, ls]
SeC	Escala el error de concentración de sólidos (eC) al rango [-1, 1].	Pequeño: alta sensibilidad al error (respuesta más rápida/agresiva). Grande: baja sensibilidad (respuesta más lenta/suave).	[0.01,50]
SdeC	Escala el cambio en el error de concentración (ΔeC) al rango [-1, 1].	Pequeño: alta sensibilidad al cambio de error (mejor amortiguación/respuesta a perturbaciones). Grande: baja sensibilidad (respuesta más lenta a cambios).	[0.01,50]
SeT	Escala el error de torque (eT) al rango [-1, 1].	Pequeño: alta sensibilidad al error (respuesta más rápida/agresiva para proteger la rastra). Grande: baja sensibilidad (respuesta más lenta/suave).	[0.01,50]
SdeT	Escala el cambio en el error de torque (ΔeT) al rango [-1, 1].	Pequeño: alta sensibilidad al cambio de error (respuesta rápida a dinámicas de torque). Grande: baja sensibilidad (respuesta más suave a cambios de torque).	[0.01,50]
SduC	Desnormaliza la salida del FLC para la válvula de descarga (duC).	Pequeño: acción de control menos agresiva (cambios más pequeños en la válvula). Grande: acción de control más agresiva (cambios más grandes en la válvula).	[0.01,50]
SduF	Desnormaliza la salida del FLC para la dosis de floculante (duF).	Pequeño: acción de control menos agresiva (cambios más pequeños en floculante). Grande: acción de control más agresiva (cambios más grandes en floculante).	[0.01,3]

UNIVERSIDAD DE CONCEPCION – FACULTAD DE INGENIERIA
RESUMEN DE MEMORIA DE TITULO

Departamento : Departamento de Ingeniería Eléctrica
Carrera : Ingeniería civil electrónica
Nombre del memorista : Benjamín Alejandro Araneda Muñoz
Título de la memoria : Desarrollo de técnicas de sintonización para estrategias de control difuso MIMO aplicable a espesadores de relave.
Fecha de la presentación oral : 23/07/2025

Profesor guía : Juan Pablo Segovia Vera
Profesores revisores : Mario Rubén Medina Carrasco, Gabriel Alejandro Saavedra Mondaca
Concepto :
Calificación :

Resumen

La gestión eficiente del agua en la minería es crucial, especialmente en los espesadores de relaves, donde la separación sólido-líquido es compleja. Los métodos de control tradicionales a menudo fallan en optimizar la recuperación de agua y estabilizar la operación.

Este trabajo presenta un enfoque para sintonizar automáticamente controladores difusos MIMO para estos espesadores. El objetivo es estabilizar la concentración de sólidos en la descarga, considerando el torque de la rastra, la dosificación de floculante y maximizando la recuperación de agua.

La metodología incluyó el diseño de un Controlador Lógico Difuso (FLC) y la aplicación de la Optimización por Enjambre de Partículas (PSO) para sintonizar sus parámetros. Se exploraron dos filosofías de control: minimizar el error cuadrático medio y minimizar los sobrepasos. Posteriormente, se usaron estos datos para entrenar controladores Adaptativos Neuro-Difusos (ANFIS).

Los resultados, simulados en Matlab con datos industriales, mostraron que PSO sintonizó eficazmente los FLC. Los FLC optimizados para el error lograron alta recuperación de agua, mientras que los optimizados para sobrepasos mostraron excelente estabilidad en sólidos y torque. Los ANFIS replicaron con éxito el comportamiento de los FLC, demostrando buena capacidad de generalización y robustez.