PROPUESTA PARA LA AUTOMATIZACIÓN DE LA DOSIFICACION DE COAGULANTE EN EL PROCESO DE POTABILIZACIÓN DEL AGUA CRUDA MEDIANTE TÉCNICAS DE CONTROL INTELIGENTE

CARLOS ALBERTO VILLARREAL CAMPOS



FACULTAD DE INGENIERÍA
ESCUELA DE INGENIERÍA ELÉCTRICA Y ELECTRÓNICA
SANTIAGO DE CALI
2011

PROPUESTA PARA LA AUTOMATIZACIÓN DE LA DOSIFICACION DE COAGULANTE EN EL PROCESO DE POTABILIZACIÓN DEL AGUA CRUDA MEDIANTE TÉCNICAS DE CONTROL INTELIGENTE

CARLOS ALBERTO VILLARREAL CAMPOS

Tesis de grado para optar al título de
Magister en Ingeniería - Énfasis en Automática

Director
EDUARDO CAICEDO BRAVO, Ph.D.



FACULTAD DE INGENIERÍA
ESCUELA DE INGENIERÍA ELÉCTRICA Y ELECTRÓNICA
SANTIAGO DE CALI
2011

CONTENIDO

pág

INTRODUCCIÓN **12**

1. MÉTODOS UTILIZADOS EN LA DOSIFICACIÓN DE COAGULANTE **13**

1.1. RESEÑA HISTÓRICA **13**

1.2. EL PROCESO DE POTABILIZAIÓN DE AGUA Y LA COAGULACIÓN **13**

1.2.1. Partículas coloidales **15**

1.2.2. Mecanismos de coagulación **17**

1.2.3. Factores que influyen en la coagulación **18**

1.3. MÉTODOS TRADICIONALES PARA LA DETERMINACIÓN DE LA DOSIS DE COAGULANTE **21**

1.3.1. Prueba de jarras **22**

1.3.2. Streaming current detector **23**

1.3.3. Modelos matemáticos **25**

1.3.4. Analizadores de partículas **25**

1.3.5. Análisis espectral **26**

1.4. MÉTODOS BASADOS EN INTELIGENCIA ARTIFICIAL PARA LA DETERMINACIÓN DE LA DOSIS DE COAGULANTE **27**

1.4.1. Redes neuronales **27**

1.4.2. Lógica Difusa **29**

1.4.3. Estructuras ANFIS **30**

1.5. CONCLUSIONES **31**

2. TÉCNICAS DE INTELIGENCIA COMPUTACIONAL PARA EL DESARROLLO DE MODELOS PARA LA DOSIFICACIÓN DE COAGULANTE **33**

2.1. INTRODUCCIÓN **33**

2.2. REDES NEURONALES **33**

2.2.1. Arquitectura de la red **34**

2.2.2. Algoritmos de aprendizaje **36**

2.2.3. Tipos de modelo **37**

2.2.4. Variables de entrada **38**

2.2.5. Pre-procesamiento de los datos **40**

2.2.6. Obtención del modelo en redes neuronales **48**

2.3. SISTEMAS DIFUSOS **51**

2.3.1. Desarrollo del modelo Mamdani **51**

2.3.2. Desarrollo del modelo Sugeno **56**

2.4. ESTRUCTURA ANFIS **63**

2.5. CONCLUSIONES **66**

3. TÉCNICAS DE INTELIGENCIA COMPUTACIONAL PARA LA VALIDACIÓN DE LA INFORMACIÓN **68**

3.1. INTRODUCCIÓN **68**

3.2. REDES NEURONALES AUTO-ASOCIATIVAS **69**

3.2.1. Obtención del modelo de AANN para la validación de la información **71**

3.2.2. Procedimiento de validación **73**

3.2.3. Simulaciones y resultados obtenidos con la red neuronal auto-asociativa **73**

3.3. ALGORITMOS GENÉTICOS **78**

3.3.1. Simulaciones y resultados de validación obtenidos con la utilización de GA **80**

3.3. CONCLUSIONES **82**

4. PLATAFORMA DE EXPERIMENTACIÓN **84**

4.1. INTRODUCCIÓN **84**

4.2. PLANTA DE POTABILIZACIÓN DEL MUNICIPIO DE ROLDANILLO **84**

4.3. IMPLEMENTACIÓN DEL SISTEMA DE DOSIFICACIÓN DE COAGULANTE **85**

4.3.1. Descripción del sistema **85**

4.3.2. Validación de la información mediante hardware redundante **86**

4.3.3. Estructura del programa en el PLC **89**

4.3.4. Bomba dosificadora **90**

4.3.5. Interfaz de operación del sistema de dosificación **91**

4.4. VALIDACIÓN DEL SISTEMA EN LA PLANTA ROLDANILLO **93**

4.4.1. Descripción de la prueba **93**

4.4.2. Desarrollo de la prueba **94**

4.5. METODOLOGÍA PROPUESTA **99**

4.6. CONCLUSIONES **102**

5. CONCLUSIONES Y TRABAJO A FUTURO **103**

5.1. CONCLUSIONES **103**

5.2. TRABAJO A FUTURO **105**

BIBLIOGRAFIA **106**

LISTA DE TABLAS

pág

Tabla 1. Aportes de la presente investigación 32

Tabla 2. Variables disponibles para el modelo y sus rangos 40

Tabla 3. Características de la red neuronal para la detección de *outliers* 42

Tabla 4. Comparación del desempeño de los modelos al eliminar los *outliers* 44

Tabla 5. Análisis de correlación variables de entrada 46

Tabla 6. Características de las redes neuronales para la selección de las variables de entrada 47

Tabla 7. Características de la red neuronal para la estimación de coagulante 48

Tabla 8. Índices de desempeño del modelo variando el número de neuronas en la capa oculta 49

Tabla 9. Valores lingüísticos asociados a la turbiedad 52

Tabla 10. Valores lingüísticos asociados al pH 52

Tabla 11. Valores lingüísticos asociados a la dosificación de coagulante 52

Tabla 12. Reglas para la estimación de coagulante 53

Tabla 13. Índices de desempeño del modelo Mamdani, basado en información lingüística 55

Tabla 14. Desempeño del modelo Sugeno v.s. radio del clúster 58

Tabla 15. Ubicación de los clústeres encontrados mediante *substractive clustering* 58

Tabla 16. Parámetros de la funciones de membrecía modelo Sugeno normalizado. 64

Tabla 17. Parámetros de la funciones de membrecía modelo ANFIS 64

Tabla 18. Índices de desempeño del modelo ANFIS 66

Tabla 19. Resumen índices de desempeño de los modelos obtenidos 67

Tabla 20. Características de la red neuronal auto-asociativa 4-8-3-8-4 para la validación de la información 72

Tabla 21. Errores máximos de las estimaciones de la red neuronal auto-asociativa. 72

Tabla 22. Características de algoritmo genético empleado para la reconstrucción de la información 81

Tabla 23. Rangos válidos de las variables que participan en el modelo de estimación 88

Tabla 24. Bloques de programación en el PLC 88

LISTA DE FIGURAS

pág

Figura 1. Etapas típicas del proceso de potabilización 14

Figura 2. Modelo de doble capa eléctrica 17

Figura 3. Representación esquemática de la coagulación 20

Figura 4. Concentración de coloide, expresada como concentración de superficie 20

Figura 5. Equipo de pruebas de jarras 22

Figura 6. Formato de pruebas de jarras y selección de dosis óptima 23

Figura 7. Aplicación del SCD 24

Figura 8. Mapa conceptual técnicas para la dosificación de coagulante 31

Figura 9. Redes MLP y RBF 34

Figura 10. Representación esquemática del proceso de coagulación 37

Figura 11. Histograma de los residuales con distribución normal asociada 43

Figura 12. Planos de componentes de las variables de entrada 45

Figura 13. Proceso de selección de variables de entrada al modelo 47

Figura 14. Arquitectura del modelo de redes neuronales obtenido para la dosificación de coagulante 50

Figura 15. Comparación entre la dosificación realizada por medio de pruebas de jarras y el modelo de redes neuronales 50

Figura 16. Funciones de membrecía definidas para la turbiedad – Mamdani 53

Figura 17. Funciones de membrecía definidas para el pH – Mamdani 53

Figura 18. Funciones de membrecía definidas para la dosificación – Mamdani 54

Figura 19. Superficie de salida para la estimación de la dosificación del coagulante – Modelo Mamdani 54

Figura 20. Comparación entre la dosificación realizada por medio de pruebas de jarras y el modelo Mamdani 55

Figura 21. Funciones de membrecía definidas para la turbiedad – Sugeno 59

Figura 22. Funciones de membrecía definidas para el pH – Sugeno 59

Figura 23. Funciones de membrecía definidas para la conductividad – Sugeno 59

Figura 24. Cálculo de la dosificación de coagulante mediante el sistema de inferencia difuso tipo Sugeno 60

Figura 25. Comparación entre la dosificación realizada por medio de pruebas de jarras y el modelo Sugeno 61

Figura 26. Superficie de salida para la estimación de la dosificación del coagulante – Modelo Sugeno (Conductividad constante en 205 µS/cm) 62

Figura 27. Estructura ANFIS para un sistema difuso de 2 entradas 63

Figura 28. Mapeado entrada/salida del modelo Sugeno normalizado antes de aplicar la optimización por estructura ANFIS 65

Figura 29. Mapeado entrada/salida del modelo Sugeno normalizado después de aplicar la optimización por estructura ANFIS 65

Figura 30. Comparación entre la dosificación realizada por medio de pruebas de jarras y el modelo ANFIS 66

Figura 31. Redes neuronales auto-asociativas 69

Figura 32. Comportamiento de la turbiedad y el color en el muestreo tomado para la construcción de la red neuronal auto-asociativa 70

Figura 33. Comportamiento del pH y la conductividad en el muestreo tomado para la construcción de la red neuronal auto-asociativa 71

Figura 34. Errores obtenidos entre la entrada y salida de la red neuronal auto-asociativa para un error suave 74

Figura 35. Comparación de las turbiedades obtenidas ante un error suave 75

Figura 36. Errores obtenidos entre la entrada y salida de la red neuronal auto-asociativa para un error moderado. 76

Figura 37. Comparación de las turbiedades obtenidas ante un error moderado 76

Figura 38. Errores obtenidos entre la entrada y salida de la red neuronal auto-asociativa para un error fuerte 77

Figura 39. Comparación de las turbiedades obtenidas ante un error fuerte con reconstrucción de señal mediante redes neuronales auto-asociativas 78

Figura 40. Comparación de las turbiedades obtenidas ante un error fuerte con reconstrucción de señal mediante algoritmos genéticos 82

Figura 41. Control feedforward de la dosificación de coagulante 85

Figura 42. Diagrama funcional del sistema de dosificación implementado en el PLC 89

Figura 43. Curva de descarga de la bomba dosificadora de coagulante 90

Figura 44. Pantalla 1 del sistema de dosificación 92

Figura 45. Pantalla 2 del sistema de dosificación 92

Figura 46. Comportamiento de los parámetros de calidad de agua durante la prueba 95

Figura 47. Dosis estimadas por los modelos de redes neuronales y ANFIS 95

Figura 48. Comportamiento de las descargas de las bombas calculadas para los modelos de redes neuronales y ANFIS durante la prueba 97

Figura 49. Comportamiento del sistema de dosificación y de la turbiedad del agua a la salida de los sedimentadores 98

Figura 50. Comportamiento de la turbiedad a la entrada de la planta, a la salida de los sedimentadores y en los tanques de almacenamiento (agua tratada). 99

LISTA DE ANEXOS*

Anexo 1. Base de datos para la implementación del modelo de estimación.

Anexo 2. Programas en MATLAB

Anexo 3. Base de datos para la implementación del modelo de redes neuronales auto-asociativas

Anexo 4. Datos técnicos de los equipos utilizados en el sistema.

Anexo5. Bloques de programación PLC SIEMENS 315-2 DP

*__Nota:__ *Los anexos se incluyen en medio magnético únicamente*

INTRODUCCIÓN

Los métodos utilizados para la dosificación de coagulante en el proceso de potabilización de agua incluyen, desde procedimientos de laboratorio simples como las pruebas de jarras, hasta esquemas de control avanzados que involucran modelos matemáticos no lineales en su implementación. Debido a las características no lineales de la coagulación y a una operación basada en la experiencia adquirida por los operadores de planta, la inteligencia computacional se ha convertido en una herramienta importante para el desarrollo de soluciones que buscan una operación más confiable, económica y consistente con los estándares de calidad establecidos en las regulaciones vigentes en la materia.

La presente investigación tiene como objetivo general desarrollar una propuesta que permita la automatización de la dosificación de coagulante mediante el uso de modelos basados en inteligencia computacional. Entre las técnicas estudiadas para el desarrollo de modelos se encuentran las redes neuronales, la lógica difusa y las estructuras neuro-difusas tipo ANFIS. De igual manera fueron objeto de estudio los mapas auto-organizados de Kohonen (SOM), las redes neuronales auto-asociativas (AANN) y los algoritmos genéticos principalmente para la validación de la información proveniente de los sensores de calidad de agua, cuyas variables constituyen las entradas de los modelos construidos para la estimación de la dosificación de coagulante.

El presente documento está dividido en cinco capítulos. En el primero se realiza una descripción del proceso de potabilización del agua cruda y se presenta el problema de la dosificación de coagulante en este proceso. Posteriormente se hace una revisión de los diferentes métodos utilizados hasta la fecha para la dosificación de coagulante. En el segundo capítulo, se presentan las diferentes técnicas estadísticas y de inteligencia computacional utilizadas para la selección de las variables a ser utilizadas en el desarrollo de los diferentes modelos de estimación, y en la detección de *outliers* (datos inconsistentes) en las bases de datos utilizadas para el desarrollo de los mismos. Igualmente, se explica la forma como fueron obtenidos los diferentes modelos para la estimación de la dosificación de coagulante. Las técnicas de validación de la información proveniente de los sensores se presentan en el capítulo 3. Dado que los métodos aquí desarrollados buscan ser implementados en un ambiente industrial, en el capítulo 4 se muestra la plataforma de experimentación usada para la validación de los modelos obtenidos en los capítulos anteriores. Finalmente en el capítulo 5 se presentan las conclusiones y recomendaciones de la investigación desarrollada.

1. MÉTODOS UTILIZADOS EN LA DOSIFICACIÓN DE COAGULANTE

1.1. RESEÑA HISTÓRICA

Los primeros esfuerzos para la obtención de agua apta para el consumo humano, llevaron al desarrollo de tratamientos basados en la filtración, los cuales fueron empleados ampliamente en Europa durante el siglo dieciocho. Sin embargo, estos sistemas no fueron suficientes y es así como en la segunda mitad del siglo diecinueve, se reconoció la naturaleza de las enfermedades infecciosas y se demostró la capacidad que tenían los sistemas de tratamiento y distribución de agua de la época, para transmitirlas. Como consecuencia, las investigaciones se enfocaron en los microorganismos causantes de enfermedades, presentes en los sistemas públicos de distribución de agua, llevando a la demostración de que la turbiedad no solo perjudicaba las características del agua desde el punto de vista estético, sino que las partículas causantes de esta característica podían albergar a los organismos patógenos causantes de enfermedades como el cólera, la tifoidea y la disentería. Como resultado, los sistemas de tratamiento de agua comenzaron a diseñarse para reducir la turbiedad y es así como a partir de comienzos del siglo veinte se ha venido utilizando la tecnología más ampliamente aplicada para la potabilización del agua cruda, consistente en el empleo de la coagulación, floculación, sedimentación, filtración y desinfección [1].

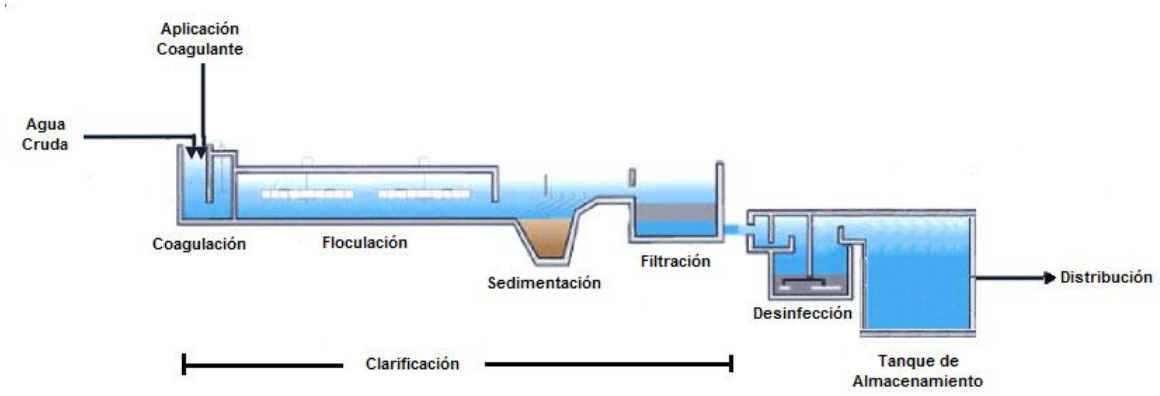
1.2. EL PROCESO DE POTABILIZACIÓN DEL AGUA Y LA COAGULACIÓN

Como se mencionó anteriormente, la obtención de agua potable, en su forma tradicional, implica el uso completo o parcial de cuatro sub-procesos denominados coagulación, floculación, sedimentación y filtración, los cuales conforman la etapa de clarificación del

agua cruda (ver figura 1). Posterior a esta primera etapa, se encuentra la desinfección y de requerirse, las etapas de acondicionamiento químico y organoléptico.

El agua cruda, al iniciar el proceso de potabilización, ingresa con un nivel de turbiedad determinado principalmente por la concentración de partículas coloidales con que cuente. Estas partículas presentan, generalmente, una carga superficial negativa que impide su aglomeración. Dichas cargas son neutralizadas mediante la adición del coagulante el cual aporta iones positivos a la mezcla. Este proceso es muy rápido, toma desde décimas de segundo hasta cerca de 100 segundos, dependiendo de las condiciones del agua, y se lleva a cabo en una unidad de tratamiento denominada mezcla rápida. Posterior a la coagulación, el agua se agita de forma relativamente lenta en una unidad denominada floculador, en la cual como consecuencia de la neutralización de las cargas negativas de las partículas coloidales y de la agitación lenta, se genera un proceso de aglomeración para formar partículas de mayor tamaño llamados *flocs*. Finalmente, durante la sedimentación, las partículas de mayor tamaño son removidas por efecto de la gravedad, mientras que las partículas restantes son removidas mediante el paso del agua sedimentada a través de los filtros. La etapa restante corresponde a la desinfección, la cual se requiere para la eliminación de los organismos patógenos que pueden estar presentes en el agua filtrada y para evitar su posible reproducción en las redes de distribución.

Figura 1. Etapas típicas del proceso de potabilización



FURNESS, R. Water Production and Supply - Measurement and Control Strategies [2]

La neutralización de las cargas eléctricas de las partículas coloidales, durante la coagulación, se logra mediante la adición principalmente de sales de hierro y aluminio (coagulante), con el fin de favorecer su remoción en los restantes procesos de la

clarificación. La calidad y los costos del agua obtenida al final del proceso dependen en gran parte de la dosificación del coagulante. Un exceso en la dosificación eleva los costos de producción, mientras que una dosificación por debajo de la requerida puede llevar a la obtención de agua que no cumpla con los parámetros de calidad exigidos por la legislación respectiva y a una operación menos eficiente de la planta. Por tanto, una correcta dosificación de coagulante es fundamental para que las demás etapas del proceso de potabilización funcionen apropiadamente.

Con el fin de entender la naturaleza de la turbiedad del agua cruda y comprender las razones por la cuales la coagulación es requerida dentro del proceso de potabilización, a continuación se describen las propiedades de las partículas coloidales.

1.2.1. Partículas coloidales [4].

Las partículas coloidales en el agua, presentan por lo general un diámetro entre 1 y 1000 milimicrómetros y sus propiedades pueden dividirse en cinéticas, ópticas, de superficie y electrocinéticas.

1.2.1.1. Propiedades cinéticas: Son las que definen el comportamiento de las partículas coloidales referidas a su movimiento en el agua. Entre ellas encontramos el movimiento browniano, la difusión y la presión osmótica. Estas propiedades explican el movimiento constante e irregular de los coloides en el agua, su dispersión por todo el sistema hídrico y su comportamiento en presencia de membranas semipermeables, el cual en la práctica se utiliza para estimar de manera experimental el número de partículas y su peso promedio en sistemas coloidales.

1.2.1.2. Propiedad óptica: Mediante el efecto *Tyndall-Faraday* se explica la capacidad de dispersar la luz que tienen las partículas coloidales. Esta dispersión es directamente proporcional a su tamaño. La determinación nefelométrica de la turbiedad utiliza el efecto de *Tyndall-Faraday* para su medición.

1.2.1.3. Propiedad de superficie: Dependiendo del tamaño de las partículas coloidales, estas pueden demorarse en sedimentar desde varios cientos de días hasta varios años. Esto explica porque no resulta práctico sedimentar este tipo de partículas sin tratamiento químico previo (coagulación). La razón de este comportamiento se debe a la gran superficie específica que presentan las partículas coloidales, la cual se define como la relación entre el área superficial y la masa.

1.2.1.4. Propiedad electrocinética: Las partículas coloidales presentan carga eléctrica y para describir su interacción con los iones que se encuentran a su alrededor se suele emplear el modelo de doble capa eléctrica.

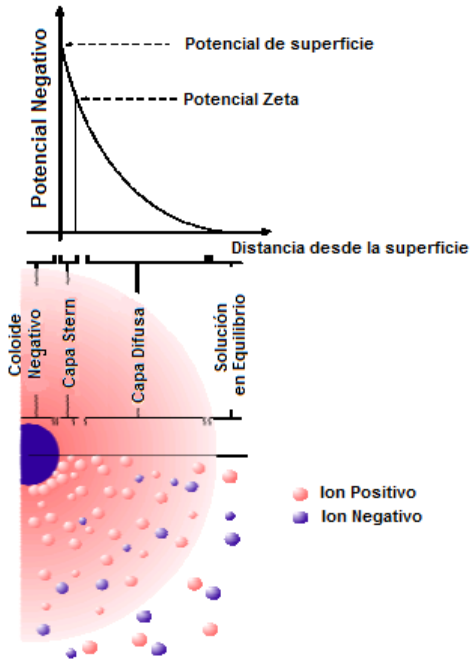
Para propósitos ilustrativos (ver figura 2) se asumirá un coloide cargado negativamente. Cerca a la superficie negativa existe una capa de iones positivos fuertemente unidos, conocida como la capa *Stern*. Iones positivos adicionales continúan siendo atraídos por el coloide pero son repelidos por la capa *Stern*. De la misma forma, los iones negativos son atraídos por los iones positivos pero repelidos por el coloide. El equilibrio dinámico de iones positivos y negativos produce una capa exterior a la capa de *Stern*, denominada capa difusa. La concentración de iones positivos en la capa difusa gradualmente decrece a medida que la distancia al coloide se incrementa hasta una distancia tal que la concentración de iones es la misma y se equilibra el agua [3].

El espesor de estas capas depende de la concentración de iones en la solución. A una distancia dada de la superficie la densidad de carga es igual a la diferencia entre la concentración de iones positivos y negativos a esa distancia. Esto resulta en un potencial eléctrico (voltaje causado por la separación de cargas) existente a través de las capas. Este potencial es máximo cerca a la superficie del coloide y decrece a cero a medida que la distancia al coloide aumenta.

El potencial en la frontera entre la capa *Stern* y la capa difusa es llamado el potencial zeta. El potencial zeta es útil, ya que es una indicación directa de la cantidad de energía requerida para unir dos partículas coloidales separadas. En condiciones de estabilidad, este potencial se encuentra del orden de 30 a 40mV. Cuando éste cae a menos de 15 o 20mV, es posible la coagulación y el coloide tiende a sedimentar. La medición del potencial zeta tiene aplicaciones en estudios de laboratorio de la coagulación y la floculación, pero es poco utilizada para la automatización en línea [3].

El hecho de que las partículas coloidales tengan carga eléctrica (por lo general negativa, causando repulsión entre ellas) se constituye en el factor principal de la estabilidad de los sistemas coloidales. Entre los factores que influyen en la desestabilización del sistema coloidal encontramos la gravedad (insignificante en la mayoría de los casos), el movimiento browniano (permite que las partículas entren en contacto) y las fueras de *Van der Walls*. Las fuerzas de *Van der Walls* son fuerzas débiles de origen eléctrico, siempre atractivas, que decrecen rápidamente con la distancia entre las partículas. En un sistema coloidal, en condiciones normales, primaran los factores que favorecen la repulsión de las partículas (estabilización) sobre los que favorecen su atracción (desestabilización).

Figura 2. Modelo de doble capa eléctrica



EDNEY, Daniel. Introduction to the Theory of the Streaming Current Meter [3]

1.2.2. Mecanismos de coagulación

La coagulación mediante sales inorgánicas se produce predominantemente por medio de dos mecanismos, la neutralización de la carga y la coagulación por barrido.

La neutralización de la carga se presenta principalmente cuando la cantidad de coloides presentes en el agua es alta. Bajo estas condiciones la distancia entre las partículas es pequeña al igual que su potencial zeta, por lo cual la energía requerida para su desestabilización es menor. Al agregar el coagulante (sulfato de aluminio o sales de hierro) se forman un conjunto de especies hidrolizadas las cuales se adhieren al coloide, desestabilizándolo y permitiendo la formación de *flocs*. Este mecanismo de coagulación se conoce también como coagulación por adsorción.

Por su parte, en la coagulación por barrido, la cual es propia de aguas claras con porcentajes bajos de coloides, se presenta cuando se aplican dosis suficientemente altas de coagulante formando un precipitado de hidróxido de aluminio el cual físicamente

arrastra a las partículas coloidales. Debido a que la distancia entre las partículas es mayor, las fuerzas de atracción son menores y se requiere mayor cantidad de coagulante y energía para desestabilizarlas.

1.2.3. Factores que influyen en la coagulación

En [4], la Organización Panamericana de la Salud (OPS) y su agencia especializada, el Centro Panamericano de Ingeniería Sanitaria y Ciencias del Ambiente (CEPIS), identifican los factores que tienen mayor incidencia en la coagulación. Estos son la calidad del agua cruda (en términos de la turbiedad, alcalinidad, pH, temperatura y tamaño de las partículas) y las variables químicas (dosis óptima y pH óptimo).

De acuerdo a este documento, la eficiencia de la coagulación mejora al aumentar la temperatura cuando esta se encuentra en el rango de 10°C – 40°C. En este rango son importantes la turbiedad y la alcalinidad tal como se verá más adelante. Por su parte para aguas con color se sugiere un pH óptimo entre 4 y 6, mientras que para aguas con mayor turbiedad el rango de pH óptimo se establece entre 6,5 y 8,5.

Finalmente, con base a lo expuesto en [4] se describe a continuación, la forma cómo influyen en la coagulación los demás factores antes mencionados.

1.2.3.1. Concentración del coloide, alcalinidad y pH: Dependiendo de la concentración de coloides, y de la alcalinidad del agua es posible identificar cuatro situaciones diferentes.

- *Alta concentración de coloides y alcalinidad baja:* Es el sistema más fácil de tratar, ya que solo se debe determinar un parámetro químico: la dosis óptima de coagulante. El mecanismo de coagulación predominante es la adsorción de especies hidrolíticas con carga positiva.

- *Alta concentración de coloides y alcalinidad alta:* En este caso, la desestabilización se realiza nuevamente por medio de adsorción. La neutralización de la carga es sencilla, debido a que el pH permanece generalmente en la región neutral, donde los polímeros de hidróxidos metálicos no tienen carga muy alta.

- *Baja concentración de coloides y alcalinidad alta: La* coagulación se realiza en este caso con una dosis de coagulante relativamente alta para capturar las partículas coloidales. Como alternativa, se puede agregar arcilla o bentonita, para aumentar la concentración coloidal y el contacto interparticular. La desestabilización se realizaría, en este caso, mediante la adsorción y la neutralización de la carga.

- *Baja concentración coloidal y alcalinidad baja:* En estos sistemas la coagulación es más difícil. La coagulación por medio de captura se dificulta, ya que el pH disminuye al agregar el coagulante y no permite la formación de hidróxidos. Asimismo, la coagulación por medio de adsorción también es difícil, ya que la concentración coloidal es demasiado baja para permitir el contacto interparticular. Para realizar una coagulación efectiva, deberá agregarse alcalinidad adicional y/o bentonita o preferentemente arcilla.

1.2.3.2. Dosis óptima: En la figura 3, se presentan cuatro curvas de variación de la turbiedad residual en función de la dosificación de coagulante con pH constante. Estas curvas están basadas en aguas naturales tratadas con sales de aluminio o hierro, que contienen grandes concentraciones de material coloidal (S4>S3>S2>S1). Las curvas de coagulación pueden dividirse en cuatro zonas:

- La zona 1 corresponde a dosis bajas, donde se ha agregado coagulante en cantidad insuficiente para realizar la desestabilización.

- La zona 2 corresponde a dosis un poco más altas, donde se realiza la desestabilización y el *floc* precipita.

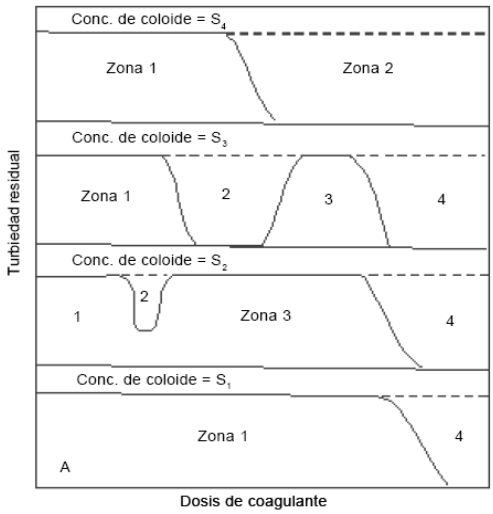
- La zona 3, donde dosis aún más altas pueden re-estabilizar las dispersiones con ciertos valores de pH.

- La zona 4, donde la gran cantidad de hidróxido de aluminio (o hierro), actúa de tal forma que captura las partículas coloidales (coagulación de barrido).

En la figura 4 puede observarse como a concentraciones bajas de coloide (S1) la coagulación solo es posible con la aplicación de grandes cantidades de coagulante que permitan la formación de *flocs* de barrido. Para mayores concentraciones de coloide (S2 y S3), se necesitan menores dosis de coagulante que en el caso S1, debido a que el mecanismo predominante de coagulación es el de adsorción (neutralización de la carga).

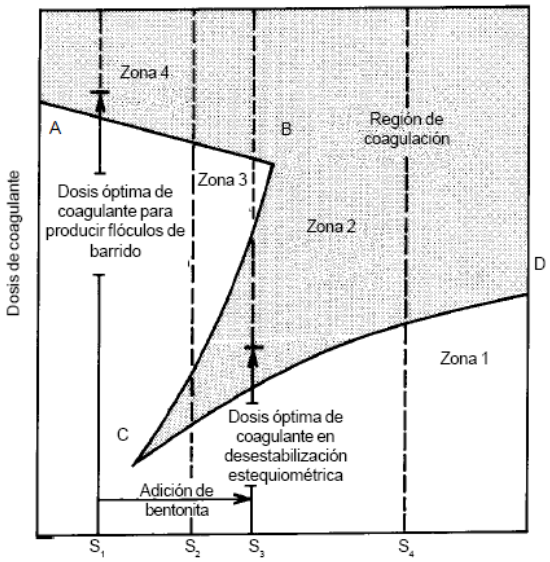
En general, la dosis química requerida depende del mecanismo de desestabilización empleado. Por ejemplo, en la línea AB de la figura 4, que representa los casos de turbiedades bajas, se observa como la dosis requerida para lograr la desestabilización de las partículas coloidales tiende a disminuir a medida que la concentración del coloide aumenta, ya que el fenómeno predominante en esta región es la coagulación por barrido (zona 4).

Figura 3. Representación esquemática de la coagulación.



CENTRO PANAMERICANO DE INGENIERÍA SANITARIA Y CIENCIAS DEL AMBIENTE. Tratamiento de agua para consumo humano, plantas de filtración rápida Manual I: Teoría, Capítulo 4: Coagulación [4]

Figura 4. Concentración de coloide, expresada como concentración de superficie



CENTRO PANAMERICANO DE INGENIERÍA SANITARIA Y CIENCIAS DEL AMBIENTE. Tratamiento de agua para consumo humano, plantas de filtración rápida Manual I: Teoría, Capítulo 4: Coagulación [4]

Para el caso de la línea CD, que representa los casos de turbiedades altas, las dosis requeridas para lograr la desestabilización es generalmente más baja que en el caso de la turbiedades bajas (línea AB) y tiende a aumentar a medida que la concentración de coloides se incrementa. Este comportamiento se debe a que el fenómeno predominante de desestabilización es el de adsorción (zona 2). Las aguas de baja concentración de coloide pueden ser coaguladas mediante la adición de partículas de arcilla (bentonita), para aumentar la turbiedad antes de inyectar el coagulante, lo cual disminuye la cantidad de coagulante requerido al realizarse el proceso en la zona 2, en la cual predomina el mecanismo de adsorción sobre el de barrido. Al aumentar la concentración de coloide, la zona 3 de re-estabilización disminuye y se alcanza una concentración en la cual es imposible realizar la re-estabilización con sobredosis de coagulante.

Como se observa la dosis óptima de coagulante a ser aplicada en un sistema de potabilización de agua, depende de una gran cantidad de factores químicos y físicos, y su determinación ha llevado a la implementación de una cantidad considerable de métodos los cuales incluyen desde pruebas de laboratorio sencillas hasta la implementación de complejos sistemas de control, probados con éxito en plantas piloto principalmente.

A continuación se describirán los métodos tradicionales que se han empleado para la determinación de la dosificación de coagulante, entendiéndose como tradicionales en este contexto, todos aquellos métodos que no han hecho uso de técnicas de inteligencia computacional. Posteriormente, se trataran las metodologías y trabajos realizados mediante la utilización de la inteligencia computacional.

1.3. MÉTODOS TRADICIONALES PARA LA DETERMINACIÓN DE LA DOSIS DE COAGULANTE

La prueba de jarras y el *streaming current detector* (SCD) son dos de las principales técnicas por medio de las cuales se ha determinado la dosificación de coagulante. La prueba de jarras, es la más antigua de ellas y es la más utilizada aún en nuestros días por su sencillez, confiabilidad y capacidad de adaptarse a un amplio rango de condiciones y escenarios. El *streaming current detector* se popularizó a mediados de los noventa y continúa ganando espacio a pesar de ciertas limitaciones de funcionamiento detectadas. Otros métodos utilizados para la determinación de la dosis de coagulante, incluyen los modelos matemáticos, los cuales tuvieron sus primeros reportes en 1990 y aunque parecían opacados por los modelos basados en redes neuronales, han recobrado un nuevo interés en la actualidad, principalmente en Australia. Igualmente existen reportes de la utilización de equipos de analizadores de partículas para determinación del tamaño del *floc* y sistemas basados en análisis espectral, capaces de operar en un esquema de control tipo *feedforward.*

1.3.1. Prueba de Jarras

La determinación de la dosis óptima de coagulante, históricamente ha implicado la realización de una prueba de laboratorio conocida como prueba de jarras. Dicha prueba consiste en tomar una muestra del agua cruda a ser tratada y depositarla en varias jarras, a las cuales se les aplica diferentes dosis de coagulante, el cual es mezclado a velocidades iguales en cada uno de los recipientes. Al final de la prueba, después de un periodo de aquietamiento, la dosis que entregue menor turbiedad residual, será seleccionada como la dosis óptima (ver figuras 5 y 6). Si bien la prueba de jarras es un método ampliamente utilizado en plantas de potabilización, tiene como desventajas principales la fuerte intervención humana en el proceso (con la posibilidad de error asociada y la dependencia de la experiencia del operador) y la baja capacidad de respuesta ante cambios bruscos en las características del agua cruda, debido al tiempo que toma realizar una prueba de este tipo. En promedio una prueba de jarras puede tomar de 30 a 40 minutos.

Los cambios bruscos en la calidad del agua cruda, especialmente en cuanto a la turbiedad se refiere, son característicos de las plantas de potabilización alrededor del mundo que toman el agua de fuentes superficiales como ríos o pequeños reservorios [5][6].

Figura 5. Equipo de pruebas de jarras



Figura 6. Formato de pruebas de jarras y selección de dosis óptima

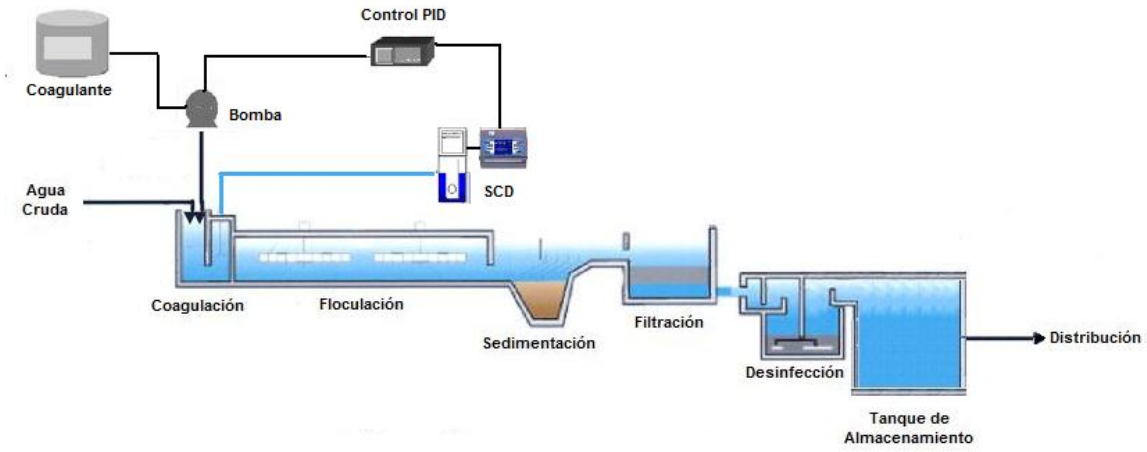
			HORA 1:	07 : 30 Q = 65,57 LTS / SEG				
			1	2	3	4	5	6
DOSIS A APLICAR (mg/l)	SULFATO LIQUIDO B		40	45	50	55	60	65
	SULFATO LIQUIDO A							
	CLORURO FERRICO							
	CAL PRIMARIA							
	CAL SECUNDARIA							
	CARBON ACTIVADO							
	POLIMERO							
APARICION DEL FLOCULO (minutos)			1,00	1,00	1,00	0,50	0,50	0,50
CALIDAD DEL FLOCULO INDICE DE WILCOMB	5,0	MINUTOS	A	A	B	B	B	B
	10,0	MINUTOS	A	A	B	B	B	B
	15,0	MINUTOS	A	B	B	B	B	B
ASPECTOS DEL SOBRENADANTE			CLARO	CLARO	CLARO	CLARO	CLARO	CLARO
TURBIEDAD RESIDUAL U.N.F.			5,50	3,99	3,60	2,90	2,75	3,40
COLOR RESIDUAL U.P.C.			11,60	8,20	7,60	6,50	6,20	6,60
ALCALINIDAD RESIDUAL mg/L							66,00	
pH RESIDUAL							6,90	

Informes diarios de operación planta de potabilización del municipio de Roldanillo (Valle)

1.3.2. *Streaming Current Detector*

El *streaming current detector* (SCD), es un instrumento cuyo funcionamiento está basado en la medición de las cargas eléctricas en el agua y permite el control automático de la dosificación de coagulante usando técnicas de control lineal relativamente sencillas como controladores PID (ver figura 7). Si bien las bases para el desarrollo del SCD fueron sentadas desde mediados de la década de los sesenta, su uso no comenzó a ser comercial hasta la década de los años ochenta [3]. En el año de 1989 se realiza una investigación [7], en la cual se reportan las ventajas de la utilización del SCD en la dosificación de coagulante, las cuales incluyen mejoramiento general de la calidad y consistencia del agua potable obtenida y disminución entre 12% y 23% en la cantidad de coagulante utilizada, respecto a la consumida mediante la utilización de pruebas de jarras. Es así como su uso se masifica y en 1995 se reportan más de 1000 unidades en funcionamiento en Norteamérica y Europa [8]. Con la masificación del uso del SCD, algunas limitaciones comenzaron a notarse en su funcionamiento, entre ellas, la necesidad de emplear pruebas de jarras para estimar su punto de operación óptimo. Este procedimiento debe realizarse durante la puesta en marcha del equipo [9], y aunque en teoría no debe ser un procedimiento muy complicado, existen reportes que indican la obtención de dicho punto óptimo después de 12 meses de operación [10].

Figura 7. Aplicación del SCD



De igual manera, si durante la operación del equipo se presentan cambios en el pH del agua cruda o en la naturaleza de las partículas que causan la turbiedad (por ejemplo, por el cambio del tipo de fuente que se ingresa a la planta de potabilización, o por crecientes que arrastren material que cambie las características de las partículas coloidales responsables de la turbiedad) se hará necesario correr una nueva prueba de jarras para determinar el punto óptimo de dosificación bajo las nuevas condiciones de operación y ajustar un nuevo *set-point* para el SCD. Cambios de este tipo, en la calidad del agua, son frecuentes en plantas que cuentan con varias fuentes disponibles para su abastecimiento.

Teniendo en cuenta estas limitaciones, varios autores han desarrollado sistemas híbridos en los que se busca mejorar el control de la dosificación de coagulante basada en SCD mediante la inclusión de modelos matemáticos en los esquemas de control. En ese sentido, en 1996, se plantea un control más robusto mediante la implementación de un modelo que relacione la salida del SCD con los cambios de pH en el agua cruda [5] y en 2005 se presenta una tesis de doctorado en la que se describen varias formas de optimizar la dosificación de coagulante mediante el uso del SCD y de modelos matemáticos incorporados en varios esquemas de control lineales y no lineales, varios de los cuales están basados en redes neuronales [11].

Otro aspecto a considerar en el uso del SCD lo constituye el desgaste de sus mecanismos internos de sensado, los cuales pueden llevar a una distorsión de la señal de salida del instrumento. Dicha anormalidad, no siempre es posible de detectar por simple inspección del equipo y por tanto puede llevar a dudas sobre el estado real de funcionamiento de un equipo en particular [3].

1.3.3. Modelos Matemáticos

En 1990 se presentan un artículo en el que se describen tres posibles esquemas de control automático, el primero de ellos tipo *feedforward*, y dos tipo *feedback*, uno de ellos basado en las características del agua tratada y el otro basado en las características del agua coagulada [16]. Para la prueba de estos esquemas se emplea un modelo matemático lineal dependiente del color coloidal, la turbiedad, temperatura, pH y conductividad. Si bien en el artículo se plantea que en pruebas preliminares el modelo funciona adecuadamente, también advierte sobre la necesidad de más pruebas para aceptar su aplicación de forma más amplia. De hecho el artículo parece favorecer más la implementación de esquemas de control basados en SCD, entre otras razones porque para la época no se contaba con medidores en línea lo suficientemente confiables para la medición de los diferentes parámetros de calidad del agua que intervienen en los modelos. En [17] se mencionan otros trabajos donde se desarrollan modelos matemáticos para la dosificación de coagulante en la década de los noventa, sin embargo la bibliografía disponible es muy inferior a la encontrada para modelos basados en inteligencia computacional de la misma época, muy probablemente debido al reconocimiento de las relaciones altamente no lineales entre las diferentes variables que intervienen en el proceso de coagulación y que pueden ser mejor tratadas mediante el uso de las técnicas de inteligencia computacional.

A pesar de lo anterior, cabe anotar que actualmente en Australia existe un marcado interés en el desarrollo de modelos matemáticos, por encima del uso de modelos basados en inteligencia artificial. Es así, como en busca de modelos más explícitos que permitan identificar de manera más precisa las relaciones de las variables que intervienen en la coagulación y que funcionen bajo el concepto de coagulación enriquecida (*enhanced coagulation*) la cual busca maximizar la remoción de materia orgánica durante el proceso de potabilización (disminuyendo así los productos derivados de la desinfección) el *Cooperative Research Centre for Water Quality and Treatment* ha desarrollado un gran número de estudios a nivel de laboratorio y plantas pilotos para la consecución de dichos modelos [17], [18] y [19].

1.3.4. Analizadores de partículas.

En [35] se presenta un sensor desarrollado en Japón que determina el tamaño del *micro-floc* formado justo después de la aplicación del coagulante en la mezcla rápida, basándose en la diferencia de la intensidad de luz recibida, después de enviar dos haces con diferente longitud de onda (una cercana al espectro infrarrojo y la otra a la luz ultravioleta) a través de la muestra de agua. Teniendo en cuenta que el tamaño de este *micro-floc* está

fuertemente relacionado con el tamaño del *floc* al final del proceso de floculación y a su vez este tamaño de *floc* determina en gran medida la calidad del agua al final de la sedimentación, su medición es utilizada como dato básico para la realimentación del sistema de control encargado de la dosificación de coagulante aplicada al proceso. Debido a los retardos de tiempo encontrados entre la aplicación del coagulante y la formación del *micro-floc* y al retardo de tiempo propio del instrumento de medición del tamaño del *micro-floc*, fue necesario implementar un sistema de control predictivo basado en un modelo de primer orden con retardo, para la obtención de la dosificación de coagulante por parte del sistema de control. También se realizaron pruebas implementando un control tipo PI en vez de un control predictivo pero los resultados obtenidos fueron muy inferiores a los obtenidos con control predictivo. Finalmente, el sistema fue probado en primer lugar en una planta piloto que se abastecía del rio Toyohira y posteriormente en una planta real con capacidad de 40000 m3/día. Los resultados obtenidos en este artículo están más orientados a resaltar la capacidad que tiene el sistema de mantener el tamaño del *micro-floc* en un valor determinado, mediante la manipulación de la dosis de coagulante, pero no es claro en cuanto a la definición de un procedimiento que permita la determinación de un tamaño de *micro-floc* óptimo para la obtención de agua tratada con las características deseadas.

1.3.5. Análisis espectral

A partir del año 2006, el fabricante austriaco *s::can* presenta el sistema *com::pass* el cual a diferencia del *streaming current detector*, funciona en un esquema de control tipo *feedforward*, el cual permite estimar la dosificación de coagulante a partir de las mediciones de calidad del agua obtenidas mediante el análisis espectral del agua cruda a ser tratada. Entre las ventajas que el fabricante menciona, respecto a otros métodos de dosificación, se encuentra la posibilidad de seleccionar dos modos de operación, convencional (máxima reducción de turbiedad) y enriquecido (máxima reducción de materia orgánica). Además, dependiendo del modo de operación escogido se pueden obtener beneficios adicionales como reducción en los costos de operación, reducción en la formación de sub-productos de la desinfección, e independencia de funcionamiento respecto a condiciones operativas tales como flujo de entrada a la planta, pH de coagulación y condiciones de la mezcla de coagulante, las cuales normalmente afectan a los sistemas de dosificación basados en el SCD.

Si bien las características de este equipo, se acercan a las ideales en un sistema de dosificación de coagulante, cabe anotar que solo se encontraron dos reportes independientes que parecen confirmar los beneficios que por lo menos respecto al ahorro en la utilización de coagulante menciona el fabricante. Estos corresponden a informes realizados en Wellington, Nueva Zelandia en las plantas de potabilización de Te Marua y

Wainuiomata [12] [13]. La demás información disponible proviene del fabricante y/o sus distribuidores [14][15].

1.4. MÉTODOS BASADOS EN INTELIGENCIA ARTIFICIAL PARA LA DETERMINACIÓN DE LA DOSIS DE COAGULANTE

En trabajos como [20], [21], [22] y [23] para mencionar solo algunos, se ha resaltado la dependencia existente entre la dosificación de coagulante requerida para la correcta potabilización del agua y variables tan diversas como la turbiedad, el pH, la temperatura, la alcalinidad, la conductividad y el color del agua cruda. Además de la dependencia de esta gran cantidad de parámetros, la relación de la rata de dosificación de coagulante con cada uno de ellos es altamente no lineal [23], lo cual, a finales de la década de los noventa y principios del siglo XXI popularizó el uso de las herramientas de inteligencia computacional para resolver el problema de la dosificación de coagulante. La técnica más utilizada ha sido las redes neuronales, pero también se reportan trabajos que utilizan lógica difusa y modelos neuro-difusos tipo ANFIS.

1.4.1 Redes Neuronales

El control de la dosificación de coagulante por medio de la utilización de redes neuronales implica la construcción de un modelo de estimación, el cual puede o no ser incluido dentro de esquemas de control avanzados.

El primer trabajo, que emplea redes neuronales para la dosificación de coagulante, del cual se tiene información, data de 1995 y fue desarrollado con datos operativos de la planta de potabilización de Wyong en Australia [20]. Los modelos desarrollados alcanzaron porcentajes de error promedios muy bajos, lo cual demostraba la idoneidad de esta técnica para resolver el problema de la dosificación planteado. El modelo predictivo desarrollado en dicha investigación no se incorporó a ningún esquema de control avanzado y se constituía básicamente en una herramienta que ayudaba al operador de planta a tomar decisiones respecto a la dosificación de coagulante. En este mismo sentido se encontraron otros trabajos en los que se desarrollaban herramientas de apoyo similares tales como las reportadas en [21], [22], [24], [25] y [26]. Dichos trabajos desarrollados entre 1999 y 2008 si bien perseguían el mismo objetivo, predecir la dosificación de coagulante, presentaban ciertas particularidades en su implementación. Por ejemplo, en [21] se incluye un bloque de reconstrucción y validación de los datos provenientes de los sensores de calidad de agua que sirven de entrada al modelo de estimación de coagulante que emplea mapas de Kohonen, bajo el concepto de “software

sensor". En [24] el modelo de predicción implementado, era un modelo directo, contrario a los modelos inversos planteados en [20], [21], [22], [25], [26], [36] y [37]. La diferencia entre modelos inversos y directos se trata en detalle en el apartado 2.2.3 del presente documento.

En [25] el modelo inverso de predicción de coagulante, es utilizado en conjunto con otros modelos directos para la implementación de dos herramientas de simulación denominadas *Sim TTP* y *Sim WT*, las cuales además de permitir la estimación de coagulante, hacían posible el entrenamiento de los operadores de planta, mediante la implementación de modelos capaces de predecir los parámetros de calidad del agua tratada basándose en los parámetros de calidad del agua cruda y la dosificación de coagulante aplicada. Otra diferencia marcada de este trabajo es que las muestras de agua a partir de las cuales se obtuvieron los datos con los que se implementaron los modelos, no provenían de una única fuente que abastecía una planta de potabilización en particular, sino que correspondían a muestras de agua provenientes de 14 sitios diferentes, en el sur de Australia, incluyendo arroyos, ríos, humedales y reservorios. En [26] se desarrollan 17 modelos, varios de ellos del tipo auto-predictivo, que basan su estimación únicamente en las dosificaciones pasadas, y comparan su desempeño respecto a los otros modelos que basan su predicción en los parámetros de calidad del agua cruda y que pueden incluir o no dosificaciones pasadas. Este trabajo incluye también comparaciones de desempeño de los modelos neuronales con modelos basados en estructuras ANFIS. El trabajo reseñado en [22] presenta como mayor novedad respecto a los estudios anteriores la inclusión de la turbiedad del agua sedimentada dentro de las variables de entrada del modelo, lo cual en teoría podría permitir la utilización del mismo para reducir costos de operación. Finalmente en [27], se presenta una metodología para el desarrollo de modelos de estimación de coagulante, la cual se centra en el pre-procesamiento de los datos y en la eliminación de datos erróneos (*outliers*) para mejorar la tasa de aprendizaje y la capacidad de predicción de los modelos.

Otra línea de trabajo dentro de la estimación de la dosificación de coagulante, basándose en redes neuronales, la constituyen los modelos que se incluyen dentro de esquemas de control avanzados. En este sentido en 1996 se planteó en Corea del Sur un esquema de control basado en un modelo directo de redes neuronales y un algoritmo de optimización para la dosificación en línea de coagulante en una planta de potabilización de la ciudad de Seúl con capacidad para el tratamiento de 1.320.000 ton/día [28]. Posteriormente en 1997 este trabajo fue replanteado y es así como en esta segunda versión, un poco más simplificada, se incluyeron dos modelos inversos uno neuronal (para turbiedades altas) y otro difuso (para turbiedades bajas) que estimaban directamente la cantidad de coagulante a dosificar (prescindiendo del algoritmo de optimización) y dicho resultado a su vez servía como *set-point* a un lazo de control PID que controlaba la bomba dosificadora [29]. En 2002, se realiza un completo estudio en la planta piloto EPCOR, localizada en Alberta (Canadá) la cual arroja como resultado el desarrollo de 5 modelos

integrados a un sistema de control avanzado el cual permitía mantener la turbiedad del agua tratada en un valor requerido, mediante el control automático de la dosificación de coagulante, dosificación de polímero y caudal de entrada a la planta, en respuesta a cambios en las características del agua cruda [23]. Si bien se obtuvieron excelentes resultados con el sistema de control implementado, cabe anotar que se lograron en una planta piloto donde fue posible realizar maniobras para la adquisición de datos que difícilmente podrían realizarse en una planta real. En China, en los años 2002 [30] y 2004 [31] se presentan dos artículos donde se desarrollan modelos basados en redes neuronales tipo perceptron multicapa (*MLP*, por sus siglas en inglés) y de base radial (*RBF*, por sus siglas en inglés) respectivamente, en los cuales se plantea la posibilidad de introducir dichos modelos en esquemas de control predictivo de lazo cerrado, los cuales de acuerdo a lo descrito en [30] cuentan con capacidades de auto-aprendizaje bastante fuertes. Aunque no se cuenta con mayores detalles de la implementación de estos dos trabajos, se referencian por ser marcadamente diferentes a los trabajos desarrollados en los demás países.

Como se menciono anteriormente, otro aspecto en el que se emplean las redes neuronales para la solución del problema de dosificación, es en la validación y reconstrucción de los datos provenientes de los sensores, los cuales constituyen las entradas de los modelos de estimación. Además del trabajo reseñado en [21] donde se emplean mapas de Kohonen para este propósito, en [32] y [33] se emplean las redes neuronales auto- asociativas para la validación y reconstrucción de la información.

1.4.2. Lógica difusa

En [29], publicado en 1996, para resolver el problema de la dosificación de coagulante se consideraron dos condiciones de operación denominadas normales y anormales. La primera corresponde a condiciones de operación donde la turbiedad del agua cruda era menor o igual a 30 unidades nefelométricas de turbiedad (*NTU*, por sus siglas en ingles), mientras que turbiedades superiores a este valor determinaban condiciones anormales. Para la condición anormal, se desarrollo un modelo basado en redes neuronales el cual determinaba la dosificación de coagulante a emplear. Para cumplir esta función en la condición normal se desarrollo un modelo de inferencia difuso. Para la determinación de los parámetros que definían las funciones de membrecía (centro y ancho izquierdo y derecho del triangulo) se emplearon algoritmos genéticos. En este mismo sentido en [38] se utiliza el problema de la dosificación de coagulante para verificar la efectividad de los algoritmos genéticos en la optimización de la construcción de modelos lingüísticos basados en un tipo especial de *clustering* denominado CFCM (*Contex-based fuzzy C-Means*). En 2010, este mismo autor trabaja en un artículo [39] en el cual se presenta una metodología para construir redes neuro-difusas adaptativas del tipo QANF (*Quantum-*

Based Adaptive Neuro-Fuzzy Networks) y nuevamente el problema de la dosificación de coagulante es tomado para verificar las excelentes características que en cuanto a precisión y generalización presenta los modelos obtenidos mediante este tipo de redes neuro-difusas, respecto a otros modelos basados en redes neuronales, regresiones lineales y otros tipos de modelos lingüísticos.

En [40] se presenta un sistema de inferencia difusa el cual no solo incluye variables del agua cruda como entradas del modelo, sino también la turbiedad del agua tratada y la señal proveniente de un analizador de dispersión fotométrico [42], de características similares al presentado en [35] el cual mide el tamaño del *floc* después de la floculación. El modelo obtenido en este artículo fue probado en la planta de potabilización de la ciudad de Harbin en China con capacidad de 400 l/min. Aunque a primera vista este modelo es incorporado dentro de un sistema de lazo cerrado (las señales del sensor óptico que mide el tamaño del *floc* y del sensor de turbiedad del agua tratada cierran el lazo), dicho modelo no es adaptativo en línea y tal como lo indica el autor dicho modelo requiere de la actualización continua de la base de reglas durante su uso a fin de mejorar el desempeño del sistema de control.

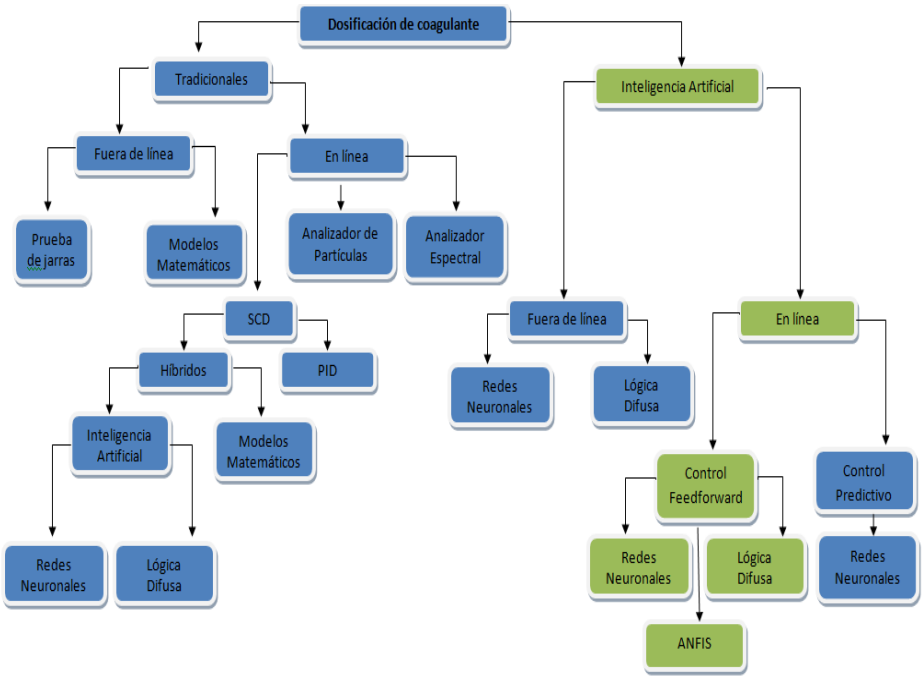
Finalmente a nivel local en [41] la Universidad de los Andes presenta una aplicación de control difuso para la dosificación de coagulante en la planta Wiesner que provee cerca del 70% del agua consumida en la ciudad de Bogotá. El modelo desarrollado tiene como entradas el error entre la señal de salida deseada de un *streaming current detector* y su señal real, la desviación de este error y la turbiedad del agua cruda. El modelo se construyó con base en la información entregada por expertos en operación de la planta y se obtuvieron un total de 175 reglas como base del conocimiento del modelo desarrollado. Tal como lo manifiestan los autores, el modelo desarrollado constituye un trabajo preliminar y varios de los supuestos utilizados en el desarrollo del modelo requieren de estudios posteriores para su validación o replantamiento.

1.4.3 Estructuras ANFIS

De acuerdo con lo descrito en [34], con la arquitectura ANFIS se busca superar una limitación que tienen los modelos de lógica difusa en cuanto a la definición de las reglas *if-then* para el caso de la dosificación de coagulante, debido a la poca regularidad que se puede encontrar en las variables que intervienen en la dosificación. Sin embargo, este mismo artículo señala la problemática del crecimiento exponencial de las reglas *if-then* con el número de entradas utilizadas en el modelo. El gran numero de reglas generadas, supera en algunos casos al número de datos disponibles para el entrenamiento del modelo lo que puede llevar a problemas en la capacidad de generalización del mismo (*overfitting*). Para resolver este problema se hace uso de los métodos *Conditional Fuzzy C-*

means y *Fuzzy Equalization*. Finalmente, este artículo de 1999 asegura que con la estructura ANFIS se logran mejores resultados que con los modelos basados en redes neuronales, desde el punto de vista del error en la estimación. Por su parte en [26], publicado en 2008, se realiza una comparación entre los resultados obtenidos por 17 modelos basados en redes neuronales y 17 basados en estructuras ANFIS. El artículo concluye que para modelos que requieren de información de la calidad del agua cruda para realizar la estimación de coagulante (los cuales son los más precisos, ya que la calidad del agua cruda varía de forma no previsible) funcionan mejor las redes neuronales, mientras que, para modelos auto-predictivos (basados únicamente en las dosificaciones pasadas, sin considerar los parámetros de calidad del agua cruda) funcionan mejor las estructuras ANFIS. Aunque como el mismo artículo lo señala, la aplicabilidad de estos últimos modelos es limitada y no presenta resultados óptimos en casos que por ejemplo la turbiedad del agua cruda se incremente de forma abrupta.

Figura 8. Clasificación de las técnicas empleadas para la dosificación de coagulante



1.5 CONCLUSIONES

Se presenta un marco general del proceso de potabilización del agua haciendo énfasis en los aspectos físicos y químicos que intervienen en el sub-proceso de la coagulación, el cual

se constituye en el de mayor importancia para la presente investigación. De igual forma se presenta un estado del arte en las técnicas de dosificación de coagulante empleadas en la potabilización de agua y una clasificación (ver figura 8) que permite observar en verde, las técnicas consideradas en el desarrollo de la investigación. Finalmente, con el fin de definir claramente los aportes de la presente investigación al problema de la dosificación de coagulante se incluyen en la tabla 1 una breve descripción de los mismos, los cuales serán tratados con mayor detalle en los capítulos siguientes.

Tabla 1. Aportes de la presente investigación

Aporte	Descripción
Metodología para la automatización de la dosificación de coagulante en el proceso de potabilización	*Como se observa a partir del estado del arte presentado, en varias investigaciones se han utilizado herramientas de inteligencia computacional para abordar el problema de la dosificación de coagulante. Sin embargo, ninguno de los trabajos consultados hace un tratamiento integral del problema que incluya todas las etapas requeridas para la implementación de un sistema automático de dosificación de coagulante a partir de datos históricos de operación. La presente investigación aporta una metodología que incluye obtención de la base de datos para la implementación del modelo, detección de outliers, selección de las variables del modelo de estimación, normalización de los datos, comparación entre los modelos obtenidos aplicando diferentes técnicas de inteligencia computacional, evaluación del desempeño del modelo seleccionado, selección de sensores y actuadores, definición del sistema de validación de la información proveniente de los sensores, implementación del sistema y actualización continua del modelo.*
Mejoramiento de la solución al problema de la validación de información	*Hasta la fecha los sistemas de validación de la información proveniente de sensores de calidad de agua han estado basados en redes neuronales auto-asociativas y mapas auto-organizados de Kohonen. La presente investigación realiza un aporte en este tema incluyendo algoritmos genéticos para el mejoramiento del desempeño logrado hasta la fecha con las redes neuronales auto-asociativas.*
Implementación de la solución propuesta en un PLC	*En los trabajos anteriores no se ha reportado la utilización de PLCs en la implementación de los modelos de estimación basados en inteligencia computacional. La presente investigación implementará los modelos que mejores índices de desempeño presenten en un PLC.*
Verificación de la solución propuesta en una planta de potabilización real	*El sistema de automatización implementado, será verificado en la planta de potabilización del municipio de Roldanillo (Valle). A nivel nacional no existen reportes de la implementación de sistemas de dosificación basados en inteligencia computacional que hayan sido probados en plantas de potabilización reales.*

2. TÉCNICAS DE INTELIGENCIA COMPUTACIONAL PARA EL DESARROLLO DE MODELOS PARA LA DOSIFICACIÓN DE COAGULANTE

2.1. INTRODUCCIÓN

En el presente capítulo se describe el proceso por medio del cual se obtienen los diferentes modelos que permiten la estimación de la dosificación de coagulante mediante la utilización de tres técnicas de inteligencia computacional: redes neuronales, lógica difusa y estructuras ANFIS. Los modelos desarrollados, al hacer parte de un sistema de automatización industrial, deben en lo posible basar su estimación en variables fácilmente medibles en línea y mantener una sencillez suficiente que permitan su implementación en un controlador lógico programable (*PLC*, por sus siglas en inglés).

2.2. REDES NEURONALES

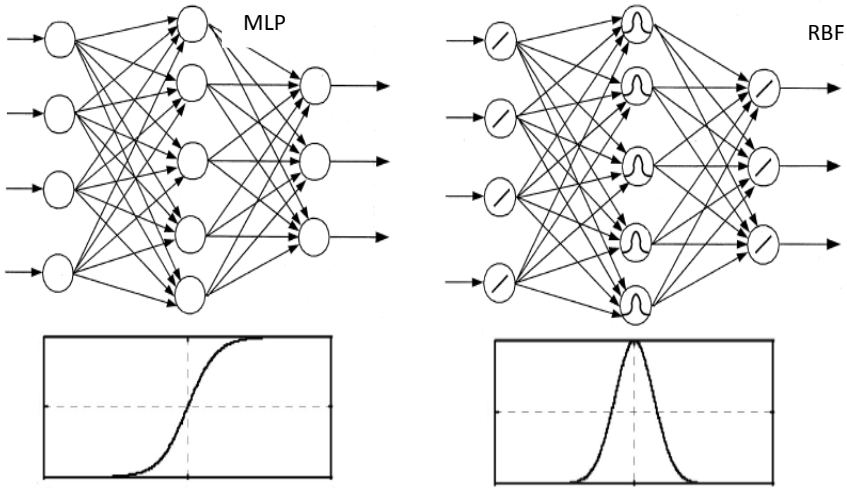
El proceso de obtención de un modelo de redes neuronales para la estimación de coagulante, requiere la toma de decisiones respecto a temas tan diversos como la selección de la arquitectura de la red, el algoritmo de aprendizaje, el tipo de modelo, las variables de entrada/salida, pre-procesamiento de los datos, etc. Las decisiones tomadas a este respecto tienen gran influencia en el rango de aplicabilidad del modelo final y la precisión de sus estimaciones. A continuación se discute brevemente cada uno de estos aspectos y se justifica cada una de las decisiones tomadas para el desarrollo del modelo en redes neuronales objeto de la presente investigación.

2.2.1. Arquitectura de la red

Dada la gran variedad de redes neuronales disponibles, podría decirse que el primer punto a considerar para abordar el problema del desarrollo de un modelo de redes neuronales para la estimación de coagulante es la selección de la arquitectura de la red. Dos de las arquitecturas más ampliamente utilizadas en aplicaciones de control la constituyen el perceptron multicapa (*MLP*, por sus siglas en inglés) y la red de base radial (*RBF*, por sus siglas en inglés) [43], las cuales se observan en las figura 9.

Como se observa la arquitectura de las redes de base radial es bastante similar a la del perceptron multicapa y la diferencia inicial consiste en el tipo de función utilizada en la capa oculta. Las funciones gaussianas son empleadas en las redes *RBF* mientras que el uso de funciones sigmoidales es propio de las redes *MLP*. Otra diferencia radica en que, las redes RBF están limitadas a solo 3 capas (1 de ellas oculta), mientras que las redes *MLP* permiten más de una capa oculta. Lo anterior, según algunos investigadores [44], se constituye en una ventaja para las redes *RBF*, ya que es posible una optimización más sencilla de su desempeño, dado que el único parámetro que puede ser usado para mejorar esta característica es el número de neuronas de la capa oculta.

Figura 9. Redes MLP y RBF



Desde el punto de vista de la estimación de los parámetros de la red (entrenamiento) en el caso de las redes *MLP* son más comunes los métodos iterativos, mientras que en la redes *RBF* es común la utilización de métodos no supervisados (*clustering*) en conjunto con la optimización por mínimos cuadrados. Sin embargo, cabe anotar, que para ambos

casos, *MLP* y *RBF*, existen métodos iterativos y métodos no supervisados disponibles para su entrenamiento.

Varios investigadores [43], han comprobado que los perceptron multicapa y las redes de base radial, pueden considerarse como aproximadores universales, por su capacidad de aproximar cualquier función real, con cualquier grado de precisión. Si bien otros modelos comparten esta propiedad, tales como los modelos polinomiales, las series trigonométricas, los *splines* y las expansiones de series ortogonales, puede demostrarse que las redes *MLP* y *RBF* (las cuales constituyen expansiones de funciones parametrizadas) requieren menos parámetros que las expansiones de funciones fijas para alcanzar un error específico. En ese sentido se consideran parsimoniosas. Un precio a pagar por la utilización de funciones parametrizadas es la existencia de varios mínimos locales en la superficie de error.

Por último, otra gran ventaja de las redes *MLP* y *RBF* la constituye su gran flexibilidad, lo cual permite que su complejidad interna pueda incrementarse significativamente (para modelar relaciones no-lineales más complejas), sin cambiar la forma global del modelo.

Para el caso particular de la estimación de coagulante, en la bibliografía consultada, es más común la utilización de redes neuronales tipo *MLP* que de redes neuronales tipo *RBF*. Esto puede justificarse teniendo en cuenta que las redes *RBF* funcionan mejor en procesos donde los puntos de operación son finitos, tales como el proceso de galvanizado descrito en [43]. En el proceso de coagulación, no es posible obtener puntos de operación finitos de operación dado que las variables que caracterizan la calidad del agua cruda (*turbiedad, pH, conductividad, color*, etc.) no varían entre valores fijos sino que por el contrario dichas variables pueden tomar cualquier valor en el rango de operación del modelo. Por tanto, en la presente investigación se utiliza el perceptron multicapa para la implementación del modelo de estimación de coagulante.

Una vez determinado que el modelo será implementado utilizando redes *MLP*, queda por definir, en cuanto a la arquitectura, cuestiones como el número de capas ocultas utilizar y su número de neuronas. En este sentido, vale la pena tener en cuenta el estudio desarrollado en el Reino Unido por la Universidad de Newcastle en conjunto con 24 multinacionales (incluida *Thames Water*, empresa encargada de prestar el servicio de acueducto y alcantarillado a 8.5 millones de usuarios ubicados en Londres y en el Valle del río Támesis), el cual tuvo una duración de 2 años y contó con una inversión de £5.7 millones por parte del Departamento de Industria y Comercio del Reino Unido [24]. Dicho estudio en una de sus conclusiones señala como la topología de red rara vez tiene efectos profundos en la precisión del modelo, mientras que otros aspectos tienen una mayor relevancia como son la escogencia de las variables de entrada y el pre-procesamiento de los datos empleados para la obtención de modelo. En general, concluye el estudio, el

tiempo es mejor invertido mejorando el pre-procesamiento de los datos que afinando la estructura de la red.

Por tanto, para la implementación del modelo se inicia con un perceptron multicapa, de una sola capa oculta con un número de *2i+1* neuronas en dicha capa, donde *i* corresponde al número de entradas al modelo, criterio adoptado en [20], [25] y [26], para la configuración inicial de la red.

2.2.2. Algoritmos de aprendizaje

El algoritmo *backpropagation* constituye uno de los algoritmos más ampliamente utilizados para el entrenamiento de redes perceptron multicapa. Esta técnica, que se deriva de la regla delta desarrollada por *Widrow-Hoff* en 1960, busca mediante el algoritmo del gradiente descendiente encontrar un valor mínimo local o global en la superficie de error que permita alcanzar los requerimientos de error previamente establecidos para el modelo a entrenar. Si bien, el algoritmo no garantiza alcanzar siempre el mínimo global, para muchas aplicaciones resulta suficiente con encontrar un mínimo local. Para controlar la velocidad de convergencia del algoritmo se ajusta el parámetro α, denominado tasa de aprendizaje. Valores altos de este parámetro aceleran la convergencia del algoritmo, pero pueden llevar a oscilaciones del mismo, alrededor de un valor mínimo. Para controlar esta situación, existe un segundo parámetro β, denominado momento, el cual además de evitar las oscilaciones permiten la convergencia de la red en un número menor de iteraciones [45].

Existen además otros algoritmos que permiten un entrenamiento más rápido al logrado utilizando el algoritmo del gradiente descendiente, entre los que se pueden mencionar el entrenamiento con rata de aprendizaje variable, algoritmos de gradiente conjugado, algoritmo *Quasi-Newton* y el algoritmo *Levenberg-Marquardt.*

Para la presente implementación se emplea el algoritmo *Levenberg-Marquardt*, el cual combina dos estrategias de minimización, el método del gradiente descendiente y el método de Newton, lo cual bajo circunstancias de entrenamientos de redes con poca cantidad de neuronas y conexiones es más rápido y efectivo que los algoritmos de gradiente conjugado [46].

Otro aspecto a considerar dentro del aprendizaje, es evitar el sobre-entrenamiento (*overfitting*) de la red, el cual lleva a una pérdida de la capacidad de generalización de la misma. Para evitar esto, se aconseja dividir los datos disponibles en datos de entrenamiento, prueba y validación. De esta manera el conjunto de entrenamiento es utilizado para la actualización de los pesos y *bias* de la red, mientras que el conjunto de

validación se emplea para monitorear su error durante el entrenamiento. Cuando el error del conjunto de datos de validación comience a crecer es una indicación que la red se está sobre-entrenando y el entrenamiento se debe detener. Finalmente, el error del conjunto de datos de prueba además de servir para comparar diferentes modelos, pueden también indicar una división poco homogénea de los datos cuando dicho error alcanza un mínimo en una iteración marcadamente diferente a la que el error de validación alcanza su mínimo. Para el desarrollo del presente modelo, los datos disponibles se dividen en 50% para entrenamiento, 25% para validación y 25% para prueba.

2.2.3. Tipo de modelo

La etapa de la coagulación, en la cual se determina la dosificación de coagulante a ser aplicada al agua cruda para alcanzar parámetros de calidad adecuados a la salida de la planta (agua tratada), puede considerarse como un proceso no lineal de múltiples entradas con múltiples salidas. Dicho proceso, en forma general, puede representarse de forma esquemática tal como se aprecia en la figura 10.

Figura 10. Representación esquemática del proceso de coagulación



Las entradas de dicho proceso la constituyen los parámetros de calidad del agua cruda (PCAC), tales como turbiedad, color, pH, conductividad, etc., y los parámetros operacionales (PO), tales como la dosificación de coagulante y polímero (en caso de requerirse). Por su parte, las salidas del proceso serán los parámetros de calidad del agua tratada (PCAT), turbiedad, color, pH, aluminio residual, etc. En este orden de ideas, es posible obtener dos tipos diferentes de modelos de redes neuronales, modelos de

proceso directos y modelos de proceso inversos. En los modelos directos, la red neuronal, predice uno o más de los valores de los parámetros de salida del proceso (parámetros de calidad del agua tratada), a partir de los valores de entrada del proceso (parámetros de calidad del agua cruda y parámetros operacionales). Con estos modelos es posible implementar interfaces virtuales que permitan mejorar el entendimiento de los factores que afectan el proceso de potabilización, realizar análisis históricos y entrenar nuevos operadores.

En los modelos inversos, la red neuronal, predice el valor de uno o varios de los parámetros de entrada, dados los valores de las entradas restantes del proceso y los parámetros de salida. Por tanto, los modelos inversos permiten predecir la dosificación de coagulante directamente dados los valores de los parámetros de calidad del agua cruda y los parámetros deseados del agua tratada [31] y [22].

Dentro de la bibliografía consultada, la gran mayoría de trabajos [20], [22], [25], [26], [27], [29] y [43] hace uso de modelos inversos para la predicción de la dosificación de coagulante a ser aplicada al agua cruda. Por su parte, en [23], [24] y [28] se describen modelos directos que fueron empleados para la predicción de la dosificación de coagulante. En estos casos, las salidas de las redes neuronales, fueron utilizadas para minimizar funciones de costo previamente definidas, las cuales entregan como resultado, entre otras, la dosificación de coagulante a ser aplicada. Dado que la utilización de algoritmos de optimización de funciones de costo, incrementan la carga computacional en la implementación del modelo de estimación, en la presente investigación se trabaja con modelos inversos para la estimación de coagulante.

2.2.4. Variables de entrada

Diversas han sido las variables de entrada utilizadas en los modelos de redes neuronales implementados para la estimación de la dosificación de coagulante. En cuanto a la cantidad de entradas al modelo, se encuentran implementaciones desde 2 entradas hasta 9, y entre las variables utilizadas se encuentran:

- Color del agua cruda
- Color del agua tratada
- Dosificación de polímero
- Dosificación de coagulante (con retardo)
- Turbiedad del agua cruda
- Turbiedad del agua tratada
- pH del agua cruda

- Alcalinidad del agua cruda
- Temperatura del agua cruda
- Conductividad del agua cruda
- Oxigeno disuelto en el agua cruda
- Absorción ultravioleta en el agua cruda
- Absorción ultravioleta en el agua tratada
- Dosificación de ozono
- Caudal de entrada
- Nivel de clorofila en el agua cruda
- Presión diferencial a través del filtro de la planta
- Tiempo transcurrido desde la última limpieza del filtro
- Conteo de partículas en el agua cruda
- Dureza del agua cruda
- Carbón orgánico disuelto en el agua cruda

Como se observa, alrededor de 21 variables diferentes han sido empleadas para la implementación de dichos modelos.

De acuerdo al tipo de variables seleccionadas se pueden encontrar tres tendencias en la implementación del modelo. En la primera aproximación la predicción se basa únicamente en los parámetros de calidad del agua cruda, tal como se observa en [43]. Otra tendencia es incluir las dosificaciones de coagulante de días anteriores como entradas al modelo, tal como se describe en [20], [26], [24], [27], [28], [29] y [23]. Otra posibilidad es incluir como entradas al modelo, los parámetros de calidad del agua tratada. En [22] y [25] se encuentran implementaciones de este tipo.

Para la implementación del presente modelo se toman los resultados de las pruebas de jarras desarrolladas diariamente por los operadores de la planta de potabilización del municipio de Roldanillo (Valle del Cauca). Durante dicha prueba se miden en laboratorio la turbiedad, el pH, la conductividad, la temperatura, la alcalinidad, el color, la dureza y el hierro del agua cruda. Posteriormente, el agua cruda es sometida a una prueba de jarras que busca simular las condiciones de proceso a la que se somete el agua durante la coagulación, floculación y sedimentación. Al finalizar la prueba, se mide en laboratorio la turbiedad en cada uno de las seis jarras participantes en la prueba con el fin de determinar la dosis de coagulante a ser aplicada (ver numeral 1.3.1).

En la tabla 2 se observan los rangos de las variables que se consideraron inicialmente para la implementación del modelo y que proceden de las pruebas de jarra realizadas.

Tabla 2. Variables disponibles para el modelo y sus rangos

Variable	Rango	Unidad	Tipo
Turbiedad	[1.6 – 541]	NTU	Entrada
pH	[6.5 – 9.4]	-	Entrada
Conductividad	[108 – 295]	µS/cm	Entrada
Temperatura	[15.2 – 24.5]	°C	Entrada
Alcalinidad	[12 – 144]	mgCaCO3/l	Entrada
Color	[3.8 – 940]	UPC	Entrada
Dureza	[39 – 135]	mgCaCO3/l	Entrada
Hierro	[0.04 – 7.3]	mgFe/l	Entrada
Dosificación de coagulante	[14 – 100]	mg/l	Salida

Cabe anotar que las cuatro primeras variables (turbiedad, pH, conductividad y temperatura) constituyen las variables más fácilmente medibles en línea, por lo tanto uno de los objetivos del presente desarrollo es la búsqueda de un modelo lo suficientemente confiable basado en lo posible en estas cuatro variables.

2.2.5. Pre-procesamiento de los datos

Como se mencionó previamente, en trabajos como [24] y [27] se hace bastante énfasis en el pre-procesamiento de los datos como medida para mejorar la velocidad de aprendizaje y la precisión de los modelos implementados. En nuestro caso, el pre-procesamiento se enfocará en tres aspectos:

- Normalización de los datos
- Detección de *outliers*
- Selección de las variables de entrada que harán parte del modelo

2.2.5.1. Normalización de los datos. La normalización ayuda a distribuir más uniformemente los valores de los datos de entrenamiento de la red neuronal en una escala uniforme para que los valores extremos no distorsionen de forma significativa los resultados de predicción de la red. Los datos pueden normalizarse en rangos entre -1 y 1, 0 y 1 o según su desviación estándar. En el presente trabajo se utiliza la normalización entre 0 y 1 dada por la ecuación 1, donde, X_{norm} corresponde al valor normalizado, X_i es el valor a normalizar y X_{max} y X_{min} los valores máximos y mínimos de la variable respectiva.

$$X_{norm} = \frac{X_i - X_{min}}{X_{max} - X_{min}} \qquad [1]$$

2.2.5.2. Detección de outliers. Un *outlier* puede definirse como "una observación en un conjunto de datos la cual parece ser inconsistente con el conjunto de datos restantes" [47]. La no detección de *outliers* y su inclusión en el proceso de obtención de modelos pueden llevar resultados incorrectos o sesgos en la predicción final de los parámetros estimados por el modelo.

La detección de *outliers* en sí, es un campo bastante amplio, el cual ha sido tema de una gran variedad de artículos y libros donde se ha abordado la búsqueda de soluciones mediante aproximaciones estadísticas, minería de datos, *clustering* y redes neuronales, entre otros. En la presente investigación se emplea la metodología propuesta en [27] la cual combina métodos estadísticos y redes neuronales para la detección de *outliers.* La metodología propuesta puede resumirse de la siguiente manera:

1. Entrenar una red neuronal que estime la dosificación de coagulante utilizando la totalidad de datos disponibles.

2. Comparando los datos reales con las predicciones realizadas por el modelo de redes neuronales, hallar los residuales del modelo.

3. Graficar mediante un histograma el comportamiento de los residuales y verificar si tienen una distribución normal.

4. Realizar un análisis de intervalo de confianza a los residuales y descartar los datos que estén por fuera del intervalo de confianza seleccionado.

Cabe anotar que los autores de la metodología advierten sobre la necesidad de analizar los datos descartados en el paso 4, ya que existe la posibilidad de denominar como *outliers* a datos perfectamente válidos lo cual a larga se verá reflejado en una disminución de la capacidad de predicción del modelo.

La base de datos original contaba con 943 datos correspondientes a las pruebas de jarras realizadas diariamente en un periodo de 2 años y 7 meses (2007, 2008 y los siete primeros meses del 2009). De estos datos, fueron descartados 96 registros incompletos los cuales fueron detectados por simple inspección visual (por ejemplo ver datos 91, 94 y 124 del anexo 1). La base de datos restante, con 847 registros, fue sometida al procedimiento para detección de *outliers*. En principio se entrenó una red tipo MLP con las características descritas en la tabla 3.

Tabla 3. Características de la red neuronal para la detección de outliers

Número de neuronas de entrada	8
Número de capas ocultas	1
Número de neuronas en la capa oculta	17
Número de neuronas de salida	1
Variables de entrada	Turbiedad, pH, Conductividad, Color Temperatura, Alcalinidad, Hierro y Dureza.
Variables de salida	Dosis de coagulante
Función de activación en las neuronas de la capa oculta	Sigmoidal Bipolar (*tansig*)
Función de activación de las neuronas de la capa de salida	Lineal (*purelin*)
Algoritmo de entrenamiento	Levenberg-Marquardt (*trainlm*)

De la figura 11 se puede observar una distribución normal en el comportamiento de los residuales por lo cual se procede a realizar el análisis del intervalo de confianza. De acuerdo a este análisis [48] es posible definir un intervalo de confianza del 100(1-α)% para la media muestral $\bar{X}$ con distribución normal, valor esperado μ y desviación estándar ($\sigma/\sqrt{n}$) como se define en la ecuación 2.

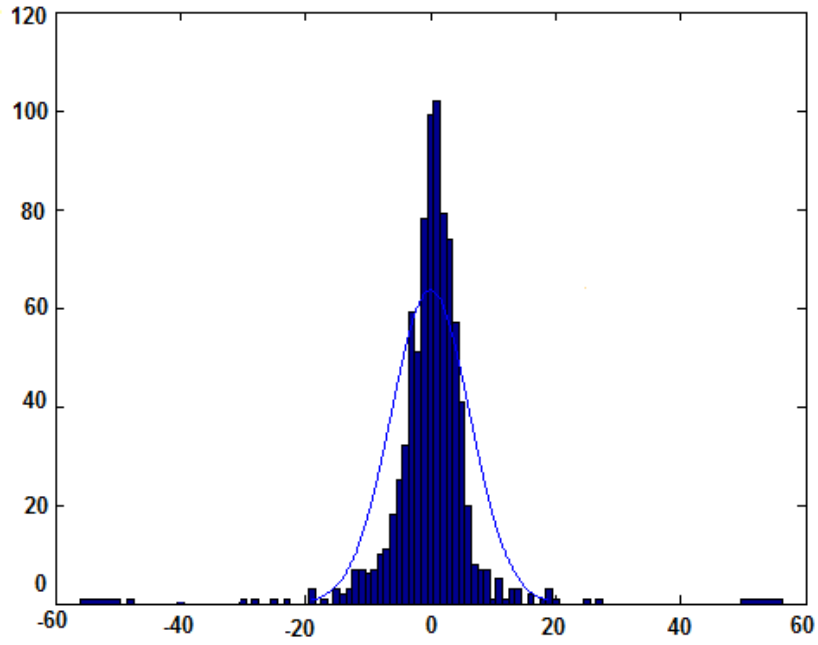
$$\left(\bar{X} - Z_{\alpha/2}\frac{\sigma}{\sqrt{n}}, \bar{X} + Z_{\alpha/2}\frac{\sigma}{\sqrt{n}}\right) \qquad [2]$$

$Z_{\alpha/2}$ corresponde a los dos valores extremos en la distribución normal para los que se cumple que lo expuesto en la ecuación 3 [49]:

$$P\left(-Z_{\alpha/2} < \frac{\bar{X} - \mu}{\sigma/n} < Z_{\alpha/2}\right) = 1 - \alpha \qquad [3]$$

Para los datos analizados se encontró que los valores de la media muestral observada y la desviación estándar para los residuales fueron 0.0279 y 6.2748 respectivamente. Definiendo un intervalo de confianza del 80% (α=0.20 y $Z_{\alpha/2}$=1.28), se encontraron un total de 80 datos con posibilidad de ser considerados como *outliers*. De estos 80 datos 43 se determinaron como *outliers* y 37 como datos válidos, que se conservaron para la construcción del modelo. Un ejemplo de *outlier* corresponde por ejemplo al dato marcado como 307 (ver anexo 1) el cual tiene asociada una dosificación de coagulante de 75 mg/l, mientras que otros datos con características de calidad de agua similares como los datos 309 y 123 presentan dosificaciones muy inferiores (y más consistentes con las características de calidad de agua) cercanas a los 45 mg/l. Un ejemplo, de un dato válido que inicialmente se consideró como posible *outlier* lo constituye el dato 509, cuya turbiedad asociada es de 493 NTU, el cual es un dato poco frecuente dentro de la base de datos, pero es un dato válido y la dosificación asociada es perfectamente congruente con las características de calidad de agua cruda del registro. En el anexo 2 se muestra el programa en MATLAB con el que se detectaron los *outliers* de acuerdo a la técnica descrita.

Figura 11. Histograma de los residuales con distribución normal asociada



El error cuadrático medio (*RMSE*, por sus siglas en inglés) que se define en la ecuación 4, donde, *N* es el número de datos, o_p es el valor estimado por la red neuronal y o_d el valor real, constituye un índice de desempeño que nos permite comparar la capacidad de predicción entre diferentes modelos de redes neuronales.

$$RMSE = \frac{1}{N}\sqrt{\sum_{i=1}^{N}(o_p - o_d)^2} \qquad [4]$$

Otro índice de desempeño es el coeficiente de correlación (R^2) entre los valores reales y los datos estimados por la red neuronal. Como se observa en la tabla 4 es claro como la eliminación de *outliers* mejora considerablemente el comportamiento de la red desde el punto de vista de la precisión de sus estimaciones.

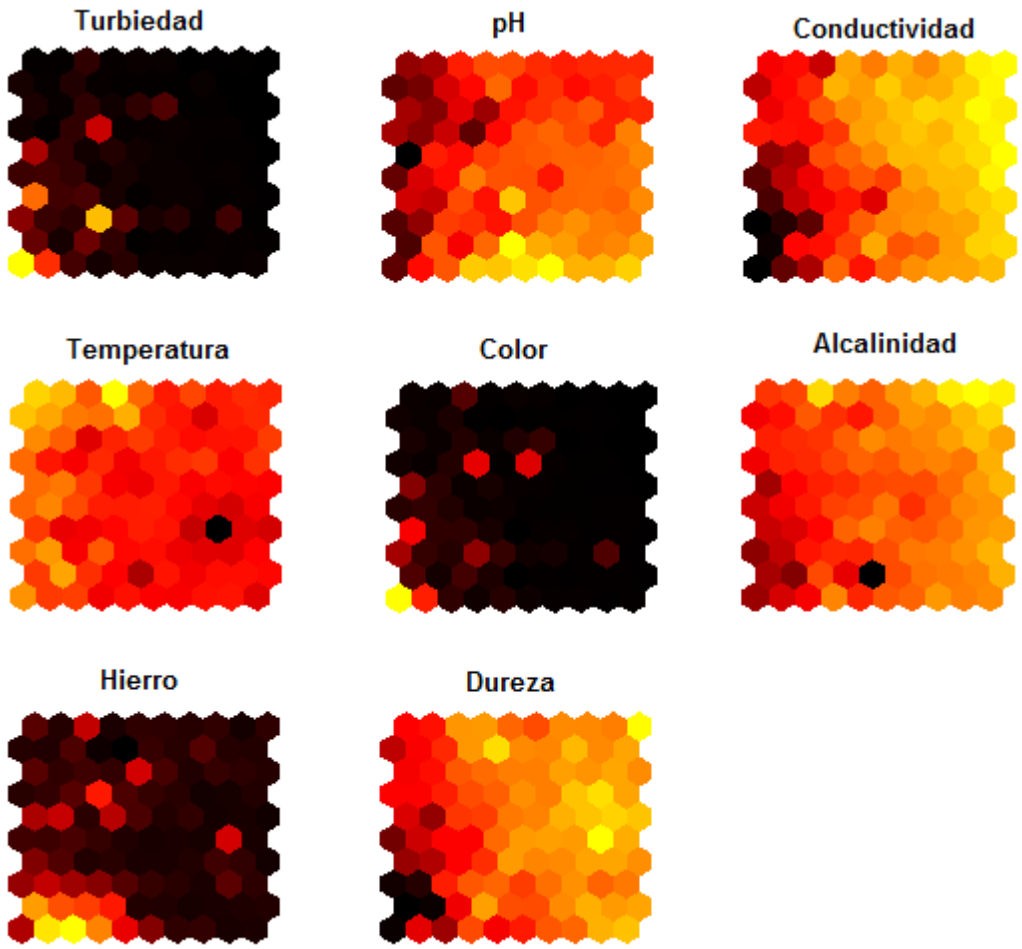
Tabla 4. Comparación del desempeño de los modelos al eliminar los outliers

	RMSE	**R^2**
Con *Outliers*	0,2155	0,8650
Sin *Outliers*	0,1591	0,9230

2.2.5.3. Selección de variables. Con el fin de determinar las variables que servirán de entrada al modelo de redes neuronales que estimará la dosificación de coagulante se deben considerar dos aspectos. El primero es determinar si entre las 8 variables con que inicialmente se cuenta para la implementación del modelo existe información redundante, o en otras palabras si existen variables altamente correlacionadas de manera tal que no se requiera incluir las 8 variables como entradas al modelo. Una manera de determinar el grado de correlación existente entre las diferentes variables, utilizando técnicas de inteligencia computacional, es mediante los mapas auto-organizados de *Kohonen* (*SOMs*, por sus siglas en inglés). Los mapas auto-organizados son una herramienta para la exploración y visualización de datos multidimensionales, que convierte relaciones no lineales complejas, en relaciones geométricas más simples representadas usualmente mediante arreglos en 2 dimensiones [50]. Dos de las técnicas para la visualización de mapas auto-organizados son la matriz U (*U-Matrix* en inglés) y los planos de componentes. La primera técnica está orientada a la identificación de *clusters* en un espacio de datos multidimensional basándose en las distancias existentes entre dos neuronas adyacentes del mapa auto-organizado [52]. La segunda técnica, planos de componentes, permite detectar correlaciones entre las diferentes variables de entrada simplemente observando el patrón de colores de cada uno de los planos [51]. En la figura 12 se observan los planos

de componentes correspondientes a las 8 variables de entrada utilizadas en la prueba de jarras. Para esta representación se entrenó un mapa auto-organizado de 100 neuronas (arreglo en dos dimensiones de 10x10). En cada uno los planos mostrados, el peso de la conexión entre cada entrada y cada una de las neuronas es representado mediante colores. Las conexiones más fuertes están representadas mediante color rojo y la ausencia de conexión mediante color negro.

Figura 12. Planos de componentes de las variables de entrada



De los planos observados en la figura 13 es posible encontrar alto grado de correlación entre la turbiedad y el color, y la conductividad y la dureza y en menor grado entre la conductividad y la alcalinidad. Por otra parte, es claro también que la temperatura, el pH y el hierro no guardan ningún tipo de correlación con las otras variables.

Con el fin de tener un indicador numérico que nos permita confirmar o descartar las afirmaciones anteriores se realiza un análisis de correlación, cuyos resultados se observan en la tabla 5.

Tabla 5. Análisis de correlación variables de entrada

	Turbiedad	pH	Conductividad	Temperatura	Color	Alcalinidad	Hierro	Dureza
Turbiedad	1.00000							
pH	-0.26696	1.00000						
Conductividad	-0.52433	0.57115	1.00000					
Temperatura	0.16540	-0.62144	-0.48273	1.00000				
Color	**0.88129**	-0.28238	-0.54111	0.17707	1.00000			
Alcalinidad	-0.45191	0.46903	**0.81168**	-0.36441	-0.44297	1.00000		
Hierro	0.45953	-0.14655	-0.51625	0.11766	0.50324	-0.38353	1.00000	
Dureza	-0.46399	0.58401	**0.89287**	-0.50513	-0.47851	0.75421	-0.52396	1.00000

El análisis anterior permite confirmar las relaciones anteriormente encontradas entre la turbiedad y el color, la conductividad y la dureza, y la conductividad y la alcalinidad. Por tanto es posible descartar como entradas del modelo, el color, la dureza y la alcalinidad, ya que la información que aportarían al modelo ya estaría siendo proporcionada en gran medida por la turbiedad y la conductividad. Se prefiere escoger la turbiedad y la conductividad, sobre las otras variables, ya que la turbiedad y la conductividad son fácilmente medibles en línea lo cual favorece la obtención de un modelo que permita la obtención automática de dosificación de coagulante. En el anexo 2 se encuentra el programa en MATLAB con el que se generó el mapa auto-organizado de *Kohonen.*

El siguiente paso en la selección de las variables que servirá de entrada al modelo, consiste en determinar, cuáles de las variables restantes, turbiedad, pH, conductividad, hierro y temperatura, afectan realmente la salida del modelo, es decir, la dosificación de coagulante. Para tal fin se emplea una metodología similar a la propuesta en [53] consistente en un proceso de selección tipo *backward*, el cual se puede resumir en los siguientes pasos:

1. Implementar un modelo que incluya todas las variables candidatas y evaluar su desempeño.

2. Para cada variable restante, evaluar el desempeño del modelo con dicha variable temporalmente eliminada.

3. Eliminar de forma permanente la variable asociada con el modelo que mejor desempeño logró en el paso 2.

4. Si todavía existen variables restantes en el modelo regresar al paso 2 para eliminar otra variable.

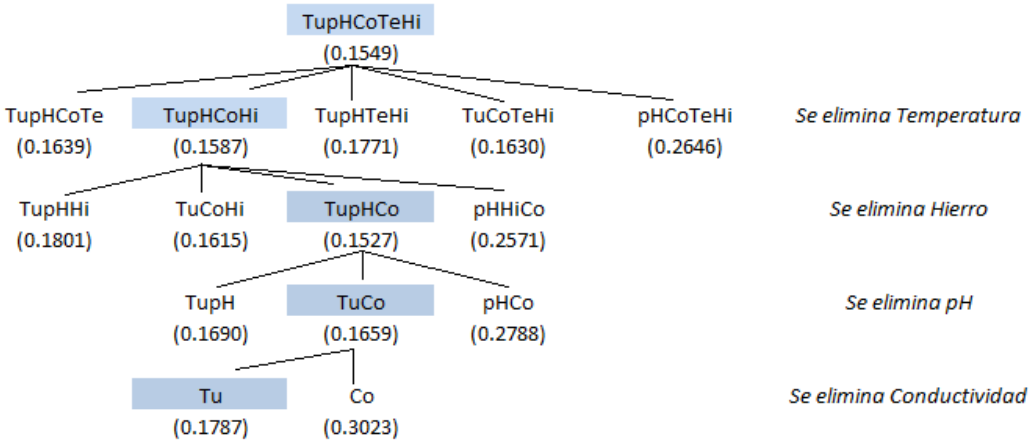
5. Seleccionar el mejor conjunto de variables de los resultantes en el paso 3.

En nuestro caso los modelos utilizados fueron modelos de redes neuronales con las características descritas en la tabla 6. El índice de desempeño para evaluar cada uno de los modelos obtenidos fue el *RMSE*, descrito previamente. Los resultados del proceso de selección se pueden observar en la figura 13.

Tabla 6. Características de las redes neuronales para la selección de las variables de entrada

Número de neuronas de entrada	**n**
Número de capas ocultas	1
Número de neuronas en la capa oculta	2*n
Número de neuronas de salida	1
Variables de salida	Dosis de coagulante
Función de activación en las neuronas de la capa oculta	Sigmoidal Bipolar (*tansig*)
Función de activación de las neuronas de la capa de salida	Lineal (*purelin*)
Algoritmo de entrenamiento	Levenberg-Marquardt (*trainlm*)

Figura 13. Proceso de selección de variables de entrada al modelo



En la figura 14, *Tu, pH, Co, Hi* y *Te*, corresponde a las iníciales de las variables participantes en el modelo (turbiedad, pH, conductividad, hierro y temperatura respectivamente). Entre paréntesis aparece el valor *RMSE* obtenido por el modelo.

Si bien es cierto, que el *RMSE* resultante en cada modelo depende no solo de las variables de entrada seleccionadas, sino que está también influenciado por la división de los datos y por el mínimo encontrado durante el entrenamiento de la red, es claro que los resultados obtenidos nos permiten observar la gran influencia que tiene la turbiedad en el resultado final de la estimación de la dosificación (los modelos en los que esta variable era eliminada desmejoraban notoriamente su desempeño), la poca o casi ninguna influencia del hierro y la temperatura (el eliminar estas variables del modelo dosificación poco alteraban el desempeño del mismo) y el grado de influencia menor (comparado con el de la turbiedad) del pH y la conductividad. Teniendo en cuenta el proceso de selección descrito, la turbiedad, el pH y la conductividad serán precisamente las variables que se utilizaran como entradas al modelo de redes neuronales, para la dosificación de coagulante.

2.2.6. Obtención del modelo en redes neuronales

Una vez determinado el número de variables de entrada al modelo, y al haber definido la base de datos a partir del cual el modelo será generado, se procede a entrenar el perceptron multicapa que estimará la dosificación de coagulante a aplicarse al agua cruda de acuerdo a las características de calidad del agua que ingresa a la planta. Las características de la red entrenada se observa en la tabla 7.

Tabla 7. Características de la red neuronal para la estimación de coagulante

Número de neuronas de entrada	**3**
Número de capas ocultas	1
Número de neuronas en la capa oculta	9,8,7,6,5 y 4
Número de neuronas de salida	1
Variables de entrada	Turbiedad, pH y Conductividad
Variables de salida	Dosis de coagulante
Función de activación en las neuronas de la capa oculta	Sigmoidal Bipolar (*tansig*)
Función de activación de las neuronas de la capa de salida	Lineal (*purelin*)
Algoritmo de entrenamiento	Levenberg-Marquardt (*trainlm*)

Después de varias simulaciones modificando el número de neuronas en la capa oculta, se encontró que, desde el punto de vista del error medio absoluto (*MAE*, por sus siglas en inglés), los mejores resultados se encontraron con 7 neuronas (ver tabla 8). El error medio absoluto se define se define en la ecuación 5, donde, f_i corresponde a la estimación del modelo y y_i al valor real.

$$MAE = \frac{1}{n}\sum_{i=1}^{n}|f_i - y_i| \qquad [5]$$

Una de las ventajas de este índice es que su valor esta expresado en las mismas unidades de la salida del modelo por lo cual permite evaluar que tan adecuadas son las predicciones de la red para ser incluidas en un sistema automático de dosificación de coagulante. En el caso de la dosificación de coagulante, teniendo en cuenta que el *MAE* se encuentra en el orden de los 3.0 mg/l, que el rango de dosificación comprendía de 20 mg/l a 100mg/l y que en una prueba de jarras las dosificaciones se escogen en intervalos entre 2mg/l y 5 mg/l, es posible afirmar que las estimaciones del modelo obtenido pueden incluirse dentro de un sistema de control para la dosificación de coagulante.

Tabla 8. Índices de desempeño del modelo variando el número de neuronas en la capa oculta

No. Neuronas en la capa oculta	R^2	RMSE	MAE
9	0.9128	0.1690	3.4445
8	0.9322	0.1521	3.2093
7	0.9393	0.1419	2.9642
6	0.9382	0.1433	2.9860
5	0.9246	0.1575	3.1639
4	0.9228	0.1594	3.3181

En la figura 14, se observa la arquitectura del modelo de redes neuronales obtenido para la dosificación de coagulante. Finalmente, en la figura 15 se observa una comparación entre las dosificaciones realizadas por medio de prueba de jarras y las estimadas por el modelo de redes neuronales, entre el 1 de Marzo de 2008 y el 1 de Junio de 2008. Como se observa en las estimaciones realizadas por el modelo de redes neuronales, son bastante cercanas a las obtenidas por los operadores mediante la realización de pruebas de jarras. Esta comparación, corrobora las bondades del modelo que ya habían sido reseñadas mediante los índices de desempeño obtenidos en la tabla 8.

Figura 14. Arquitectura del modelo de redes neuronales obtenido para la dosificación de coagulante.

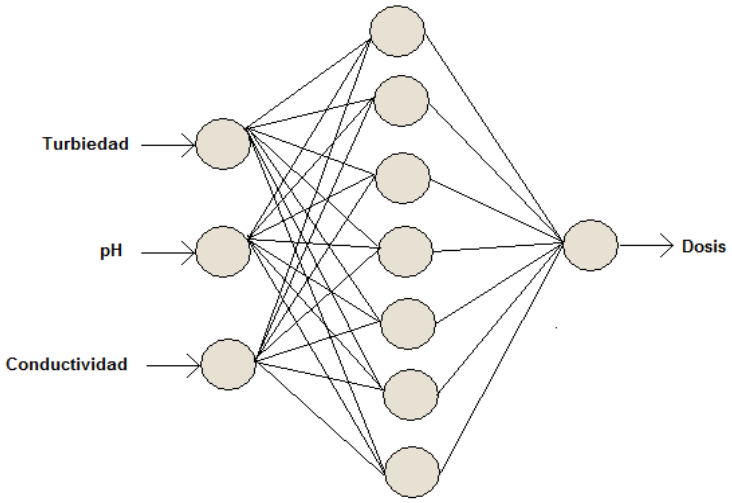
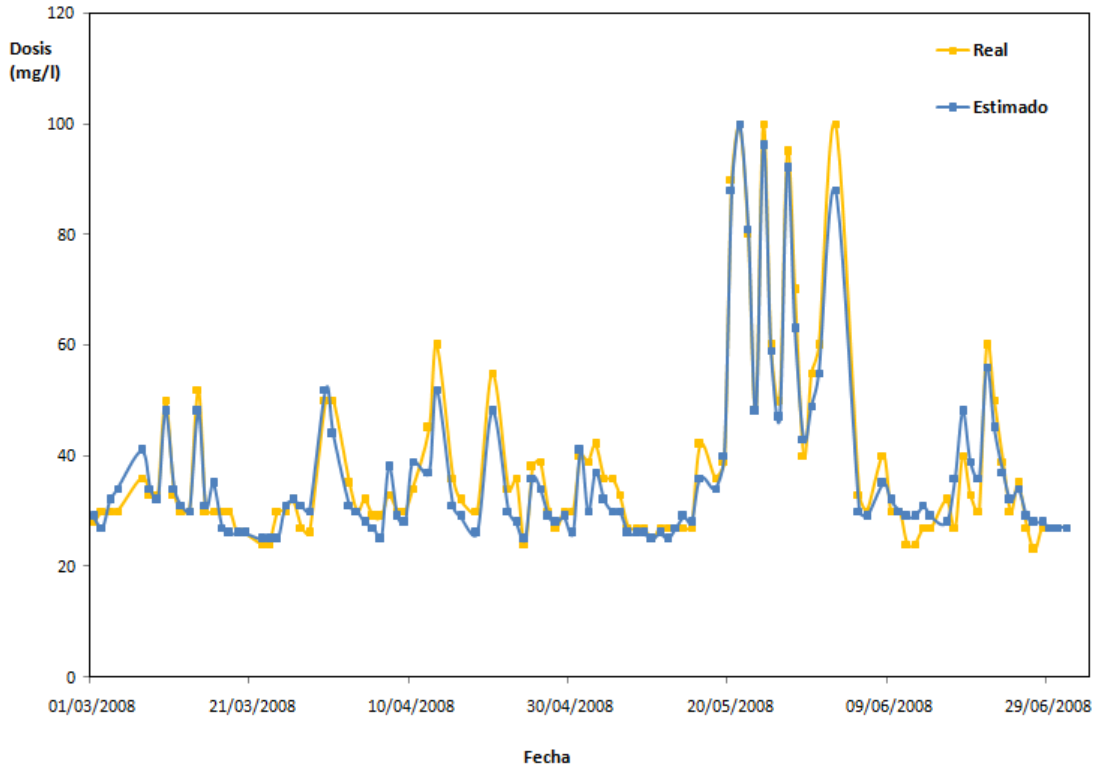


Figura 15. Comparación entre la dosificación realizada por medio de pruebas de jarras y el modelo de redes neuronales



2.3. SISTEMAS DIFUSOS

Al igual que las redes neuronales, los sistemas difusos cumplen la propiedad de ser aproximadores universales, es decir que están en la capacidad de aproximar cualquier función real, con cualquier grado de precisión, aunque para precisiones arbitrarias, pueda requerirse un número arbitrariamente grande de reglas [54][55]. Una de las ventajas de los sistemas difusos, respecto a las redes neuronales, es que permiten la construcción de modelos a partir de información lingüística proporcionada por expertos, aunque como se verá más adelante, también es posible la construcción de modelos difusos mediante la utilización de pares de entrada/salida numéricos.

En términos generales, existen dos tipos de inferencia para la implementación de sistemas difusos. En la primera conocida como inferencia *Mamdani*, tanto las entradas como las salidas son definidas como conjuntos difusos, lo cual trae como ventaja el utilizar completamente la información lingüística para describir el problema a solucionar. Por su parte, la inferencia *Sugeno* es una representación más compacta y eficiente desde el punto de vista computacional, que la inferencia *Mamdani*, en la que las entradas se definen como conjuntos difusos, pero las salidas se definen en términos de las entradas, usualmente utilizando una combinación lineal.

Para la implementación de los sistemas de inferencia difusa que estiman la dosificación de coagulante, se utilizaran modelos *Mamdani* y modelos *Sugeno*. El modelo *Mamdani* se emplea para desarrollar un sistema de inferencia para la dosificación de coagulante basado en las reglas derivadas del conocimiento que en cuanto al manejo del proceso de coagulación tiene uno de los operadores de la planta de potabilización del municipio de Roldanillo (Valle del Cauca). Por su parte el modelo *Sugeno*, se empela para desarrollar un sistema de inferencia obtenido a partir de los mismos datos numéricos utilizados para el desarrollo de los modelos en redes neuronales.

2.3.1. Desarrollo del modelo *Mamdani*

Mediante una entrevista realizada a uno de los operadores de la planta del municipio de Roldanillo (Valle del Cauca), se trató de obtener un conjunto de reglas de operación, que permitieran la implementación de un sistema difuso tipo *Mamdani* para la estimación de coagulante.

Aunque inicialmente fue planteado al operador, la posibilidad de utilizar tres variables de entrada para la construcción de las reglas (turbiedad, pH y conductividad), el prefirió trabajar con la turbiedad y el pH, ya que para él no era claro como cuantificar la influencia

de la conductividad en el resultado final de la dosificación de coagulante. En las tablas 9,10 y 11 se observan los valores lingüísticos asignados a cada una de las variables de entrada y salida. Dado que se seleccionaron 7 variables lingüísticas para la turbiedad y 3 para el pH, se generaron un total de 21 reglas del tipo *if-then*, las cuales se resumen en la tabla 12.

Tabla 9. Valores lingüísticos asociados a la turbiedad

Valor lingüístico	Descripción
BB	Turbiedad muy baja
B	Turbiedad baja
MB	Turbiedad media-baja
MM	Turbiedad media
MA	Turbiedad media-alta
A	Turbiedad alta
AA	Turbiedad muy alta

Tabla 10. Valores lingüísticos asociados al pH

Valor lingüístico	Descripción
B	pH bajo
M	pH medio
A	pH alto

Tabla 11. Valores lingüísticos asociados a la dosificación de coagulante

Valor lingüístico	Descripción
BB	Dosis muy baja
B	Dosis baja
MB	Dosis media-baja
M	Dosis media
MA	Dosis media-alta
A	Dosis alta
AA	Dosis muy alta

Tabla 12. Reglas para la estimación de coagulante

Dosis		pH		
		B	**M**	**A**
Turbiedad	**BB**	BB	BB	BB
	B	BB	BB	B
	MB	B	B	MB
	MM	MB	MB	MB
	MA	M	MB	MA
	A	M	M	A
	AA	MA	A	AA

A continuación se definen las funciones de membrecía para la turbiedad, el pH y la dosificación de coagulante, las cuales se observan en las figuras 16, 17 y 18.

Figura 16. Funciones de membrecía definidas para la turbiedad - Mamdani

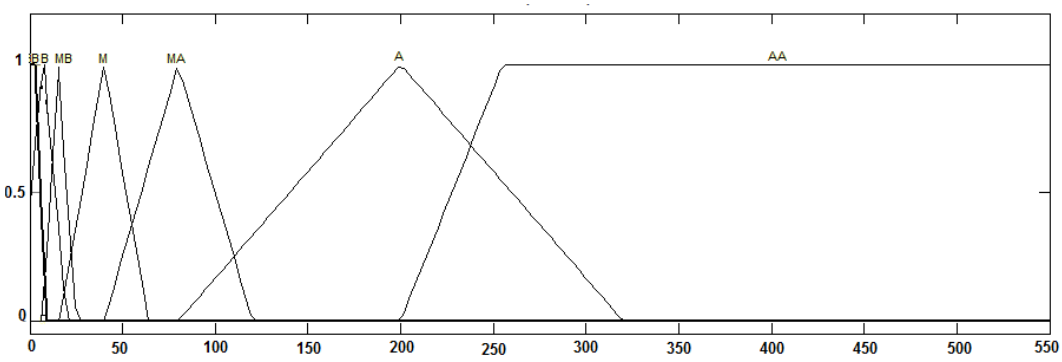


Figura 17. Funciones de membrecía definidas para el pH - Mamdani

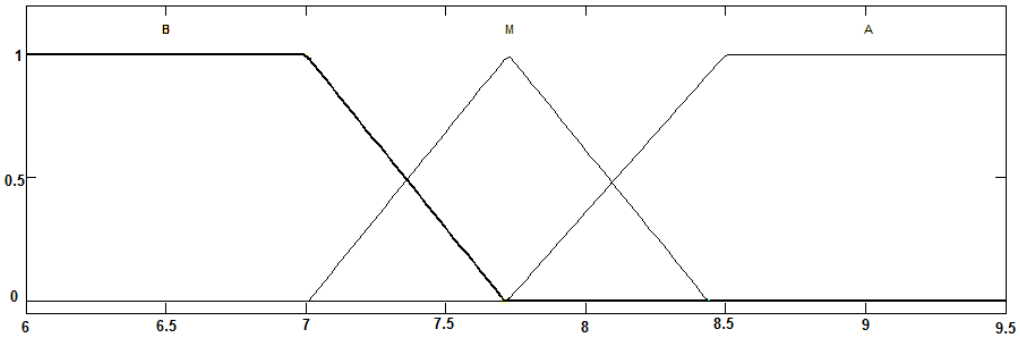
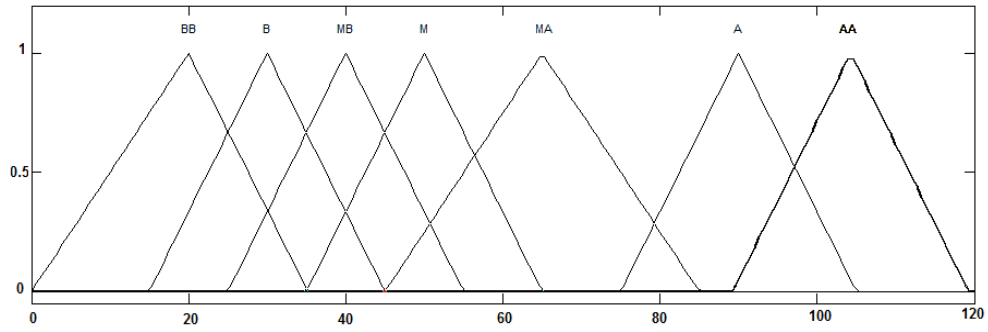
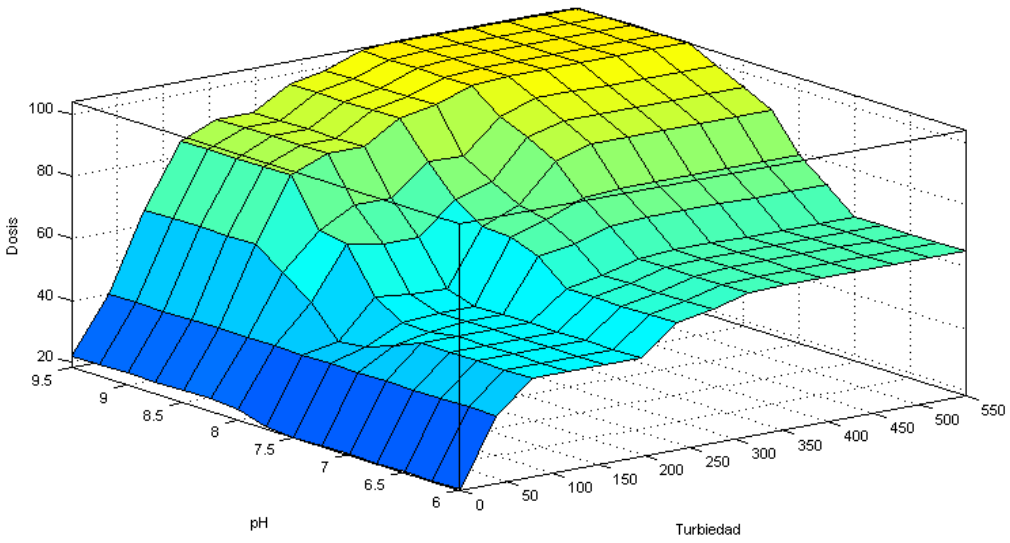


Figura 18. Funciones de membrecía definidas para la dosificación - Mamdani



En la figura 19 se observa la superficie de salida del sistema de inferencia difuso *Mamdani*, en la cual se representa de manera explícita las relaciones no lineales, definidas por medio de las reglas del sistema difuso, que permiten la estimación de la dosificación de coagulante.

Figura 19. Superficie de salida para la estimación de la dosificación del coagulante – Modelo Mamdani.



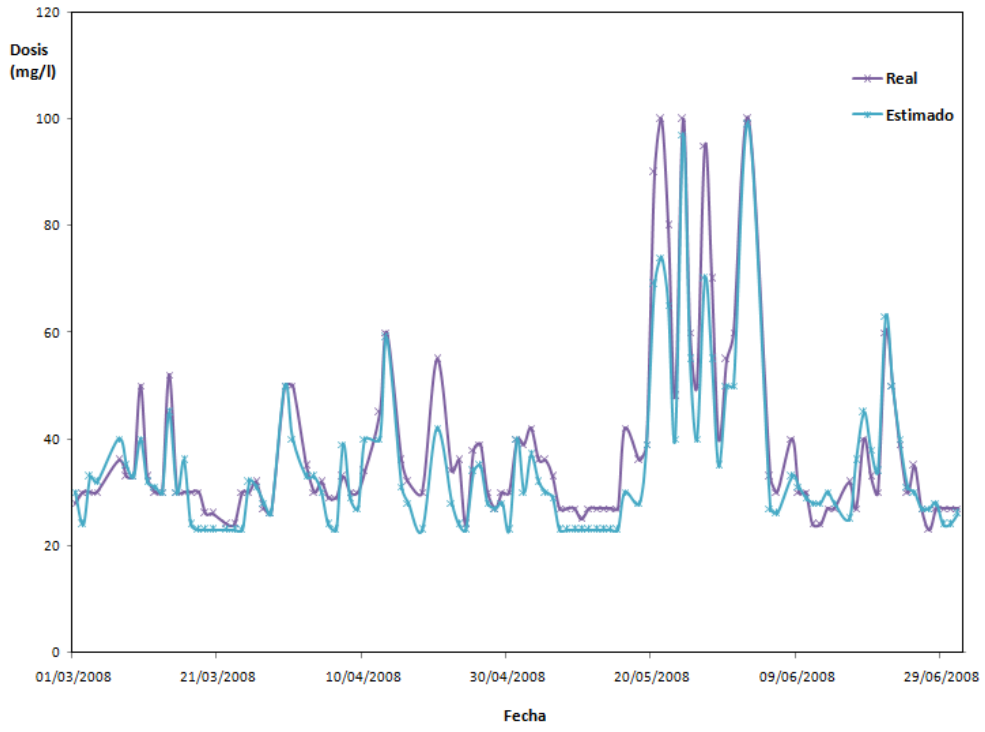
Con el fin de poder evaluar el desempeño del modelo obtenido fueron utilizados nuevamente los índices R^2, *RMSE* y *MAE* cuyos valores obtenidos pueden observarse en la tabla 13. En el anexo 2 aparece el programa en MATLAB con que dichos índices fueron calculados.

Tabla 13. Índices de desempeño del modelo Mamdani, basado en información lingüística

	R^2	RMSE	MAE
Modelo *Mamdani*	0.8615	0.2298	4.7160

Como se observa, los resultados obtenidos por el modelo *Mamdani* (ver tabla 13 y figura 20), son inferiores a los obtenidos con las redes neuronales. Existen dos razones para explicar estos resultados. En primer lugar, si bien los operadores son conocedores del proceso y están en la capacidad de establecer relaciones entre las variables de calidad del agua cruda (turbiedad y pH, en este caso) con la dosificación de coagulante a aplicarse, estas relaciones constituyen simples aproximaciones, ya que la dosificación exacta se determina mediante la prueba de jarras cuyos datos generados fueron precisamente los que se utilizaron en el modelo de redes neuronales. El otro factor que pudo tener alguna incidencia en el resultado final es la no utilización de la conductividad en el modelo *Mamdani.*

Figura 20. Comparación entre la dosificación realizada por medio de pruebas de jarras y el modelo Mamdani



Con el fin de obtener un modelo difuso que se acerque o mejore los índices de desempeño del modelo basado en redes neuronales, en la próxima sección se implementará un sistema difuso tipo *Sugeno* que utilice los mismos datos que sirvieron para la implementación del modelo basado en redes neuronales.

2.3.2. Desarrollo del modelo *Sugeno*

Para la implementación del modelo *Sugeno* se va a partir de información numérica a diferencia de lo realizado en el modelo *Mamdani* donde se trabajó con información lingüística. Dos de las técnicas más comunes para la obtención de modelos de inferencia difusos a partir de información numérica la constituyen el *grid partitioning* y el *clustering*. Mediante el *grid partitioning*, el espacio de entrada es dividido en particiones regulares y la generación de reglas se logra mediante la enumeración de todas las posibles combinaciones de las funciones de membrecía de todas las entradas. Aunque simple, esta estrategia puede llevar a un crecimiento exponencial del número de reglas generadas, prohibitivo para la implementación de un sistema de inferencia difuso práctico. Por ejemplo para un sistema de inferencia difuso de 10 entradas con dos funciones de membrecía cada una, la aplicación del *grid partitioning* conllevaría a la obtención 1024 (2^{10}) reglas [56][57]. Una forma de solucionar esta situación la constituye la utilización de *clustering.*

En términos generales mediante las técnicas de *clustering*, se busca identificar grupos naturales de datos (clústeres), presentes en un gran conjunto de datos, que justifiquen o soporten la existencia de una regla *if-then* de entrada/salida para cada clúster. La principal ventaja de los métodos de *clustering* es que dado que una regla solo se genera donde es encontrado un clúster, el número final de las mismas no dependerá del número de entradas del espacio de datos lo cual evita la explosión combinacional del número de reglas al aumentar la dimensión del espacio de entrada [58]. Entre los métodos de *clustering* principales se encuentran el *Fuzzy-C Means*, y el *Substractive Clustering*.

El *Fuzzy C- Means* es un algoritmo de *clustering* que está basado en la minimización de la función de costo definida en la ecuación 6.

$$J_m(U,P) = \sum_{k=1}^{n}\sum_{i=1}^{c}(u_{ik})^m || x_k - p_i||^2 , \qquad 1 \le m \le \infty \qquad [6]$$

En dicho algoritmo, se parte de la existencia de un conjunto de *N* datos {x_1,x, … , x_N} representados por vectores *n*-dimensionales x_k=[x_{1k}, … ,x_{nk}]. El término u_{ik} representa el grado de pertenencia del vector x_k al clúster *i* y *m* es un exponente que determina el grado

en el cual miembros que pertenecen a un determinado clúster afectan el valor de los centroides p_i. La principal desventaja de este algoritmo es que se debe de antemano especificar el número de clústeres *c* y sus centroides iníciales p_i y la calidad de la solución obtenida, depende en gran parte de la especificación de estos parámetros. Escoger parámetros iníciales (*c* y *pi*) adecuados implica tener un conocimiento *a priori* de la información contenida en los datos (por ejemplo, los clústeres existentes en el conjunto de datos) con la que usualmente no se cuenta, por lo cual es común que en el uso de este algoritmo se deban ejecutar varias pruebas con inicializaciones aleatorias a la espera de que alguna de dichas inicializaciones lleve a la obtención de buenos resultados de *clustering* [59][60]. Una metodología alternativa de *clustering* que evita la necesidad de determinar de antemano el número de clústeres y su ubicación inicial es el *substractive clutering*.

El *substractive clustering* tiene sus orígenes en el algoritmo desarrollado por *Yager* y *Filev* denominado *mountain clustering*. El algoritmo de *Yager* y *Filev* divide el espacio de datos mediante particiones regulares (malla) y a cada punto de la malla le es definido un valor de potencial el cual depende de su distancia a los datos. Un punto de malla con muchos datos cercanos tendrá un alto valor de potencial. El punto de malla con el valor más alto de potencial se selecciona como el primer centro de clúster. Una vez se selecciona el primer clúster, el valor de potencial de los demás puntos de malla se reduce de acuerdo a su distancia al primer clúster seleccionado. El siguiente centro de clúster seleccionado es aquel con mayor valor de potencial restante. El procedimiento de seleccionar nuevos centros de clústeres y reducir el valor de potencial de los puntos de malla restantes continúa hasta que el valor de potencial de todos los puntos de malla queda por debajo de un valor umbral. A pesar de los simple y efectivo de este método, su desventaja principal la constituye el crecimiento exponencial de los cálculos con la dimensión del problema. Por ejemplo, un problema de *clustering* con 4 variables y cada una dividida en 10 partes para formar la partición inicial resultarían en 104 puntos de malla a evaluar. Como respuesta a esta desventaja se propuso el método de s*ubstractive clustering* en el cual cada dato y no cada punto de malla son considerados como un potencial centro de clúster. De esta manera, el número total de puntos a ser evaluados sería igual al número de datos, independiente de la dimensión del problema [58].

De acuerdo a lo anterior es claro que de los algoritmos descritos el que mejor se ajusta a la presente aplicación (donde no se conoce de antemano el probable número de clústeres a formarse) lo constituye el *substractive clustering*. Al utilizar la metodología de *substractive clustering* para la obtención del modelo difuso, el parámetro más importante a definir es el radio del clúster, el cual determina el rango de influencia de los centros de los clústeres y cuya selección afecta tanto los índices de desempeño del modelo difuso como su número de reglas. Un radio muy grande resultaría en pocos clústeres y por consiguiente en un modelo muy burdo. Un radio muy pequeño, por su parte, implicaría un número excesivo de clústeres y en un modelo con capacidad limitada de generalización

(*overfitting*) [58]. Tomando como base los mismos datos empleados para el desarrollo del modelo de redes neuronales, se puede observar en la tabla 14 los índices de desempeño y el número de reglas obtenidas para distintas selecciones en el radio del clúster.

Tabla 14. Desempeño del modelo Sugeno v.s. radio del clúster

Radio	R^2	RMSE	MAE	No. de Reglas
0.5	0.8533	0.2158	4.4150	1
0.2	0.8912	0.1880	3.6800	4
0.15	0.8962	0.1839	3.6048	7
0.1	0.9043	0.1771	3.4488	11
0.09	0.9046	0.1763	3.3658	14

Como se observa, aumentar el radio del clúster por encima de 0.2 hace que el desempeño del modelo se reduzca considerablemente, mientras que la disminución del radio por debajo de 0.1 incrementa la complejidad del modelo (el número de reglas aumenta) sin lograr ningún beneficio importante en el desempeño del modelo. Por tanto haciendo un compromiso entre la complejidad del modelo y su desempeño se selecciona 0.15 como radio para la implementación del modelo *Sugeno.*

En el anexo 2 se observa el programa de MATLAB utilizado para la obtención del modelo *Sugeno* a partir de *substractive clustering*. Es de anotar que mediante la utilización de esta metodología no se encontró diferencia en el resultado final entre la utilización de datos normalizados o datos sin normalizar. En la tabla 15 se muestra la ubicación de los centros de clúster encontrados. Como se observa en la tabla los clúster quedaron ubicados en su totalidad en la región de baja turbiedad y baja dosificación lo cual es lógico teniendo en cuenta que la gran mayoría de los datos se encuentran en esta región.

Tabla 15. Ubicación de los clústeres encontrados mediante substractive clustering.

Cluster	Turbiedad (NTU)	pH	Conductividad (µS/cm)	Dosis (mg/l)
1	7.4	8.4	268	28
2	4.4	8.0	272	23
3	14.0	8.3	248	33
4	4.2	8.5	286	26
5	7.3	7.2	208	30
6	7.0	8.9	257	27
7	3.0	8.0	295	20

En las figuras 21, 22 y 23 se pueden observar las funciones de membrecía encontradas para la turbiedad, pH y conductividad.

Figura 21. Funciones de membrecía definidas para la turbiedad - Sugeno

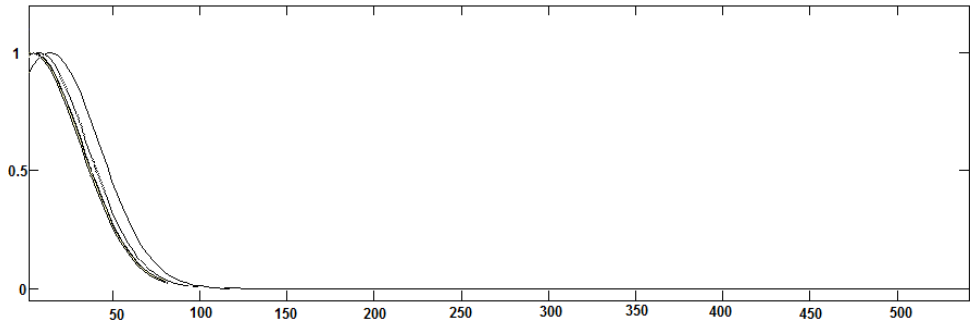


Figura 22. Funciones de membrecía definidas para el pH - Sugeno

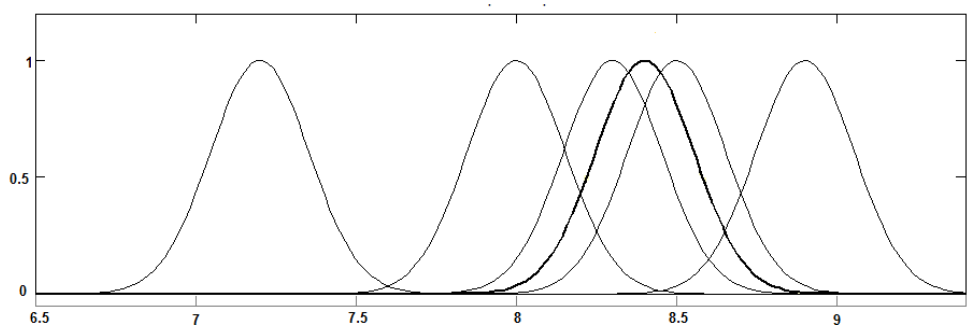


Figura 23. Funciones de membrecía definidas para la conductividad - Sugeno

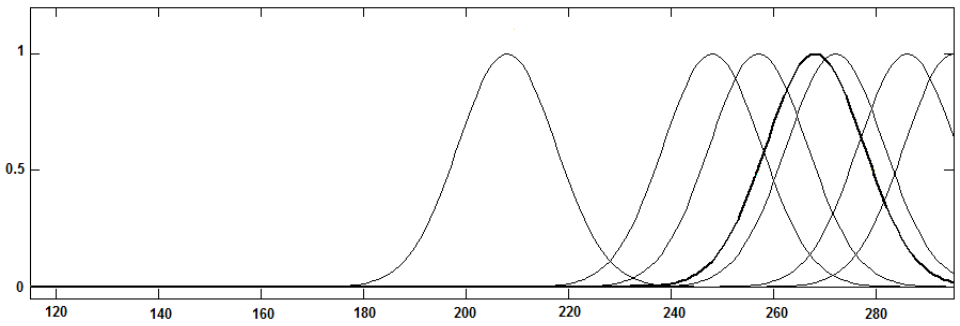
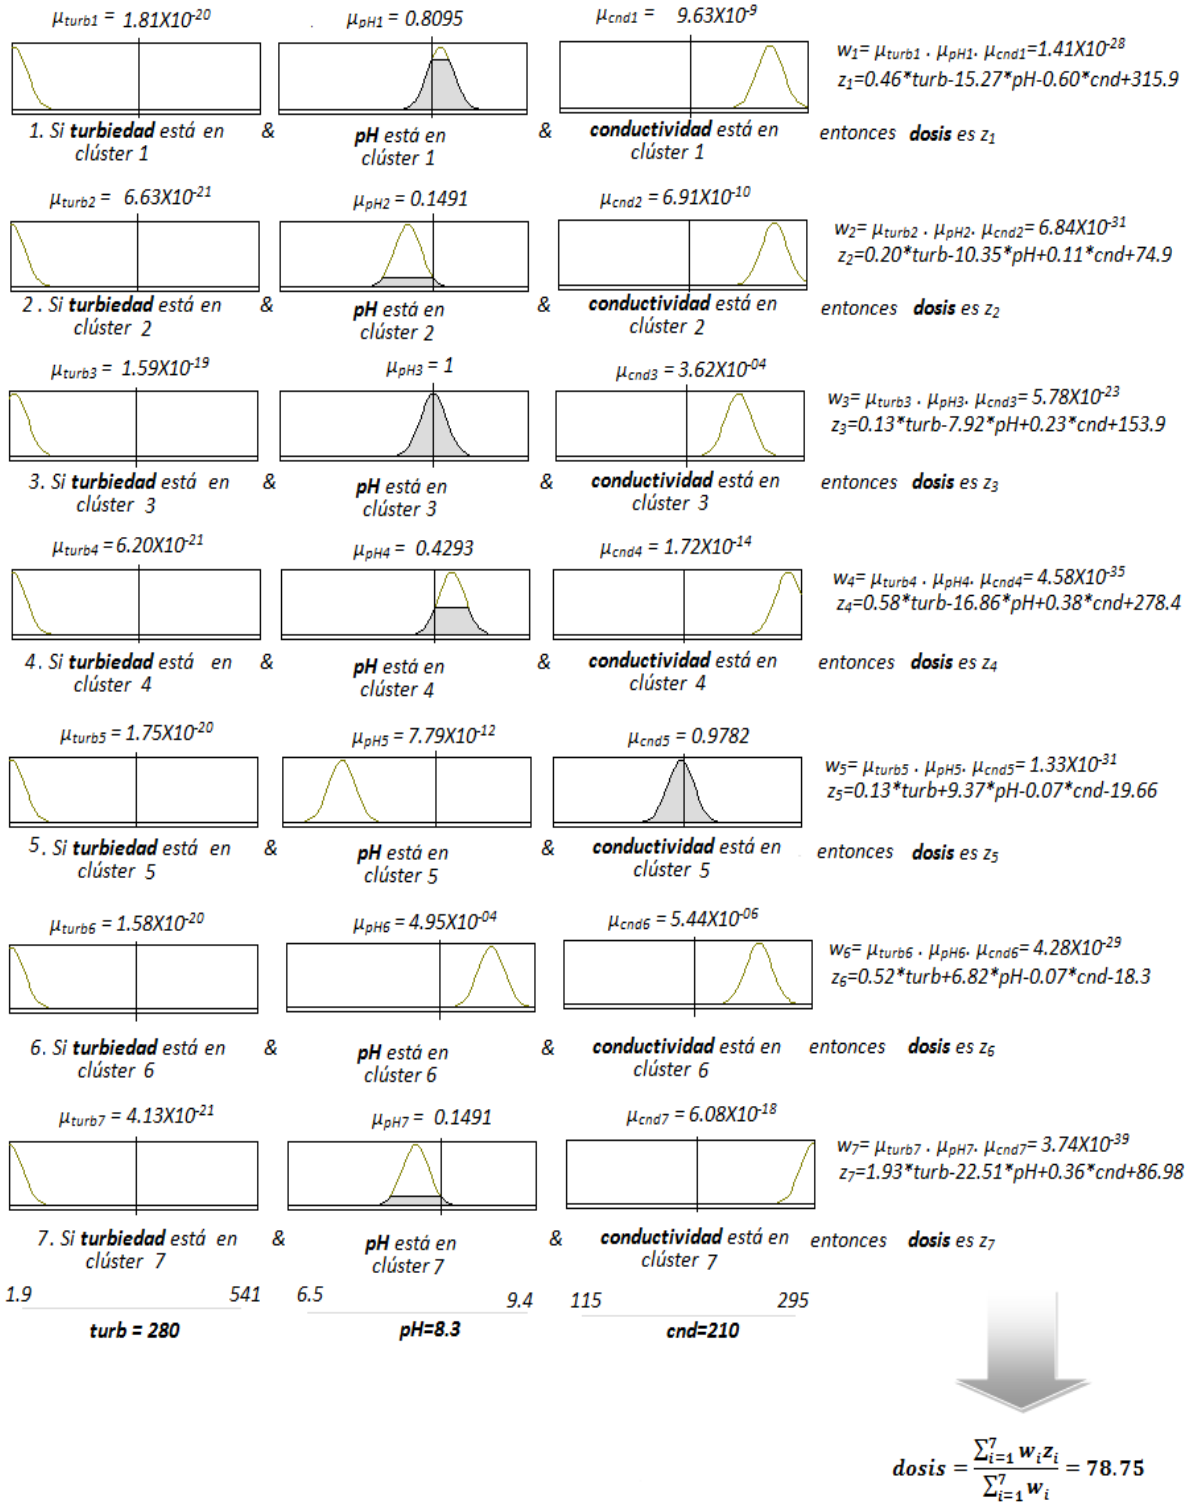


Figura 24. Cálculo de la dosificación de coagulante mediante el sistema de inferencia difuso tipo Sugeno

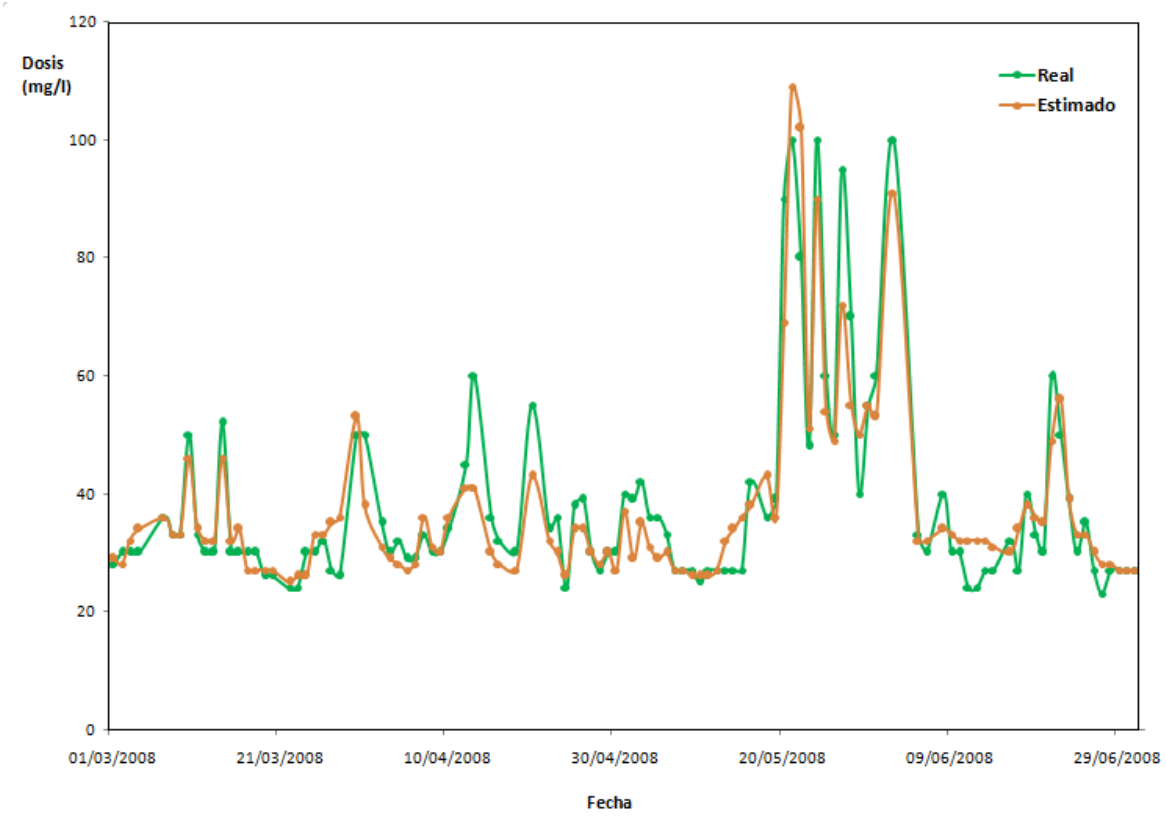


Aunque a primera vista pareciera que por la distribución de las funciones de membrecía no existirán reglas activas para entradas con turbiedades altas, se debe tener en cuenta que las funciones fueron implementadas utilizando funciones gaussianas simétricas de la forma descrita en la ecuación 7.

$$f(x; c, \sigma) = e^{\frac{-(x-c)^2}{2\sigma^2}} \qquad [7]$$

Dichas funciones gaussianas no llegan a ser cero completamente, sin importar que tan alejado se encuentre *x* del centro de la función gausiana *c* (centro del clúster). Con el fin de clarificar la forma como el sistema difuso *Sugeno* estima la dosificación de coagulante, en la figura 24 se ilustra el cálculo de la dosificación para una turbiedad de 280 NTU un pH de 8.3 y una conductividad de 210 µS/cm.

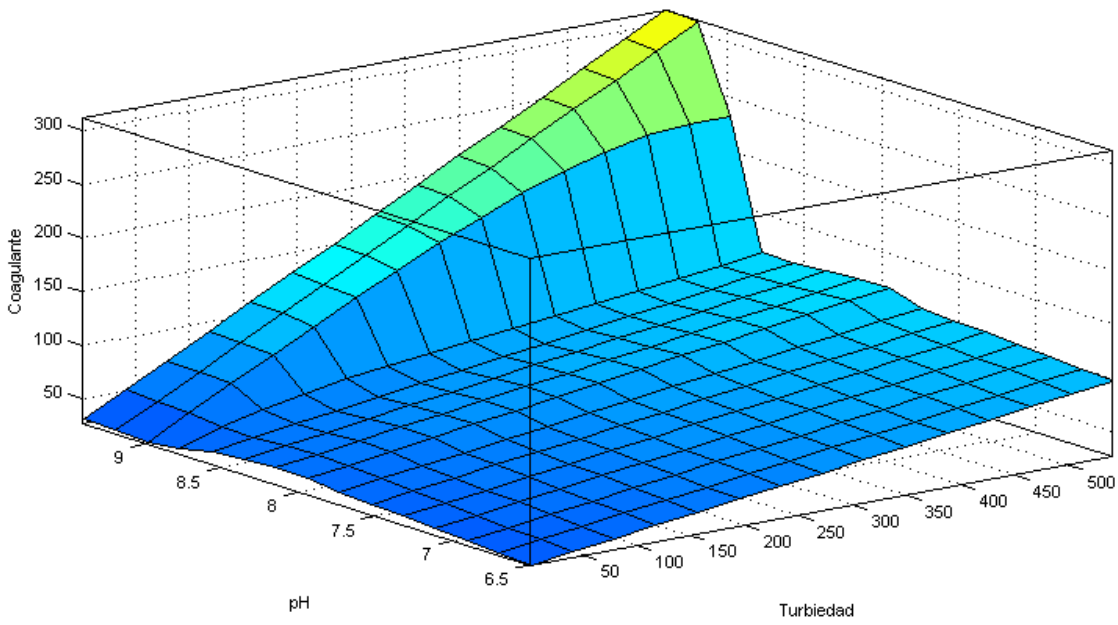
Figura 25. Comparación entre la dosificación realizada por medio de pruebas de jarras y el modelo Sugeno



A partir de los índices de desempeño de la tabla 14 y de la comparación realizada en la figura 25 es posible observar como las estimaciones realizadas por el modelo *Sugeno* superan a las realizadas por el modelo *Mamdani*, con la ventaja adicional de que en el modelo *Sugeno* solo se utilizaron 7 reglas en su implementación, mientras que en el *Mamdani* se emplearon 21.

Por otra parte, al observar la superficie de salida (figura 26) se observa que el sistema de inferencia presenta una región donde la dosificación aumenta de forma desproporcionada para valores de pH por encima de 8.7 aproximadamente. Este comportamiento no es congruente con la experiencia del operador ni con los datos empleados (no existen dosificaciones superiores a 100 mg/l en la base de datos utilizada). Con el fin de mejorar esta situación y obtener mejores índices de desempeño en el modelo *Sugeno*, dicho modelo será sometido a un procedimiento de optimización empleando para tal fin una estructura ANFIS.

Figura 26. Superficie de salida para la estimación de la dosificación del coagulante – Modelo Sugeno (Conductividad constante en 205 µS/cm)

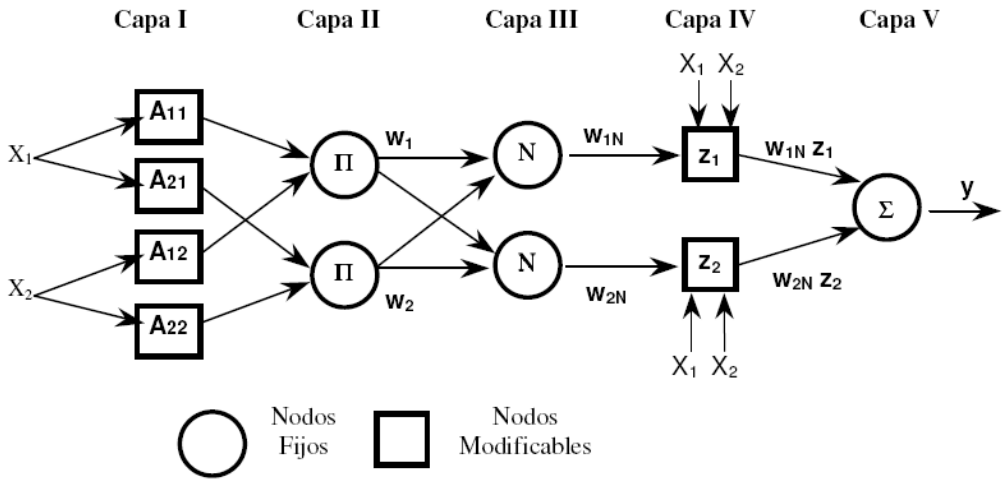


2.4. ESTRUCTURA ANFIS

Una de las motivaciones para el desarrollo de la arquitectura ANFIS fue la necesidad de una metodología que permitiera el ajuste de las funciones de membrecía de los sistemas difusos y así de esta forma, minimizar la medida del error de salida o maximizar los índices de desempeño del modelo difuso. Como resultado de la investigación llevada a cabo por *Jang, R. [61],* se desarrolló la estructura ANFIS que permitía el ajuste de las funciones de membrecía de los sistemas difusos mediante un aprendizaje híbrido basado en gradiente descendiente y mínimos cuadrados. En la figura 27 se observa una estructura ANFIS para un sistema difuso de dos entradas.

Haciendo uso de una arquitectura ANFIS se realiza el ajuste del modelo *Sugeno* desarrollado en la sección anterior. En el anexo 2 se observa el programa en MATLAB utilizado para tal fin. Cabe anotar que para hacer uso de la estructura ANFIS es necesario normalizar los datos por tanto el modelo Sugeno que se optimizará deberá ser un modelo construido a partir de datos normalizados.

Figura 27. Estructura ANFIS para un sistema difuso de 2 entradas



Sistemas Neuro Difusos. Grupo de Investigación Percepción y Sistemas Inteligentes. Universidad del Valle.[62]

Tabla 16. Parámetros de la funciones de membrecía modelo Sugeno normalizado.

Función de Membrecía	Turbiedad (σ/c)	pH (σ/c)	Conductividad (σ/c)
1	0.0530/0.0104	0.0530/0.6552	0.0510/0.8556
2	0.0530/0.0048	0.0530/0.5172	0.0510/0.8770
3	0.0530/0.0226	0.0530/0.6207	0.0510/0.7487
4	0.0530/0.0045	0.0530/0.6897	0.0510/0.9519
5	0.0530/0.0102	0.0530/0.2414	0.0510/0.5348
6	0.0530/0.0096	0.0530/0.8276	0.0510/0.7968
7	0.0530/0.0022	0.0530/0.5172	0.0510/1.0000

Tabla 17. Parámetros de la funciones de membrecía modelo ANFIS.

Función de Membrecía	Turbiedad (σ/c)	pH (σ/c)	Conductividad (σ/c)
1	0.0769/0.0183	0.0542/0.6536	0.0649/0.8578
2	0.0494/0.0042	0.0514/0.5175	0.0755/0.8701
3	0.0385/0.0166	0.0410/0.6294	0.0569/0.7498
4	0.0473/0.0012	0.0548/0.6901	0.0623/0.9461
5	0.0459/0.0109	0.0486/0.2401	0.0541/0.5334
6	0.0530/0.0096	0.0546/0.8264	0.0570/0.7936
7	0.0531/0.0026	0.0548/0.5176	0.0629/0.9953

Con la utilización de la estructura ANFIS, se modifican los parámetros σ (ancho) y c (centro) de las funciones gaussianas que definen las funciones de membrecía del sistema difuso, lo cual puede verificarse al observar las tablas 16 y 17. Cabe resaltar, como el sistema difuso hallado por *substractive clustering* deja fijo el parámetro σ en las funciones de membrecía de cada variable (de hecho para la turbiedad y el pH el parámetro es el mismo) mientras que en el modelo ANFIS dicho parámetro es diferente en cada una de las funciones de membrecía, situación ésta que de alguna forma se ve reflejada en las superficies de salida de los dos modelos. De las figuras 28 y 29 se observa también como el salto desproporcionado en la dosis al aumentar el pH por encima de 8.7 que se presentaba en el modelo *Sugeno*, ya no aparece en el modelo ANFIS. Ambas superficies fueron graficadas con la conductividad (normalizada) constante en 0.5. Finalmente, de acuerdo a la comparación realizada en la figura 30 y a los índices de desempeño de la tabla 18, es claro como la aplicación de la estructura ANFIS permitió la obtención de un sistema de inferencia difuso más preciso que al obtenido mediante la sola utilización del *substractive clustering*.

Figura 28. Mapeado entrada/salida del modelo Sugeno normalizado antes de aplicar la optimización por estructura ANFIS

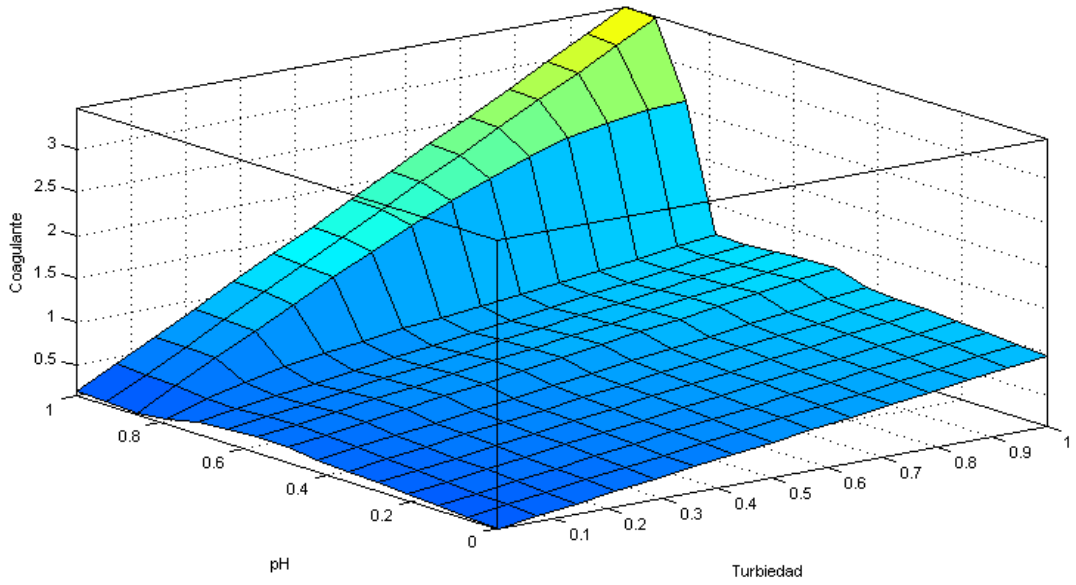


Figura 29. Mapeado entrada/salida del modelo Sugeno normalizado después de aplicar la optimización por estructura ANFIS

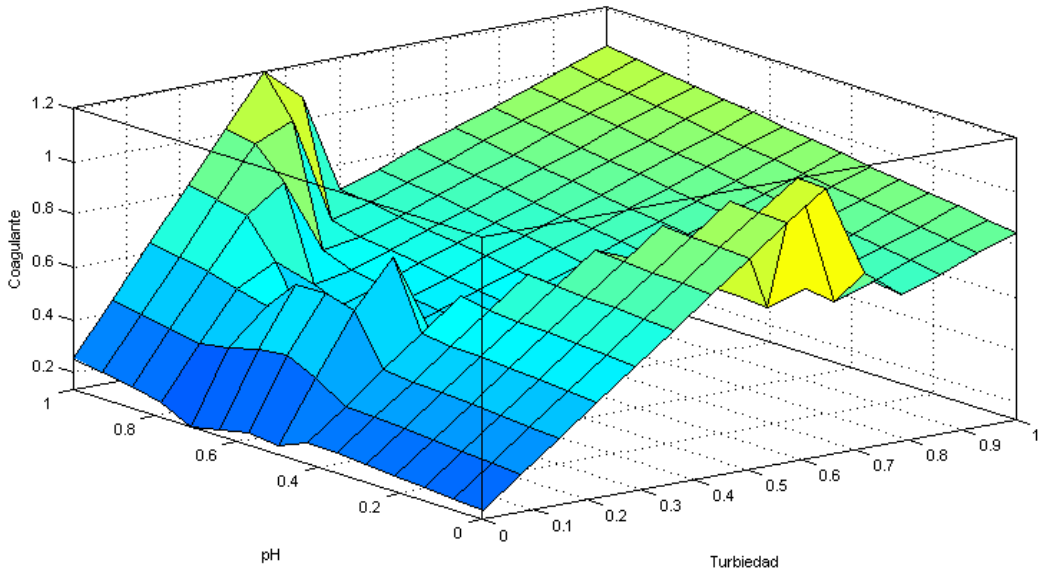
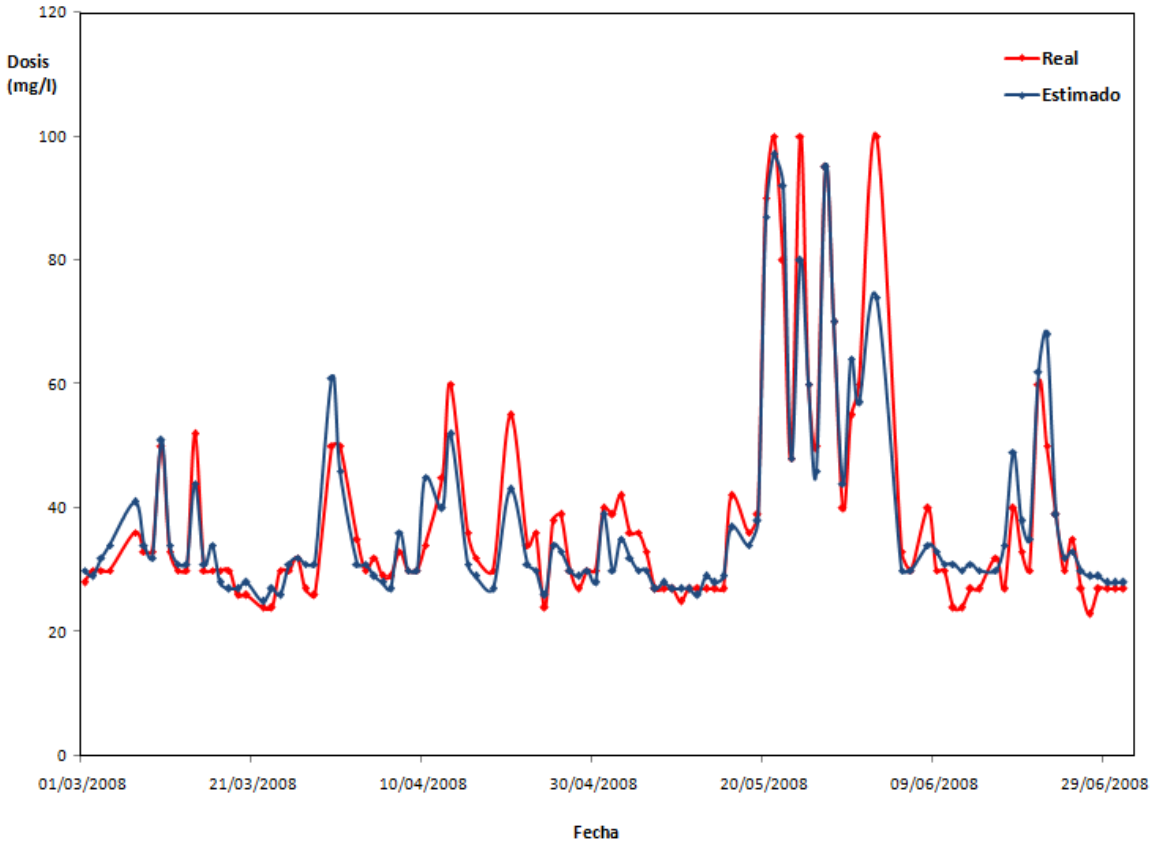


Tabla 18. Índices de desempeño del modelo ANFIS

	R^2	RMSE	MAE
Modelo ANFIS	0.9232	0.1592	3.0501

Figura 30. Comparación entre la dosificación realizada por medio de pruebas de jarras y el modelo ANFIS



2.5. CONCLUSIONES

Se presenta de manera detallada el proceso por medio del cual fue posible obtener modelos para la estimación de coagulante basados en redes neuronales, lógica difusa (*Mamdani* y *Sugeno*) y estructuras neuro-difusas tipo ANFIS. En la tabla 19, se observa un resumen con los índices de desempeño de los cuatro modelos obtenidos.

Tabla 19. Resumen índices de desempeño de los modelos obtenidos

Modelo	R^2	RMSE	MAE
Redes Neuronales	0.9393	0.1419	2.9642
Mamdani	0.8615	0.2298	4.7160
Sugeno	0.8962	0.1839	3.6048
ANFIS	0.9232	0.1592	3.0501

Como se observa el modelo que presenta los mejores índices de desempeño es el basado en redes neuronales, mientras que de los tres modelos que se implementaron usando inferencia difusa el que mejor resultado entregó fue el que empleó la estructura ANFIS, la cual comparte con las redes neuronales el mismo tipo de entrenamiento. Por su parte el modelo *Mamdani* el cual se obtuvo a partir de información lingüística proporcionada por el operador de planta fue el que peores índices de desempeño presentó, sin embargo, presenta la ventaja de que fue construido con base en reglas fácilmente entendibles por el ser humano.

3. TÉCNICAS DE INTELIGENCIA COMPUTACIONAL PARA LA VALIDACIÓN DE INFORMACIÓN

3.1. INTRODUCCIÓN

Los modelos obtenidos en el capítulo 2, se incluirán en esquemas de control tipo *feedforward*, en los cuales la información de entrada a los modelos será suministrada por sensores de calidad de agua (turbiedad, pH y conductividad) los cuales pueden en un momento dado fallar y suministrar información errada y de esta forma llevar a dosis de coagulante no acordes con las condiciones reales de la calidad del agua cruda. Por esta razón, es importante, realizar una validación de la información suministrada por los sensores antes de que ésta sea procesada por el modelo de estimación.

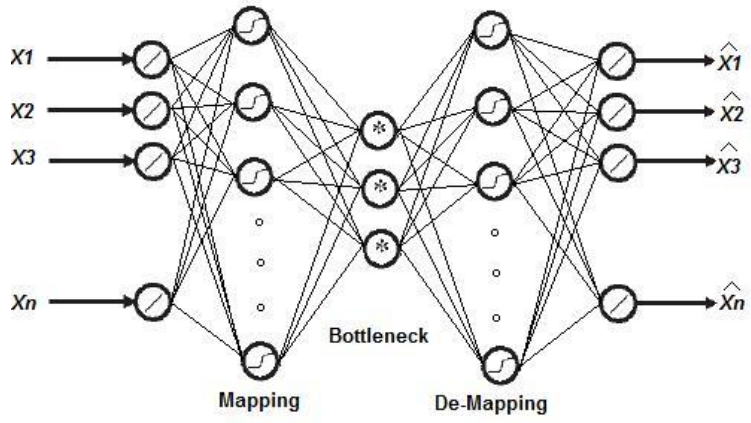
La validación de la información suministrada por sensores incluye tres etapas, la detección, el aislamiento y la reconstrucción [63] [64]. La primera etapa consiste en la capacidad del sistema de validación de reconocer cuando la información suministrada por uno o más sensores es incorrecta, en la segunda, una vez es detectada la falla el sistema de validación debe, como su nombre lo indica, aislar la falla para no tomar decisiones con base a esta información errónea y finalmente, en la tercera etapa, tratar de reconstruir la información que se suponía debía entregar el sensor en falla. La capacidad de poder reconstruir la información a ser suministrada por un sensor en falla depende en gran medida de la posibilidad de contar con redundancia analítica en el conjunto de sensores que están siendo validados. Un ejemplo de esta redundancia, se puede observar en el numeral *2.1.5.3* del capítulo anterior, donde se demostró la alta correlación existente entre las variables color y la turbiedad en el agua cruda. Por tanto, si se contará con sensores independientes para cada una de estas variables y alguno de los sensores fallara, se estaría en la capacidad de reconstruir la información del sensor en falla a partir de la información suministrada por el otro sensor, dada la redundancia de información existente entre ambas variables. Los métodos para la validación de la información

suministrada por sensores, incluyen sistemas basados en modelos (utilizados ampliamente en la industria aeroespacial) y técnicas de inteligencia computacional como las redes neuronales auto-asociativas y los mapas auto-organizados de *Kohonen*. En este capítulo se aborda el problema de la validación de información mediante las redes neuronales auto-asociativas.

3.2. REDES NEURONALES AUTO-ASOCIATIVAS

El concepto de las redes neuronales auto-asociativas (*AANN*, por sus siglas en inglés) fue desarrollado por *Kramer* [65] a principios de la década de los años noventa y buscaba la reducción de la dimensión de un conjunto de datos mediante una técnica denominada análisis de componentes principales no lineales [66].

Figura 31. Redes neuronales auto-asociativas



GALOTTO, L; et al. Auto-Associative Neural Network Based Sensor Drift Compensation in Indirect Vector Controlled Drive System

Las redes neuronales auto-asociativas son redes del tipo perceptron multicapa (*MLP*, por sus siglas en inglés) que reproducen en su salida las entradas de la red y que constan de una capa de entrada, tres capas ocultas y una capa de salida. Aunque teóricamente tres capas ocultas son suficientes para una red tipo *AANN*, capas ocultas adicionales pueden mejorar el desempeño del modelo y ayudan a mapear de manera más efectiva las relaciones entre las variables de entrada y salida de la red [65]. Como se observa en la

figura 31, las neuronas de las capas de entrada y salida de la red auto-asociativa tienen funciones de transferencia lineales, mientras que las neuronas de las capas de mapeo (*mapping layer*) y de-mapeo (*de-mapping layer*), tienen funciones de transferencia no lineales (por ejemplo, tipo sigmoidal). En el caso de la segunda capa oculta (*bottleneck layer*) es posible utilizar tanto funciones lineales como no lineales. La red completa puede considerarse como la conexión en cascada de dos sub-redes de tres capas cada una, donde la eliminación de la redundancia de los datos es llevada a cabo en la capa de compresión (*bottleneck layer*). Durante el entrenamiento, la capa de compresión (*bottleneck layer*) fuerza a la red *AANN* a codificar la información de entrada para después decodificarla o descomprimirla para reproducir las entradas de la red en sus salidas. De esta forma, las salidas no muestran ningún cambio significativo, cuando el correspondiente patrón de entrada ha sido distorsionado por ruido, pérdidas de datos o no-linealidades. Esta característica, permite a las redes *AANN* detectar desviaciones o fallas en los sensores, al comparar la salida del sensor con la correspondiente estimación de la red.

Figura 32. Comportamiento de la turbiedad y el color en el muestreo tomado para la construcción de la red neuronal auto-asociativa

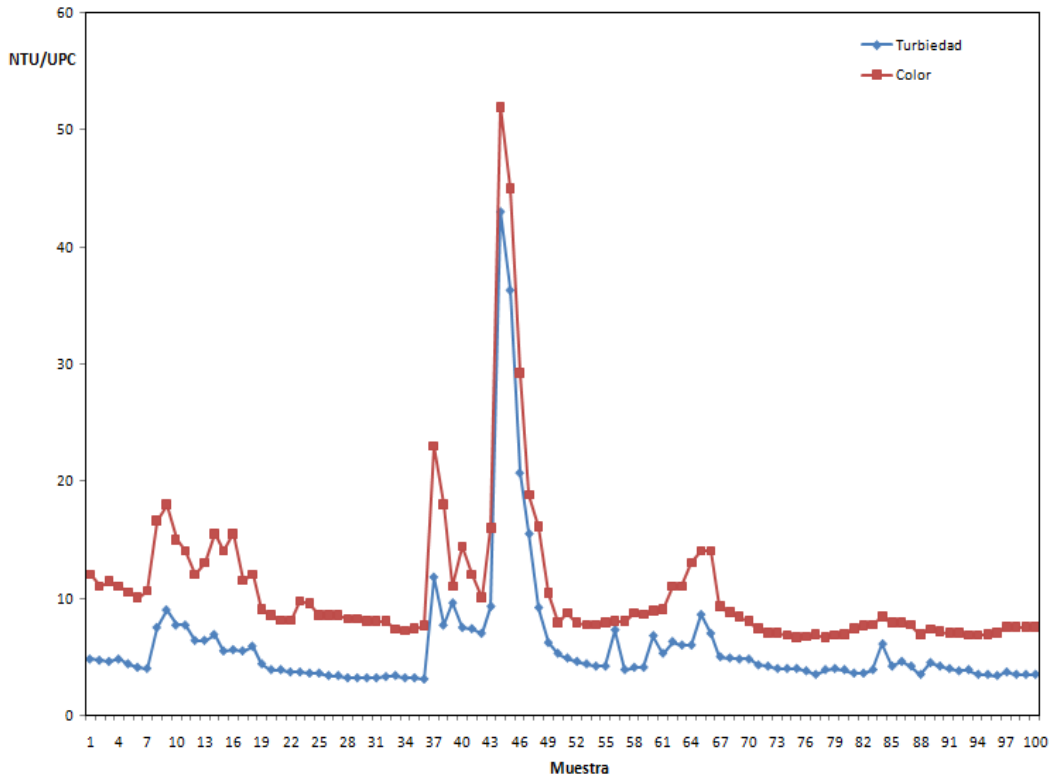
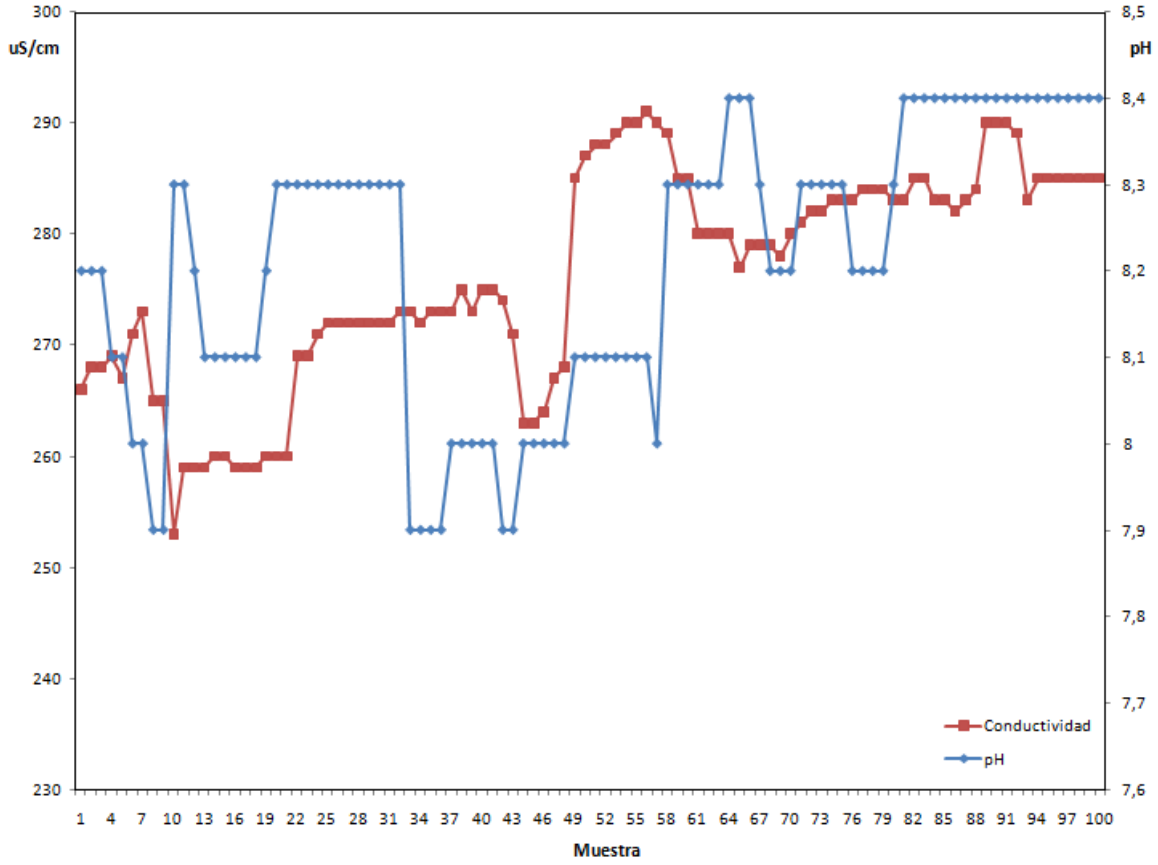


Figura 33. Comportamiento del pH y la conductividad en el muestreo tomado para la construcción de la red neuronal auto-asociativa



3.2.1. Obtención del modelo de *AANN* para la validación de información

Con el fin de ilustrar el concepto de la validación de la información mediante la utilización de redes neuronales auto-asociativas, se asume que se cuenta con cuatro sensores que proporcionan la medición de la calidad del agua cruda que sirve de entrada al modelo de estimación de la dosificación de coagulante. Las cuatro variables medidas son color, turbiedad, pH y conductividad. Los datos a emplearse para la construcción de la red neuronal auto-asociativa corresponden a una muestra de 100 datos pertenecientes al monitoreo de las condiciones de calidad del agua cruda (hora a hora) entre las 00:00 horas del día 2 Febrero de 2009 y las 03:00 horas del día 6 de Febrero de 2009 en la planta de potabilización del municipio de Roldanillo – Valle del Cauca (ver anexo 3). El comportamiento de las variables se observa en las figuras 32 y 33.

Las características de la red neuronal auto-asociativa que se entrenó a partir de los datos del anexo 3, se observan en la tabla 20. En el anexo 2 se encuentra el programa en MATLAB con que se generó la red neuronal auto-asociativa.

Tabla 20. Características de la red neuronal auto-asociativa 4-8-3-8-4 para la validación de la información

Número de neuronas de entrada	**4**
Número de capas ocultas	3
Número de neuronas en la capa *mapping*	8
Número de neuronas en la capa *bottleneck*	3
Número de neuronas en la capa *de-mapping*	8
Variables de entrada	Color, Turbiedad, pH y Conductividad
Variables de salida	Color, Turbiedad, pH y Conductividad
Función de activación en las neuronas de la capa oculta	Sigmoidal Bipolar (*tansig*)
Función de activación de las neuronas de la capa de salida	Lineal (*purelin*)
Algoritmo de entrenamiento	Levenberg-Marquardt (*trainlm*)

Los errores máximos absolutos encontrados entre los valores reales de las variables que sirven de entrada a la red y las estimaciones realizadas por la red auto-asociativa fueron las siguientes:

Tabla 21. Errores máximos de las estimaciones de la red neuronal auto-asociativa.

Variable	Error Máximo
Turbiedad	0.0653
Color	0.0492
pH	0.0952
Conductividad	0.0466

Cabe anotar que los valores de la tabla 21 corresponden a los errores obtenidos con los datos normalizados en el rango 0-1.

3.2.2. Procedimiento de validación

Para simular el funcionamiento de la red neuronal auto-asociativa para la validación de la información generada por los sensores, se va a considerar una posible falla en el sensor que mide la turbiedad. Las fallas en este tipo de sensores generalmente ocurren cuando algún tipo de material se deposita en su lente ocasionando un cambio abrupto en la lectura de la turbiedad del sensor.

El procedimiento general para la validación de la información proporcionada por los sensores mediante el uso de la red neuronal auto-asociativa, de acuerdo a lo descrito en [33], es el siguiente:

- Los errores máximos encontrados en las estimaciones de la red neuronal auto-asociativa, consignados en la tabla 21, constituyen los valores umbral para detectar el fallo en alguno de los sensores. En nuestro caso, para la turbiedad dicho valor es de 0.0653.

- Si al comparar la turbiedad a la entrada de la red neuronal con la turbiedad a la salida de la misma, se observa que se supera el valor umbral, se declara que dicho sensor está en falla.

- Con la detección de la falla se procede a aislar la información proporcionada por el sensor y se reemplaza por la información proporcionada por la salida de la red neuronal auto-asociativa.

Con el procedimiento descrito anteriormente, es posible con el solo uso de la red neuronal auto-asociativa implementar los tres pasos que comprenden el proceso de la validación de la información proporcionada por sensores, detección, aislamiento y reconstrucción. Sin embargo, como se verá más adelante, dicho procedimiento no siempre funciona apropiadamente y puede requerir el uso de herramientas de inteligencia computacional adicionales tales como los algoritmos genéticos.

3.2.3. Simulaciones y resultados obtenidos con la red neuronal auto-asociativa

Con el fin de analizar el desempeño de la red neuronal auto-asociativa, se van a analizar tres casos que difieren en la magnitud del error generado en la lectura del sensor en falla.

3.2.3.1 Error suave. En este caso se asume que la lectura en falla proporcionada por el sensor se aleja poco de la lectura real. Tomando como base los datos normalizados que se ingresan como entrada a la red neuronal auto-asociativa se simula que de la muestra 80 a la muestra 100 el sensor permanece constante en un valor normalizado de 0.025 (equivalente a 4.1 NTU). En este tipo de falla, no se supera ni siquiera el valor umbral necesario para su detección y aislamiento. Sin embargo, la desviación del valor proporcionado por el sensor respecto al valor real de la turbiedad es tan baja, que el efecto que tendría en el modelo de la estimación de coagulante sería poco significativo. Por tanto, no se considera crítica la no detección de esta falla por parte de la red neuronal auto-asociativa. En la figura 34 se observan los errores obtenidos en cada una de los variables y en la figura 35 la comparación entre el valor real de la turbiedad, la turbiedad reportada por el sensor en falla y el valor de la turbiedad a la salida de la red neuronal auto-asociativa. Como se observa en la figura 35, la turbiedad proporcionada por la salida de la red neuronal se acerca bastante a la turbiedad real y aunque no pudo detectarse la falla del sensor por no superar el error el valor umbral, deja ver que este tipo de red presenta *inmunidad* a ciertos niveles de ruido presentes en la señal del sensor, propiedad esta que puede ser explotada en el filtrado de señales tal como se describe en [64].

Figura 34. Errores obtenidos entre la entrada y salida de la red neuronal auto-asociativa para un error suave

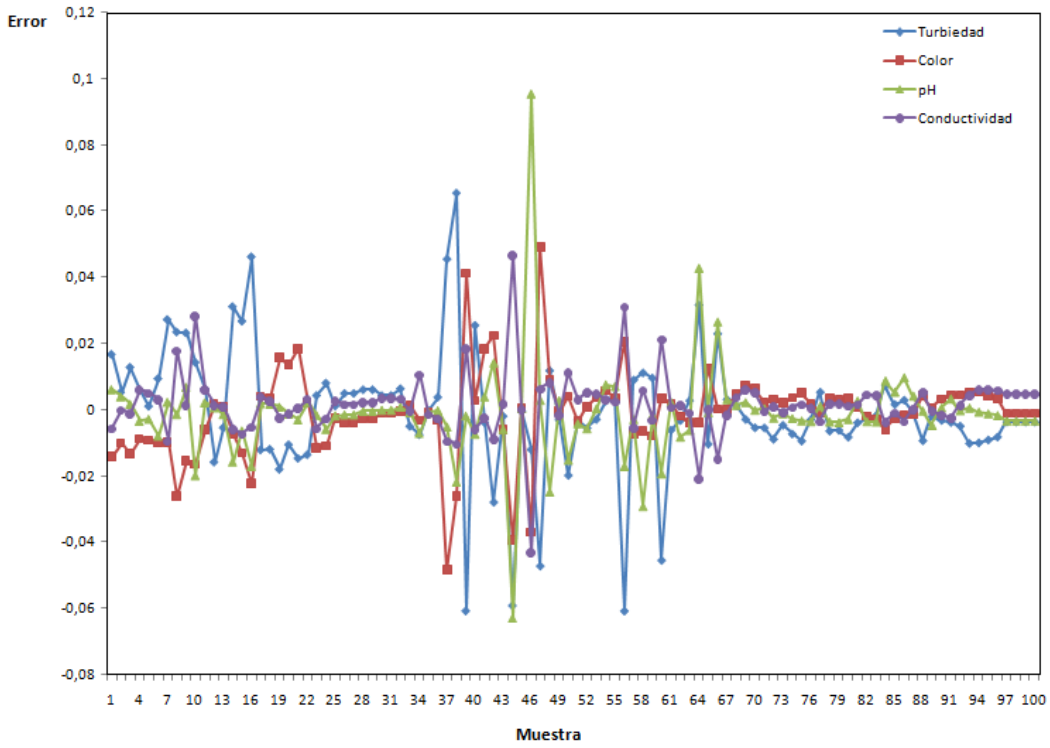
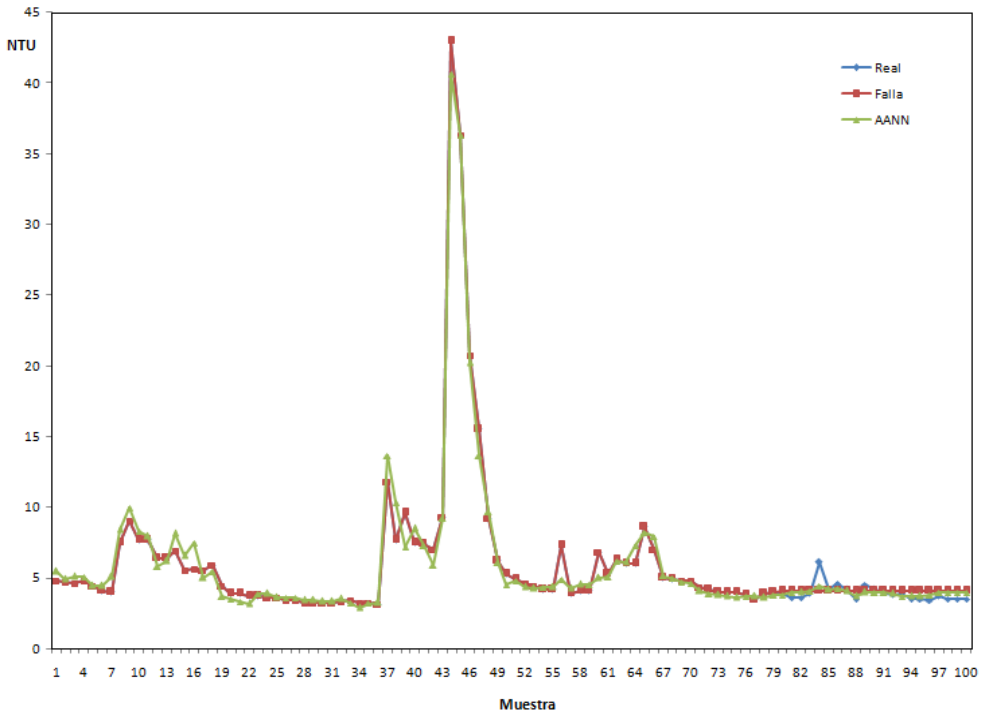


Figura 35. Comparación de las turbiedades obtenidas ante un error suave



3.2.3.2 Error moderado. En este caso se asume que la lectura en falla proporcionada por el sensor se aleja un poco más de la lectura real. Tomando como base los datos normalizados que se ingresan como entrada a la red neuronal auto-asociativa se simula que de la muestra 80 a la muestra 100 el sensor permanece constante en un valor de 0.150 (equivalente a 9 NTU). En este tipo de error, se supera el valor umbral necesario para la detección y aislamiento del sensor en falla. Por tanto la turbiedad reportada por el sensor es reemplazada por la que se encuentra a la salida de la red neuronal auto-asociativa.

En la figura 36 se observan los errores obtenidos en cada uno de las variables y en la figura 37 la comparación entre el valor real de la turbiedad, la turbiedad reportada por el sensor en falla y el valor de la turbiedad a la salida de la red neuronal auto-asociativa.

De la figura 36 es claro como todos los errores de las variables que maneja la red neuronal auto-asociativa presentaron perturbaciones importantes a partir de la muestra 80 pero únicamente, el error correspondiente a la turbiedad superó el valor umbral definido en la tabla 21. En la figura 37, se observa cómo es posible la reconstrucción de la señal de turbiedad a partir del valor reportado por la red neuronal auto-asociativa en su salida.

Figura 36. Errores obtenidos entre la entrada y salida de la red neuronal auto-asociativa para un error moderado.

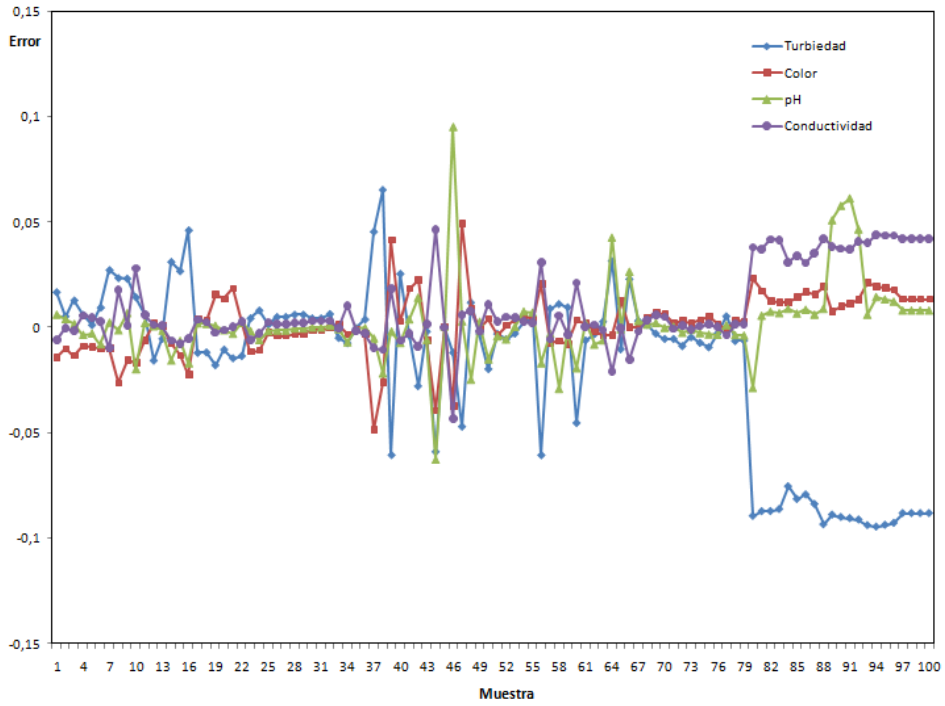
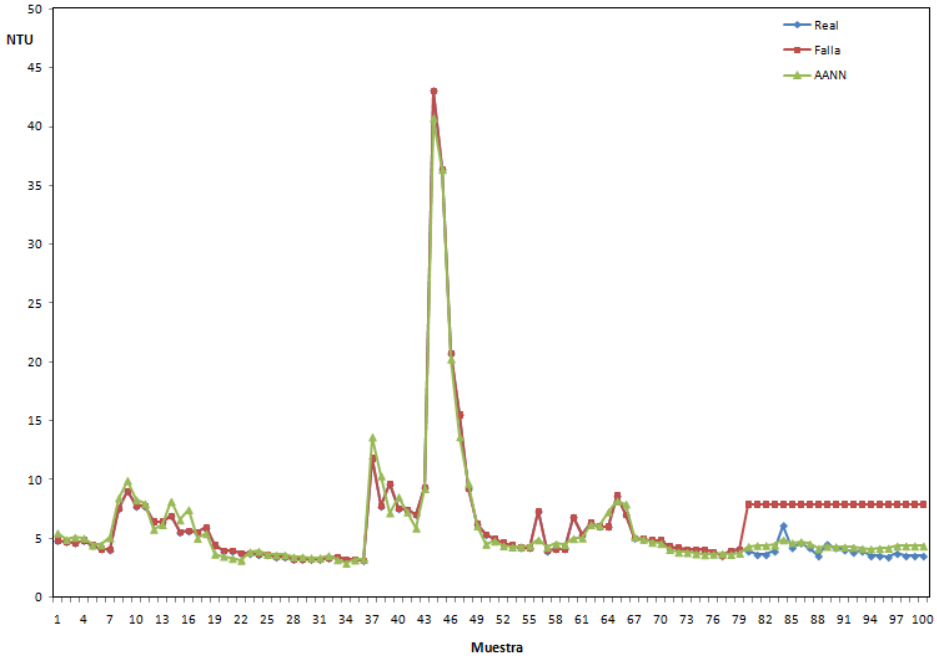


Figura 37. Comparación de las turbiedades obtenidas ante un error moderado



3.2.3.3 Error fuerte. En este caso se asume que la lectura en falla proporcionada por el sensor se aleja fuertemente de la lectura real. Tomando como base los datos normalizados que se ingresan como entrada a la red neuronal auto-asociativa se simula que de la muestra 80 a la muestra 100 el sensor permanece en constante en un valor de 0.95 (equivalente a 45 NTU). En la figura 38 se observan los errores obtenidos en cada una de las variables y en la figura 39 la comparación entre el valor real de la turbiedad, la turbiedad reportada por el sensor en falla y el valor de la turbiedad a la salida de la red neuronal auto-asociativa. De la figura 38 es claro que no solo el error del sensor que estaba en falla superó el umbral de detección sino que las otras variables también lo superaron, lo cual de entrada ya presupone un problema, ya que de acuerdo al procedimiento de validación inicialmente planteado todos los sensores serían declarados como defectuosos. Además asumiendo que se cuente con un mecanismo que permita determinar que el sensor en falla es el correspondiente al de la turbiedad, la reconstrucción de la señal obtenida a partir de la salida de la red neuronal auto-asociativa (tal como se observa en la figura 39) tampoco es satisfactoria (incluso arroja valores negativos) y su diferencia con el valor real tendría consecuencias profundas al utilizar dicha información en el modelo de estimación de coagulante.

Figura 38. Errores obtenidos entre la entrada y salida de la red neuronal auto-asociativa para un error fuerte.

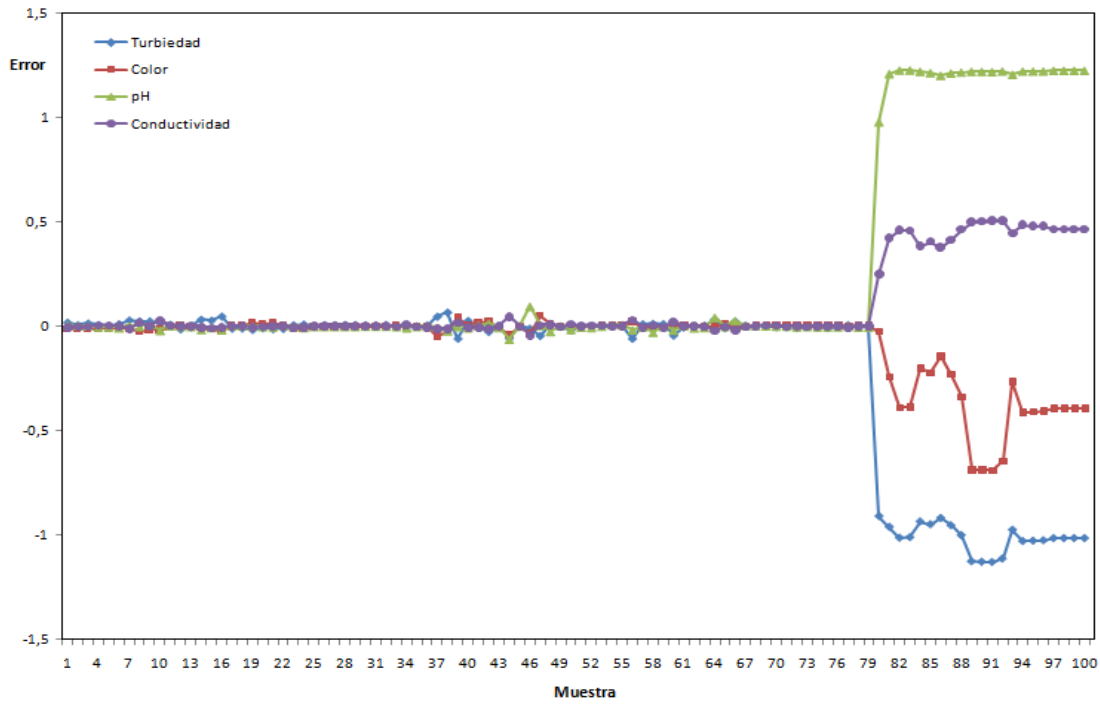
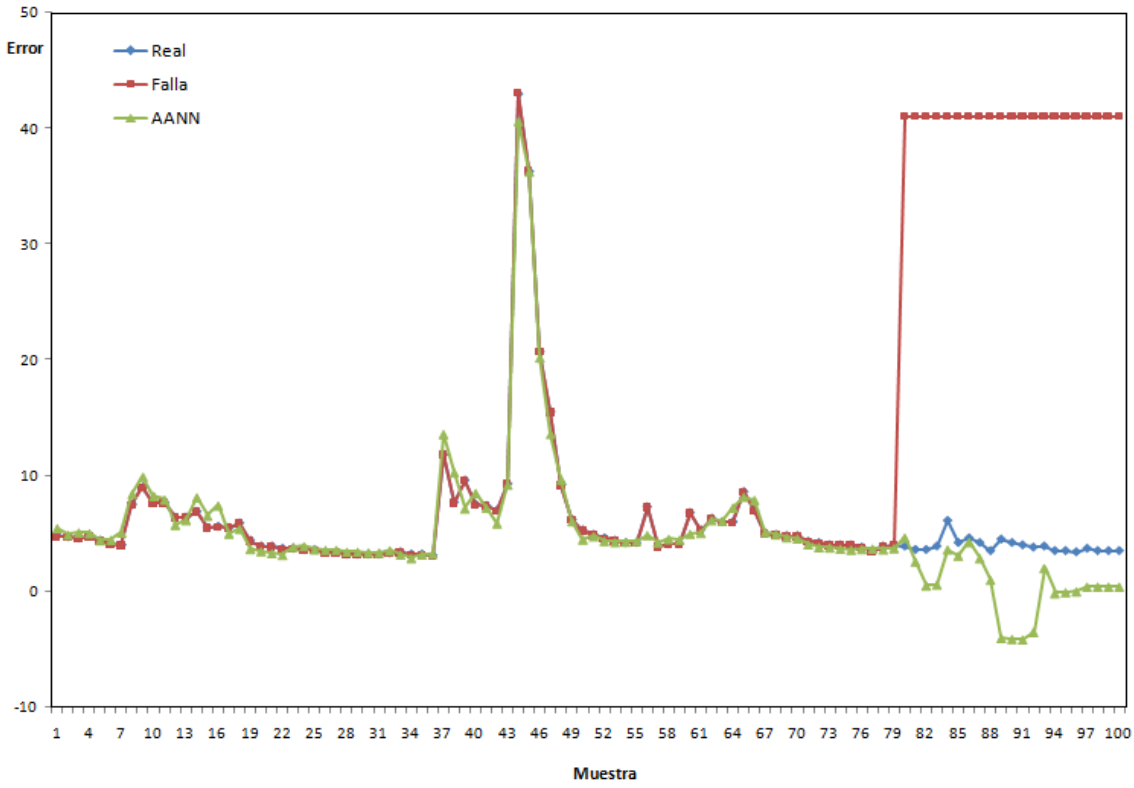


Figura 39. Comparación de las turbiedades obtenidas ante un error fuerte con reconstrucción de señal mediante redes neuronales auto-asociativas



Del análisis anterior, es claro como la sola utilización de la red neuronal auto-asociativa para la implementación de los tres pasos que comprenden la validación de la información reportada por los sensores (detección, aislamiento y reconstrucción) no es suficiente, bajo ciertas circunstancias, sobre todo en el paso de la reconstrucción de la información. Con el fin de superar esta limitación se hará uso de algoritmos genéticos los cuales junto con la red neuronal auto-asociativa permitirán la implementación de un sistema de validación más robusto. La implementación de este sistema se basa en lo propuesto por *Lu P.* y *Hsu T.* en [64].

3.3. ALGORITMOS GENÉTICOS

Los algoritmos genéticos (*GA*, por sus siglas en inglés) hacen parte de la rama de la inteligencia artificial denominada computación evolutiva la cual se concentra en los

aspectos sociales de los seres vivos, a diferencia de las redes neuronales que se enfoca en los aspectos morfológicos y los sistemas difusos, que buscan emular los aspectos cognitivos.

En términos generales los algoritmos genéticos son métodos adaptativos, utilizados principalmente en problemas de búsqueda y optimización de parámetros, basados en la reproducción sexual y en el principio de supervivencia del más apto. Para alcanzar la solución a un problema se parte de un conjunto inicial de individuos, llamado población, generado de manera aleatoria. Cada uno de estos individuos representa una posible solución al problema. Estos individuos evolucionaran tomando como base los esquemas propuestos en la selección natural, y se adaptaran en mayor medida tras el paso de cada generación a la solución requerida [67].

Para la simulación de la validación de la información proporcionada por los sensores, se empleó el algoritmo genético definido en el *Genetic Algortithm And Direct Search Toolbox* de MATLAB, cuyo funcionamiento se explica a continuación:

1. El algoritmo crea una población inicial aleatoria.

2. A continuación el algoritmo crea una sucesión de nuevas poblaciones. En cada paso, el algoritmo utiliza los individuos de la generación actual para crear la siguiente población. Para crear la nueva población el algoritmo ejecuta las siguientes acciones:

- Califica cada individuo de la población actual calculando su ajuste. El ajuste es una medida que indica que tan cerca un individuo está de representar una buena solución al problema planteado.

- Selecciona miembros de la población, denominados padres, basándose en sus ajustes. Aquellos individuos con mejores ajustes tendrán mayor probabilidad de ser seleccionados como padres.

- Algunos de los individuos de la población actual que tengan el mejor ajuste, denominados élite, son pasados directamente a la siguiente generación (copia).

- A partir de los padres seleccionados se generan los hijos. Los hijos pueden ser generados realizando cambios aleatorios sobre un solo padre (mutación) o combinando las características de un par de padres (cruce).

- La población actual se reemplaza con los hijos para dar lugar a la siguiente generación.

3. El algoritmo se detiene cuando uno de los criterios de parada se ha alcanzado. Los principales criterios de parada son:

- Se ha alcanzado una población en la cual los mejores individuos representan soluciones suficientemente buenas para el problema que se desea resolver.

- La población ha convergido. Es decir, en un número de generaciones determinado el valor promedio ponderado de la función de ajuste no ha cambiado significativamente.

- Se ha alcanzado el máximo número de generaciones preestablecidas para dar solución al problema de optimización.

Entre los aspectos que más influyen en el desempeño del algoritmo se pueden mencionar, la diversidad de la población (relacionada con la distancia promedio entre los individuos), la metodología empleada para la selección de los padres, los porcentajes de cruce y mutación definidos y el número de copias permitidos en la creación de nuevas generaciones.

A continuación las características de los algoritmos genéticos son utilizadas para la implementación de la etapa de reconstrucción dentro del proceso de la validación de la información suministrada por los sensores.

3.3.1. Simulaciones y resultados de validación obtenidos con la utilización de GA

El primer paso para la reconstrucción de la información generada por el sensor en falla, es la definición de la función de costo que se minimizará a través de la utilización del algoritmo genético. En el presente trabajo, la función de costo se obtiene al comparar las entradas de la red neuronal auto-asociativa (E_i) con sus respectivas salidas (S_i) y evaluando el error absoluto medio tal como se describe a continuación:

$$f(x_j) = \frac{1}{n}\sum_{i=1}^{n} |E_i - S_i| \qquad [8]$$

En la ecuación anterior, $f(x_j)$ representa el ajuste para el *j-ésimo* sensor en falla cuando se le asigna un valor de x_j. En otras palabras, el algoritmo genético tratara de encontrar el valor x_j correspondiente al sensor en falla que haga mínima la diferencia entre las entradas y las salidas de la red neuronal auto-asociativa de acuerdo a lo definido en la

función de costo. La definición en MATLAB de esta función de costo se puede observar en el anexo 2.

Retomando los resultados obtenidos en el numeral *3.2.3.3*, donde se observó como la red neuronal auto-asociativa no era capaz de reconstruir satisfactoriamente la información del sensor en falla, se procede a la minimización de la función de costo anteriormente presentada mediante la utilización de algoritmos genéticos con las características observadas en la tabla 22.

El programa que hace uso de la función de costo definida anteriormente para la implementación de los algoritmos genéticos en MATLAB se pueden observar en el anexo 2.

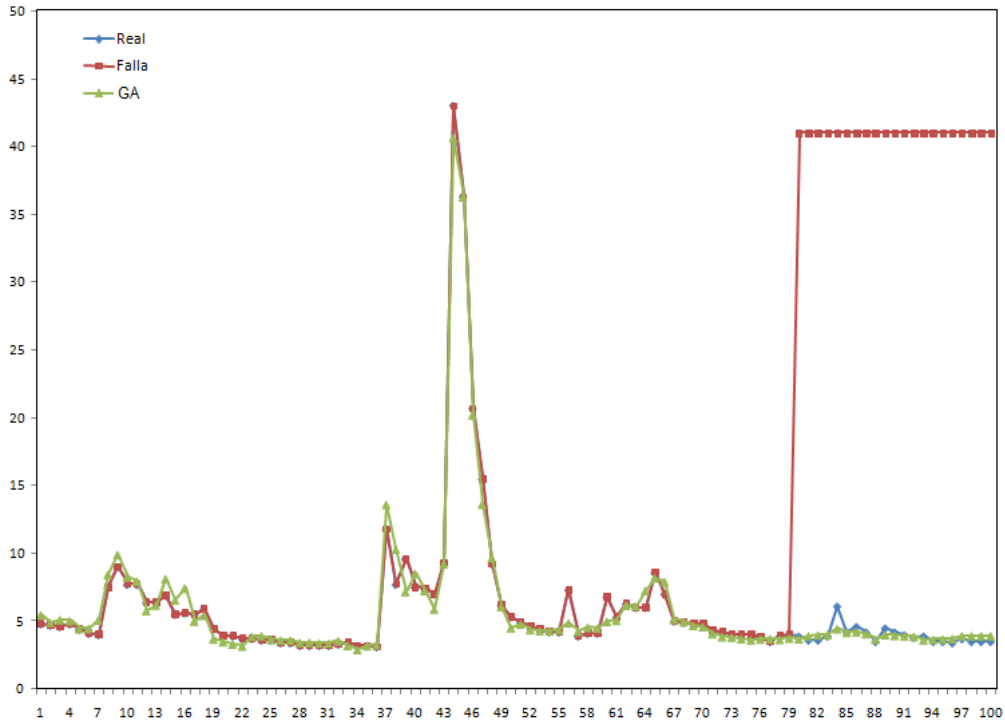
Tabla 22. Características de algoritmo genético empleado para la reconstrucción de la información

Tipo de población	Vector Doble
Método de selección	Estocástica uniforme
Método de cruce	Uniforme
Tamaño de la población	20
Tasa de cruce	80%
Método de mutación	Adaptativo
Número máximo de generaciones	100

Teniendo en cuenta que en el caso de la reconstrucción mediante redes neuronales auto-asociativas, el error promedio entre la turbiedad real y la reconstruida por la red neuronal fue de 3.48 NTU (la cual se puede considerar como excesiva, dado que la turbiedad promedio real entre las muestras 80 y 100 era de 3.93 NTU), la reconstrucción de la señal por medio de algoritmos genéticos introduce una mejora significativa, ya que en este caso el error promedio entre la turbiedad real y la reconstruida fue de tan solo 0.32 NTU (ver figuras 39 y 40).

De todas formas, no se debe perder de vista que la utilización de los algoritmos genéticos no reemplaza la utilización de las redes neuronales auto-asociativas en el proceso de validación de la información, ya que como se mencionó anteriormente a partir de los resultados entregados por las redes neuronales auto-asociativas se construye la función de costo que será minimizada por los algoritmos genéticos.

Figura 40. Comparación de las turbiedades obtenidas ante un error fuerte con reconstrucción de señal mediante algoritmos genéticos



3.3. CONCLUSIONES

Se logra la implementación de un sistema para la validación de la información entregada por los sensores basada únicamente en inteligencia artificial (redes neuronales auto-asociativas y algoritmos genéticos). A pesar de los excelentes resultados obtenidos, existen dos factores que no permiten su utilización práctica en la presente investigación. La primera es que no se cuenta con redundancia analítica. Los sensores con que se cuentan para el modelo de estimación de coagulante son turbiedad, pH y conductividad y como se discutió en el capítulo 2 no hay información redundante entre estas variables. La segunda es que el modelo de validación definido presenta una complejidad tal que dificulta su implementación en un *PLC* industrial típico, sobre todo lo concerniente a los algoritmos genéticos. De hecho la red neuronal auto-asociativa utilizada para la validación es mucho más compleja que la utilizada para la estimación de coagulante. Por tal razón, se implementará un modelo de validación basado en redundancia de hardware el cual se explicará en el próximo capítulo. No obstante, vale la pena resaltar nuevamente los excelentes resultados de simulación obtenidos con el esquema de validación aquí

discutido y se espera que dicho esquema pueda ser implementado en trabajos futuros donde se cuente con redundancia analítica entre las variables medidas y capacidades de procesamiento superiores a las proporcionadas por un *PLC* industrial típico. Cabe anotar igualmente, que es necesario realizar estudios adicionales que permitan obtener un procedimiento que identifique de manera precisa el sensor que se encuentra en falla. Con la metodología basada en el umbral de error, aquí empleada, se pueden tener dificultades en la determinación del sensor en falla cuando la medición entregada por uno de los sensores se aleja de manera significativa del valor real de la variable en cuestión. Finalmente, se recomienda en trabajos futuros, abordar el tema de la validación de la información proporcionada por los sensores, mediante mapas auto-organizados de *Kohonen* y comparar su desempeño con el que se obtiene con el uso de redes neuronales auto-asociativas.

4. PLATAFORMA DE EXPERIMENTACIÓN

4.1. INTRODUCCIÓN

Con el fin de validar los resultados de las simulaciones obtenidas en el capítulo 2 con los modelos de estimación de coagulante, en el presente capítulo se describe el sistema desarrollado para la utilización de estos modelos de dosificación en un proceso de potabilización real, tal como el que se lleva a cabo en la planta de potabilización del municipio de Roldanillo en el Valle del Cauca. Se implementaran los modelos de redes neuronales y ANFIS que fueron los que mejores resultados arrojaron durante las simulaciones y se trataran de identificar las ventajas e inconvenientes de cada una de estas dos técnicas de inteligencia computacional. Al final del capítulo se presenta una metodología que permite la implementación de sistemas de dosificación basados en inteligencia computacional, en otros sistemas de potabilización.

4.2. PLANTA DE POTABILIZACIÓN DEL MUNICIPIO DE ROLDANILLO

La planta del municipio de Roldanillo potabiliza en la actualidad un promedio de 5700 m3/día y sirve aproximadamente a una población de 38.000 habitantes. Para su abastecimiento cuenta con dos fuentes superficiales (río Roldanillo y río Cáceres) y con el agua proveniente del embalse Guacas perteneciente al acueducto regional SARA-BRUT, el cual abastece también a otros 6 municipios del norte del Valle del Cauca. La planta de potabilización es del tipo convencional con unidades de coagulación, floculación, sedimentación, filtrado y desinfección. Como coagulante se emplea el sulfato de aluminio líquido tipo B, cuya dosificación actualmente se estima mediante la realización de prueba de jarras. Esta planta al formar parte del acueducto regional SARA-BRUT cuenta con un controlador lógico programable (*PLC*, por sus siglas en ingles) y equipos de telemetría que

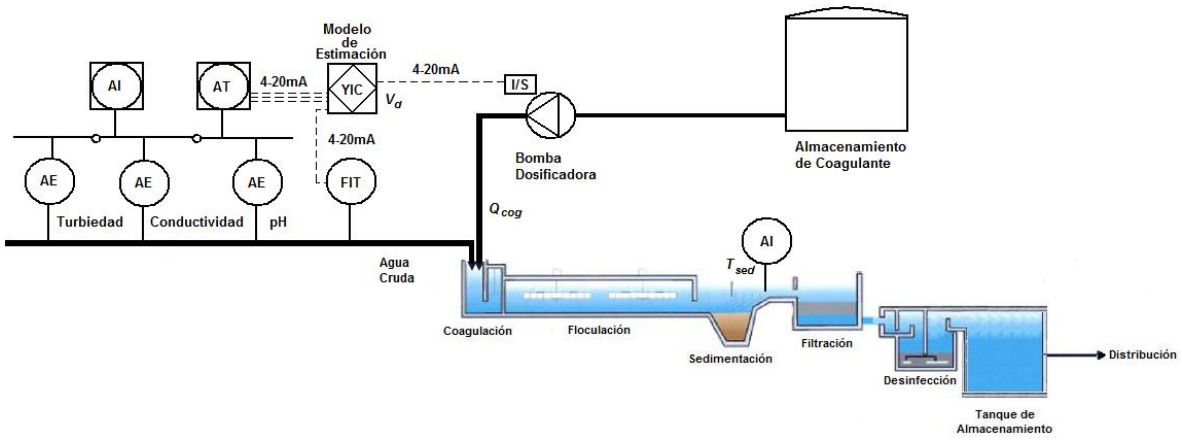
le permiten su integración al sistema SCADA del acueducto regional. Igualmente, la planta de Roldanillo es la única planta de ACUAVALLE S.A. - E.S.P., que cuenta medición de parámetros de calidad del agua cruda en línea. Estas dos características junto con la gran cantidad de datos operativos disponibles, hicieron de esta planta el lugar adecuado para la implementación del sistema de control de dosificación de coagulante propuesto en la presente investigación.

4.3. IMPLEMENTACIÓN DEL SISTEMA DE DOSIFICACIÓN DE COAGULANTE

4.3.1. Descripción del sistema

El sistema implementado para la dosificación automática de coagulante en el proceso de potabilización del agua cruda es del tipo *feedforward*, tal como se muestra en la figura 41.

Figura 41. Control feedforward para el ajuste automático de la dosis de coagulante



En este esquema de control, la *variable controlada* es la turbiedad del agua a la salida de la unidad de sedimentación (T_{sed}), la cual para condiciones idóneas de operación no debe sobrepasar el valor de 5 NTU. *La variable manipulada* que permite mantener T_{sed} en el rango apropiado de operación es el flujo de coagulante aplicado al agua cruda (Q_{cog}). Por su parte, el modelo de estimación basado en inteligencia computacional implementado en el PLC permite relacionar los *disturbios* que afectan la variable T_{sed} (cambios en la turbiedad, pH y/o conductividad del agua cruda) con la variable manipulada Q_{cog}. De esta

relación y con el conocimiento del caudal de agua cruda que ingresa a la planta, se genera l*a acción de control* (V_d) que permite modificar la velocidad de la bomba y de esta forma obtener una descarga de coagulante que compense los *disturbios* presentados y mantenga la variable T_{sed}, en el valor apropiado. Las características técnicas de los equipos empleados para la implementación de este esquema de control se encuentran en el anexo 4.

Se debe tener en cuenta que la variable caudal como tal, no hace parte del modelo de estimación, simplemente se utiliza para calcular la descarga de la bomba dosificadora a partir de la dosis entregada por el modelo, mediante la ecuación [9].

$$Q_d\left[\frac{ml}{min}\right] = \frac{Q_{in}[l/s] * 60\left[\frac{s}{min}\right] * DO\left[\frac{mg}{l}\right] * 100\%}{1000\left[\frac{mg}{g}\right] * D\left[\frac{g}{ml}\right] * C[\%]} \qquad [9]$$

Como se observa el caudal de descarga de la bomba dosificadora (Q_d) no solo depende del caudal de entrada a la planta (Q_{in}) y de la dosificación entregada por el modelo de estimación (*DO*), sino que también dependen de la densidad (*D*) y concentración (*C*) del coagulante. Valores típicos de densidad y concentración para el sulfato de aluminio líquido son 1.32 g/ml y 49.80% respectivamente. Por tanto, para una dosis óptima de 33 mg/l calculada por el modelo, y un caudal de entrada a la planta de 75l/s la bomba debería tener una descarga de 226 ml/min.

4.3.2. Validación de la información mediante hardware redundante

Como se mencionó en el capítulo anterior, realizar la validación de la información proporcionada por los sensores de calidad de agua por medio de técnicas de inteligencia computacional si bien es posible, para las herramientas con que se cuentan en la presente investigación representarían una carga computacional demasiado grande y resultaría más práctica una aproximación basada en hardware redundante, la cual se explica a continuación.

Del seguimiento realizado a los sensores, el más propenso a presentar fallas súbitas es el sensor de turbiedad y al mismo tiempo es el que mayor influencia tiene en la salida entregada por el modelo de estimación. El sensor de pH tiene tendencia a sufrir un deterioro lento pero progresivo en su electrodo el cual se manifiesta con un *offset* que se sobrepone al valor real de pH. Esta situación se puede remediar mediante procedimientos de calibración periódicos recomendados por el fabricante. Por último, el sensor de

conductividad es el más estable de todos y el menos susceptible a fallos. De acuerdo a lo anterior, la siguiente es la estrategia que se emplea para evitar que mediciones erróneas entren al modelo de estimación:

1. El sistema de instrumentación de los sensores de calidad de agua, cuenta con funciones de auto-diagnóstico, el cual permite que ante un fallo de alguno de los sensores se envíe una señal de corriente constante al *PLC* (típicamente 21mA), la cual podrá ser interpretada por el *PLC* como falla en el sensor respectivo.

2. Cuando esto ocurra, el *PLC* mantendrá la última descarga de la bomba calculada con todos los sensores en correcto funcionamiento.

3. Simultáneamente, el *PLC* emitirá una alarma indicando al operador la falla en el sistema de medición e indicando cual es el sensor en falla.

4. En este momento el operador, si lo desea, podrá pasar la dosificación a modo manual y ajustar la descarga de la bomba de acuerdo a su propio criterio.

5. Para el caso del sensor de turbiedad, dado que es el que más fallas puede presentar se utilizaran dos sensores, de los cuales uno de ellos será tomado como principal y será el que en condiciones normales suministre la información al modelo de estimación. En caso de falla, el segundo sensor entrará a suministrar la turbiedad requerida para la estimación de la dosificación de coagulante. Si los dos sensores de turbiedad fallan de forma simultánea, se seguirá el esquema definido anteriormente para los otros sensores, es decir, el sistema mantendrá la última descarga de la bomba calculada con todos los sensores en correcto funcionamiento.

Se debe tener en cuenta igualmente, que si bien el caudal no hace parte del modelo de estimación de coagulante, sí afecta la descarga final de la bomba por lo cual la información suministrada por dicho sensor también es sometida a un proceso de validación como el descrito para las variables de calidad de agua.

Finalmente, cabe anotar que otro punto del que se debe ocupar el sistema de validación es el de la verificación de que las medidas entregadas por los sensores de calidad de agua, así sean correctas, se encuentren dentro de los rangos que los modelos de estimación manejan, ya que si alguna variable se encuentra fuera del rango de los valores que se emplearon para la construcción de los modelos en redes neuronales y ANFIS, dichos modelos suministraran dosificaciones poco acordes con las características reales del agua cruda.

Tabla 23. Rangos válidos de las variables que participan en el modelo de estimación

Variable	Valor Mínimo	Valor Máximo
Turbiedad	1.8 NTU	541 NTU
pH	6.5	9.4
Conductividad	108 uS/cm	295 uS/cm

En caso de que alguna de las variables quede por fuera de los rangos observados en la tabla 23, el sistema mantendrá la última descarga de la bomba calculada con las variables dentro del rango definido por el modelo de estimación, enviando una alarma al operador.

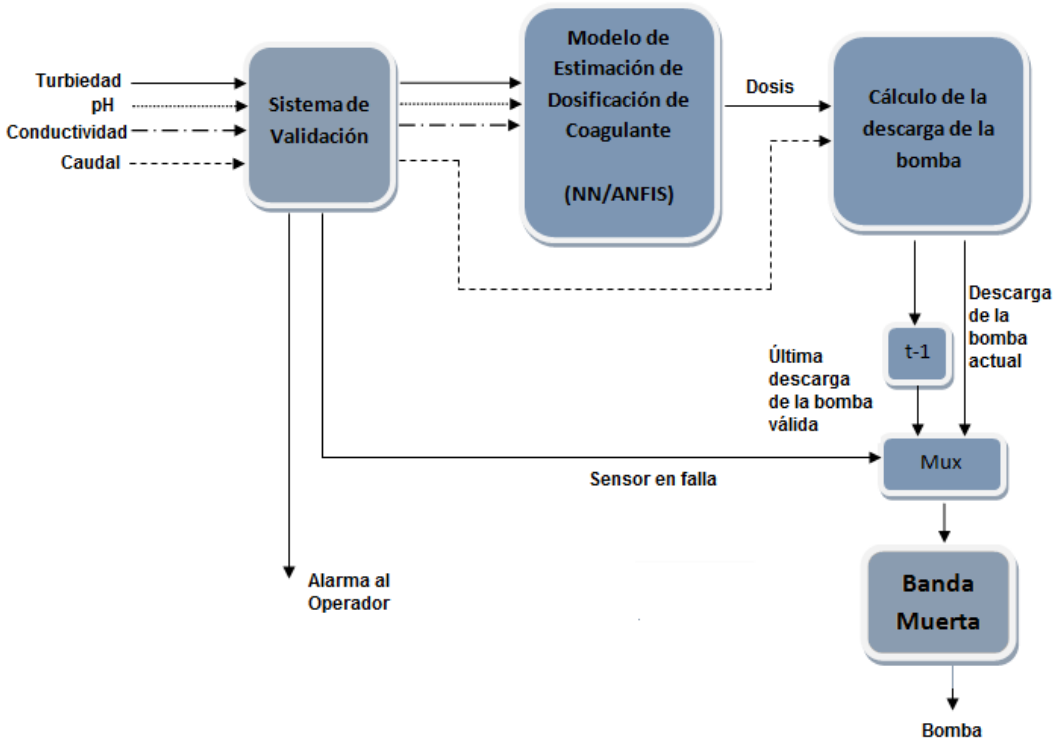
Tabla 24. Bloques de programación en el PLC

Bloque	Nombre	Descripción
OB1	Principal	Rutina principal desde se llama a la sub-rutina FC19.
FC19	Dosificación	Sub-rutina que ejecuta la validación de los sensores y la dosificación de coagulante mediante el llamado a otras sub-rutinas y funciones.
FC17	NNDose	Sub-rutina que estima la dosificación de coagulante mediante redes neuronales.
FC18	ANFISDose	Sub-rutina que estima la dosificación de coagulante mediante el modelo ANFIS.
FB117	TangSigm	Función que calcula la tangente sigmoidal de un valor real.
FB118	EvalMF	Función que calcula los niveles de pertenencia de cada una de las variables y entrega el nivel de activación del antecedente (w_i) para la regla en evaluación
FB119	Defuzz	Función que realiza la agregación (cálculo de la salida del sistema difuso) mediante la suma ponderada (w_i) de la salida de las diferentes reglas dividida entre la sumatoria de los niveles de activación de los antecedentes (w_i)
FB120	Descarga de la bomba	Función que calcula la descarga de la bomba dosificadora.
FB121	EscalQ	Función que normaliza y válida la información proporcionada por los sensores de calidad de agua.

4.3.3. Estructura del programa en el PLC

La implementación del sistema de dosificación fue realizada utilizando el lenguaje de programación AWL, propio de los PLC SIMATIC 300 de SIEMENS. En total fueron utilizados 9 bloques de programación cuyos nombres y descripciones se observa en la tabla 24. El código de programación correspondiente a cada uno de estos bloques se observa en el anexo 5. En la figura 42 se observa un diagrama funcional del sistema de dosificación implementado en el PLC.

Figura 42. Diagrama funcional del sistema de dosificación implementado en el PLC



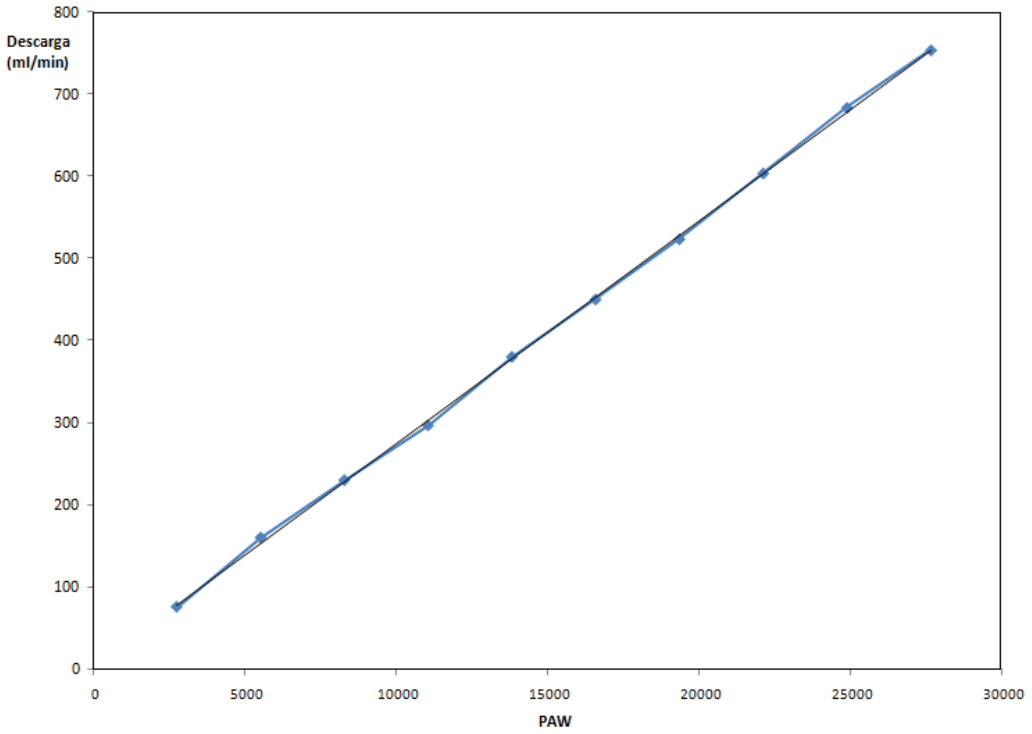
Como se observa en la figura 42, antes de entregar la señal de control a la bomba dosificadora, existe una banda muerta que evita que la bomba actué de forma innecesaria ante leves modificaciones en el caudal de descarga de la bomba calculado. Lo anterior permite que la aplicación de coagulante sea más constante, lo cual de acuerdo a la experiencia de los operadores de planta favorece al proceso de potabilización. La banda muerta aplicada es de ± 5 ml/min.

4.3.4. Bomba dosificadora

La bomba dosificadora cuenta con dos controles para ajustar su descarga. El primero de ellos denominado *stroke* regula el recorrido del diafragma de la bomba y solo puede ajustarse de manera manual mediante una perilla en la escala de 10 a 100. El segundo de ellos denominado *speed* regula la velocidad del *stroke* y puede ajustarse de forma manual mediante una perilla en la escala de 0 a 100 o mediante una señal remota de 4-20mA.

Con el fin de controlar la descarga de la bomba (a través del control *speed* y mediante la señal de 4-20 mA generada por el PLC) es necesario calcular la curva de descarga de la bomba en todo el rango de 4-20mA. Como se mencionó anteriormente, la descarga de la bomba no solo depende del control *speed* sino que también del control *stroke*. De acuerdo al rango de los modelos implementados y a las dosificaciones históricas máximas aplicadas en la planta de Roldanillo, se observó que con un *stroke* igual a 40, se podría cubrir todo el rango posible de dosificación.

Figura 43. Curva de descarga de la bomba dosificadora de coagulante



Una vez ajustado el *stroke*, el cual permanecerá constante, se procedió a modificar la señal de 4-20mA, que ajusta el control *speed*, y a aforar la descarga de la bomba obteniéndose la curva mostrada en la figura 43.

Como se observa en la figura 43, en el eje X no se encuentra la variable de 4-20mA, sino la variable PAW, la cual corresponde a la digitalización de la señal de 4-20mA que hace la tarjeta de salida análoga del PLC. Esta relación es lineal, donde un valor de 0 en la variable PAW corresponde a 4mA y un valor de 27648 a 20mA. De acuerdo a esta curva, la relación entre la variable PAW y la descarga de la bomba se puede aproximar por la ecuación 10.

$$PAW = \frac{Descarga\ de\ la\ bomba}{0.028} \qquad [10]$$

Esta es la relación que utiliza el PLC en el bloque de programación FC19 para calcular la señal de 4-20mA a ser enviada al control *speed* de la bomba para ajustar su descarga de acuerdo a las dosis calculadas y al caudal de entrada a la planta.

4.3.5. Interfaz de operación del sistema de dosificación

Para la operación del sistema de dosificación, se implementó una interfaz en la terminal gráfica OP27 de SIEMENS utilizando el software *Pro-Tool*, generando las pantallas observadas en las figuras 44 y 45 desde las cuales el operador tiene acceso al sistema de dosificación.

Como se observa en la figura 44, el sistema muestra en primer lugar el ESTADO DEL MODELO. Un led verde en este campo indica que todos los sensores que hacen parte del sistema dosificación están trabajando correctamente y que sus variables se encuentran en el rango de operación de los modelos de redes neuronales (*NN*, por sus siglas en inglés) y ANFIS.

Figura 44. Pantalla 1 del sistema de dosificación



Figura 45. Pantalla 2 del sistema de dosificación



En este estado, el sistema de dosificación actualizará de forma continua las dosis calculadas por ambos modelos y sus descargas correspondientes en las columnas “DOSIS (mg/l)” y “DSC(ml/min)”. El operador puede seleccionar el modelo que controlará de manera automática la dosificación de coagulante en la planta mediante las teclas F9 (NN) y F10 (ANFIS). En caso de que el operador no esté de acuerdo con las dosificaciones calculadas por los modelos y quiera el mismo digitar la descarga de coagulante que debe aplicar la bomba al agua cruda, deberá oprimir la tecla F11, con lo cual se tendrá un control manual de la bomba. Al oprimir las teclas F9, F10 y F11 se pondrá en verde el led que corresponda a la selección realizada por el operador y el campo “DESCARGA ACTUAL DE LA BOMBA” se igualará con la descarga calculada para la selección hecha por el operador (redes neuronales, ANFIS o manual).

En caso de presentarse una falla en alguno de los sensores de pH, conductividad o caudal, o en las dos sondas de turbiedad, el indicador ESTADO DEL MODELO pasara a color rojo y las dosificaciones y descargas correspondientes a las redes neuronales y al modelo ANFIS, se mantendrán en el último valor válido, es decir con todos los sensores en correcto funcionamiento. Mediante la tecla F13 (DATA) el operador cambiara de pantalla (ver figura 45) y podrá determinar que sensor presenta mal funcionamiento o se encuentra fuera del rango de operación de los modelos, lo cual se indica mediante un led rojo en la variable respectiva. Cada variable tiene al frente su correspondiente valor numérico. En esta pantalla el operador tiene la posibilidad también, de ingresar los valores de densidad y concentración del coagulante que se está dosificando, en los campos D y C respectivamente.

4.4. VALIDACIÓN DEL SISTEMA EN LA PLANTA ROLDANILLO

A continuación se presentan los resultados obtenidos en la planta de potabilización del municipio de Roldanillo, con la utilización del sistema de dosificación descrito previamente.

4.4.1. Descripción de la prueba

El día 25 de Agosto de 2010, se procede a verificar el funcionamiento del sistema de dosificación aquí propuesto. Como parámetro para validar el trabajo del sistema de dosificación, se empleará la turbiedad del agua a la salida de los sedimentadores. La turbiedad en este punto en condiciones idóneas de operación no deberá superar los 5 NTU. Turbiedades por encima de este valor, incrementará de forma innecesaria el trabajo de los filtros, llevando a un lavado prematuro de los mismos a fin de no afectar la calidad

del agua potabilizada. De acuerdo a los operadores, el efecto de la dosificación de coagulante en el agua cruda, se refleja en la turbiedad del agua a la salida de la etapa de sedimentación, aproximadamente 1 hora y media después de aplicada la dosificación de coagulante. Las fuentes de agua cruda disponibles eran la quebrada Cáceres, el río Roldanillo y el agua proveniente del embalse Guacas perteneciente al sistema SARA-BRUT.

La prueba se inicia a las 07:00 a.m. con la operación tradicional de la planta, aplicando la dosificación de acuerdo a la prueba de jarras efectuada por el operador encargado. Esta dosificación manual nos da también una referencia para la comparación, de la turbiedad del agua a la salida de los sedimentadores, con la planta en operación manual y operación automática. Aproximadamente, a las 12:00 m se inicia la operación de la planta de forma automática utilizando el modelo de redes neuronales. Se prefirió la utilización del modelo de redes neuronales sobre el modelo ANFIS, debido a que con el primero se obtuvieron mejores índices de desempeño, tal como fue descrito en el capítulo 2.

Cabe anotar, sin embargo, que aunque en modo automático solo se dosificó con el modelo de redes neuronales, también se corrió en el PLC el modelo ANFIS, lo cual permite comparar el desempeño de ambos modelos para las condiciones presentadas durante el desarrollo de las pruebas. Sobre las 07:00 p.m. se termina la operación automática de la planta y se vuelve a una operación manual tradicional por prueba de jarras, concluyendo de esta forma la prueba.

4.4.2. Desarrollo de la prueba

En la figura 46 se observa el comportamiento de los tres parámetros de calidad del agua cruda correspondientes al día 25 de Agosto de 2010 entre las 07:00 a.m. y las 07:00 p.m. Desde el inicio de la prueba hasta aproximadamente las 3:00 p.m., se trató en la planta el agua de la fuentes superficiales (quebrada Cáceres y río Roldanillo). A partir de las 3:00 p.m. se realizó una mezcla del agua superficial con el agua proveniente del sistema SARA-BRUT (70% agua superficial, 30% agua del embalse). Entre las 03:40 p.m. y las 04:20 p.m. se presenta un incremento en las turbiedades de las fuentes superficiales, por lo cual a partir de las 04:30 p.m. aproximadamente, se incrementa el ingreso del agua proveniente del embalse y se disminuye en la mezcla, el agua superficial, lográndose así un descenso en la turbiedad (y por consiguiente en el gasto de coagulante) llegándose a trabajar con agua proveniente del embalse únicamente, sobre las 05:30 p.m. Con estas condiciones se continúa trabajando el resto del día.

Figura 46. Comportamiento de los parámetros de calidad de agua durante la prueba

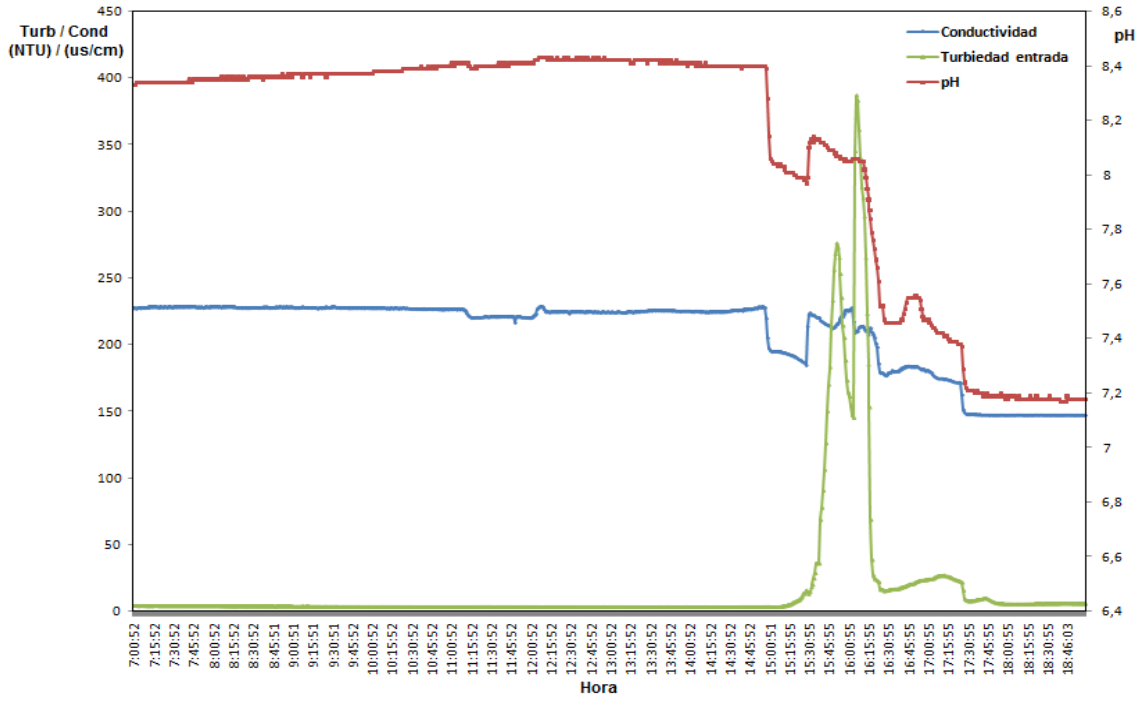
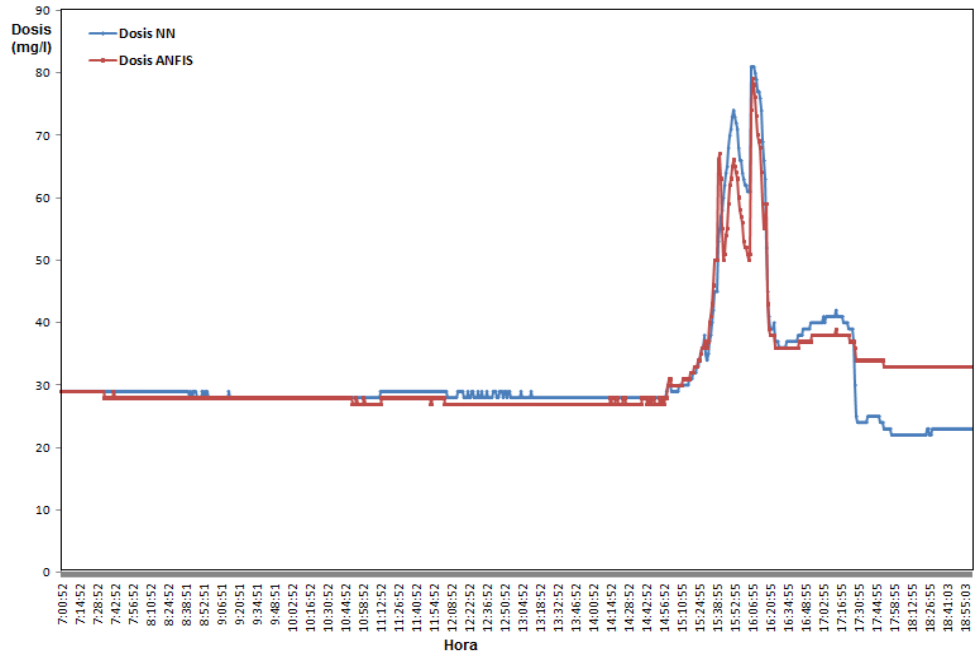


Figura 47. Dosis estimadas por los modelos de redes neuronales y ANFIS



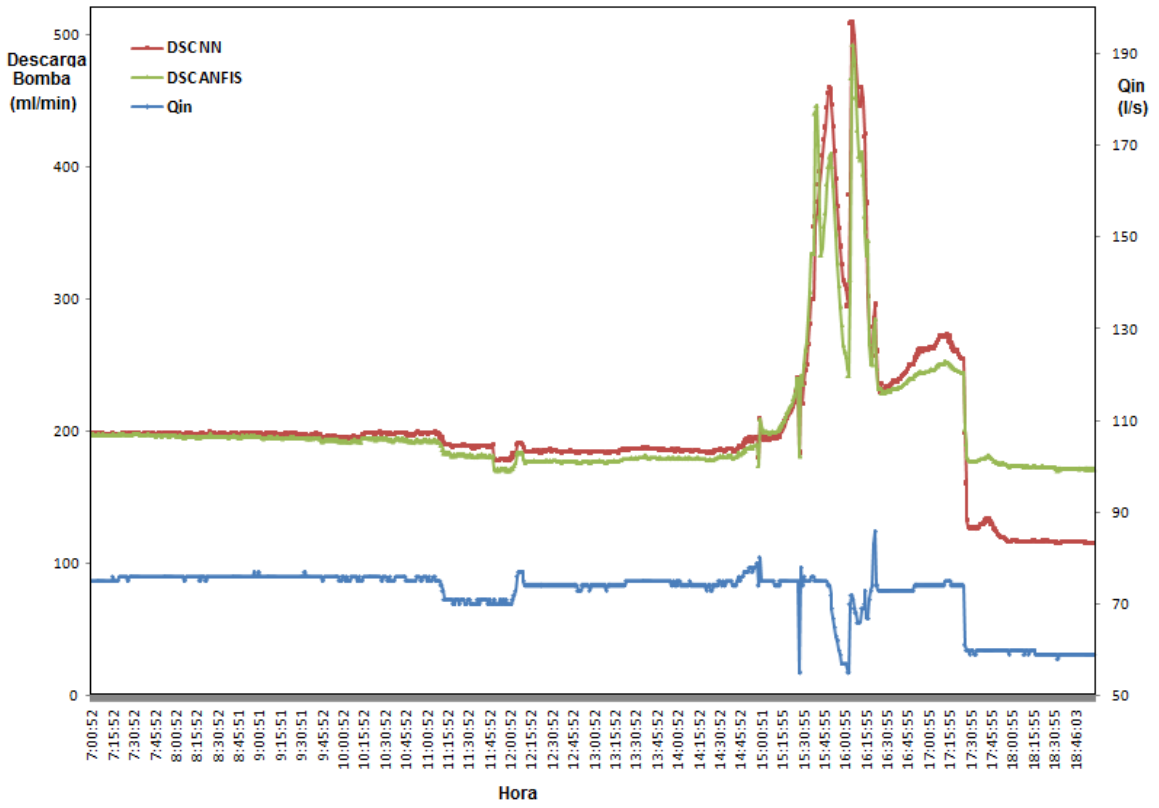
Como se observa en la figura 47, las dosis calculadas por los dos modelos (redes neuronales y ANFIS) son muy similares para aguas de bajas turbiedades (menores a 10) y pH altos (mayores a 8), las cuales representan las condiciones normales de operación durante la gran parte de año en ese municipio. En los picos de turbiedad se observa que el modelo de redes neuronales tiende a estimar mayores dosis de coagulante que el modelo ANFIS. Por último para aguas provenientes del embalse, las cuales tienen pH bajo (menor a 7.2) se observa una diferencia importante entre las dosificaciones realizadas por los modelos, tendiendo el modelo ANFIS a aplicar aproximadamente 10 unidades más a las estimadas por el modelo de redes neuronales.

Esta diferencia se puede explicar al revisar los datos históricos a partir de los cuales fueron implementados ambos modelos, donde se observa como estas dos situaciones turbiedades altas y turbiedades bajas con pH bajos no son comunes, por lo cual las estimaciones entregadas corresponden a generalizaciones realizadas por cada uno de los modelos. Determinar cuál de las dos generalizaciones es mejor, implicaría realizar una prueba de jarras para cada una de las situaciones descritas. Para el caso de los picos de turbiedad, estos fueron tan rápidos que no dieron el tiempo suficiente para la realización de la prueba de jarras. Para el caso del agua de baja turbiedad y bajo pH (proveniente del embalse) cuyas características son más estables fue posible realizar una prueba de jarras y el resultado fue más cercano a las estimaciones realizadas por el modelo ANFIS. Sin embargo, como se verá más adelante la aplicación del modelo de redes neuronales a lo largo de la prueba, no generó alteraciones significativas en la turbiedad del agua a la salida de los sedimentadores, lo cual también avala las estimaciones realizadas por este modelo. Cabe aclarar que esta situación no contradice las evaluaciones realizadas en el capítulo 2, donde se encontró que el modelo que presentaba mejor desempeño en todo el rango de dosificación de coagulante (turbiedades, pH y conductividades altas, medias y bajas) era el basado en redes neuronales. Lo que se encontró con la prueba de validación realizada en la planta de Roldanillo, fue simplemente que para el caso específico de agua proveniente del embalse (turbiedades y pH bajos) la estimación del modelo ANFIS presentó mayor cercanía al resultado de la prueba de jarras, que la estimación dada por el modelo de redes neuronales.

En la figura 48 se observan las descargas calculadas para la bomba dosificadora a partir de las dosificaciones estimadas por los modelos de redes neuronales y ANFIS. Se muestra también el caudal de entrada a la planta (*Qin*) que es la otra variable que interviene en el cálculo de la descarga de la bomba. La densidad y concentración del coagulante aplicado (sulfato de aluminio líquido) eran de 1.32 y 51.78% respectivamente. La descarga de la bomba calculada para cada modelo es proporcional a la señal de control en miliamperios que será enviada a la bomba. Como se observa, en este sentido las dos descargas presentan un comportamiento muy similar por lo cual no se encuentra desde el punto de vista del esfuerzo de control diferencia alguna entre la utilización de uno u otro modelo, lo cual era de esperarse teniendo en cuenta el control tipo *feedforward* implementado. En la

figura 48, se observa también la dependencia, de las descargas calculadas para cada modelo, del caudal de entrada a la planta.

Figura 48. Comportamiento de las descargas de las bombas calculadas para los modelos de redes neuronales y ANFIS durante la prueba



En la figura 49, se muestra la turbiedad del agua a la entrada de la planta, la dosis calculada por el modelo de redes neuronales, la descarga calculada para la bomba dosificadora y la turbiedad del agua a la salida del sedimentador. También es posible observar la señal de control (PAW), la cual corresponde a la digitalización de la señal de 4-20mA que va hacia la bomba dosificadora. Esta relación es lineal, donde un valor de 0 en la variable PAW corresponde a 4mA y un valor de 27648 a 20mA. Como se observa, la señal de control PAW es más estable (presenta menos rizado) que la descarga calculada por el modelo debido a la banda muerta de ± 5 ml/min, permitiendo de esta forma tener una dosificación más constante, que solo se modifica cuando existan cambios significativos en las descargas calculadas. Aproximadamente, a las 05:30 p.m se observa una caída significativa en la señal de control, debido a que la dosificación estimada del

modelo disminuye (como consecuencia de la baja en la turbiedad) y al mismo tiempo se disminuye el caudal de entrada a la planta.

También es claro como la utilización del sistema de dosificación automático, a partir de las 12:00 m, permitió que la planta de potabilización manejara agua con turbiedades de hasta 387 NTU a su entrada, sin que el agua a la salida de los sedimentadores incrementara su turbiedad por encima de 5 NTU después de la 1:30 p.m., teniendo en cuenta el retardo de aproximadamente 1 hora y media que existe entre el momento que se dosifica el coagulante y el momento en que dicha dosificación tiene efecto en el comportamiento del agua sedimentada. Por ejemplo, para el primer pico de turbiedad presentado a las 3:52 p.m., se obtuvieron a la salida de los sedimentadores, alrededor de las 5:20 p.m., turbiedades del orden de 2.75 NTU, tal como se puede observar en la figura 50. Igualmente, en esta figura se puede apreciar la turbiedad del agua tratada almacenada en los tanques de distribución, la cual no sobrepasa los 0.7 NTU.

Figura 49. Comportamiento del sistema de dosificación y de la turbiedad del agua a la salida de los sedimentadores.

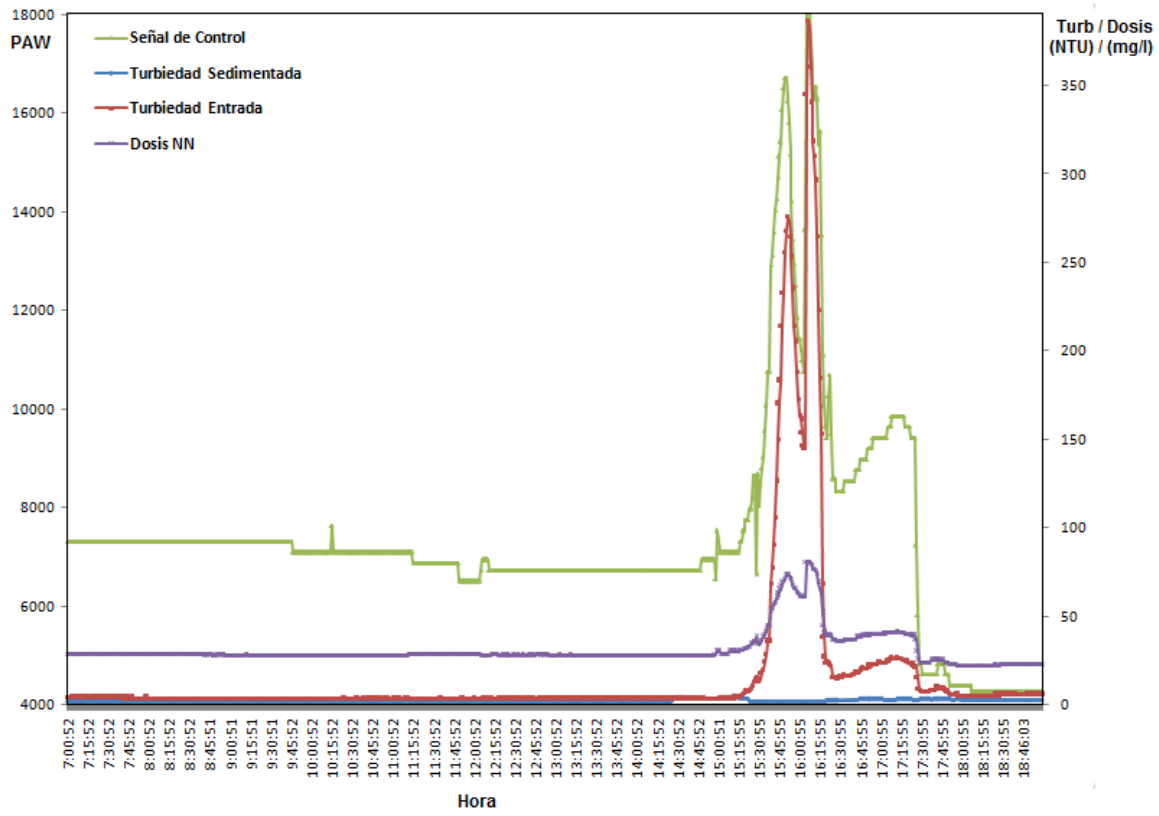
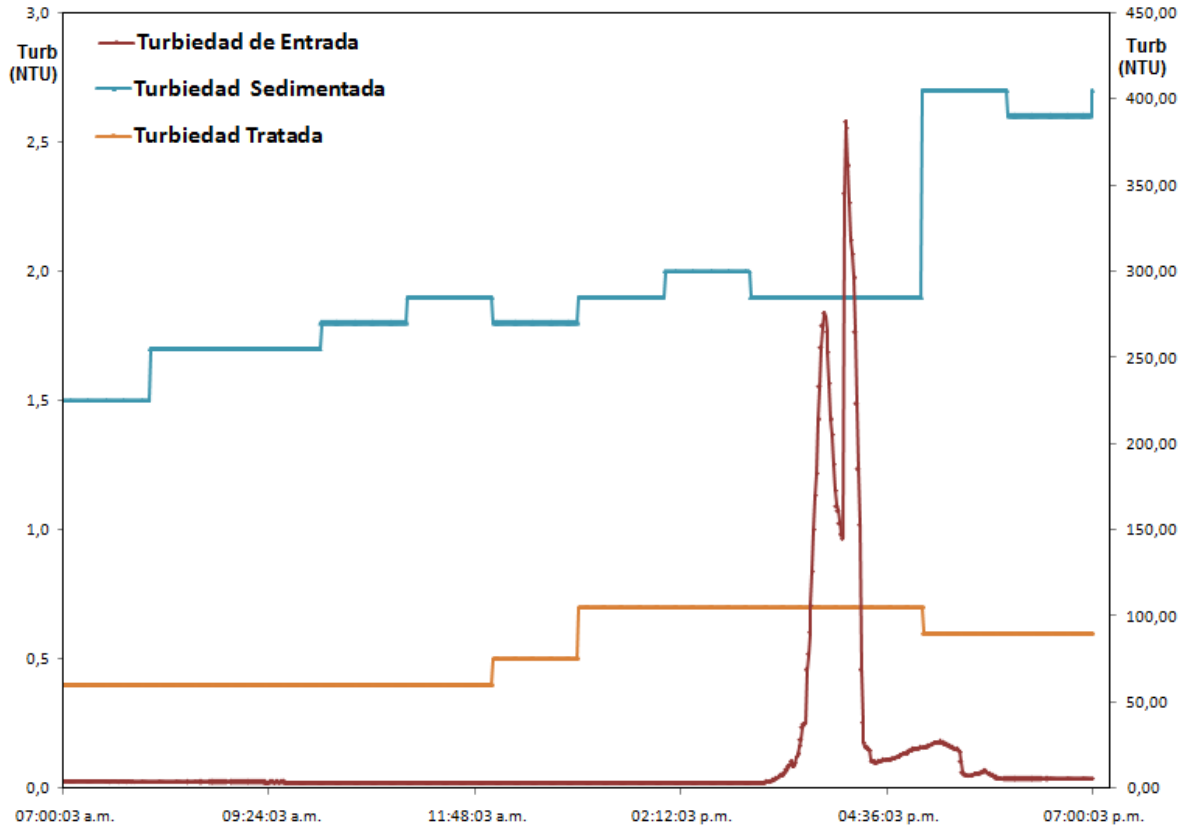


Figura 50. Comportamiento de la turbiedad a la entrada de la planta, a la salida de los sedimentadores y en los tanques de almacenamiento (agua tratada).



4.5. METODOLOGIA PROPUESTA

Tomando como base los resultados de la investigación desarrollada se propone la siguiente metodología para la implementación de sistemas de dosificación de coagulante, basados en técnicas de inteligencia computacional, para plantas de potabilización de agua.

1. Obtención de la base de datos para la implementación del modelo. Teniendo en cuenta las condiciones climáticas de nuestro entorno, donde no existen estaciones, normalmente con dos años de información sería suficiente para la implementación de un modelo que cubra la mayor parte de escenarios de dosificación. La base de datos deberá provenir de las pruebas de jarras realizadas (o cualquier otro método confiable de dosificación) y contener registros de las variables de la calidad del agua cruda y la dosificación de coagulante aplicada para cada una de las condiciones de calidad de agua registradas.

2. *Detección de outliers.* La base de datos puede contener errores provocados por mal funcionamiento de los sensores de calidad de agua o por problemas de transcripción de los datos, los cuales se constituyen en *outliers*. Dichos *outliers* deben ser eliminados antes de iniciar la construcción del modelo, ya que su inclusión llevaría a la construcción de modelos con sesgos en la predicción final del coagulante. Para la detección de *outliers* existe una gran variedad de métodos que pueden o no incluir técnicas de inteligencia computacional. Se recomienda la metodología propuesta en [27] la cual combina redes neuronales y métodos estadísticos.

3. Selección de las variables que harán parte del modelo. Durante la selección de las variables se deben analizar dos aspectos. El primero, es determinar si existe información redundante entre las variables de calidad de agua que se incluyeron en la base de datos. Dicha redundancia puede observarse de forma gráfica mediante mapas auto-organizados de *Kohonen* o de forma numérica mediante un análisis de correlación. La eliminación de variables redundantes simplifica el modelo sin sacrificar de manera significativa su desempeño. El otro aspecto a considerar es si las variables que finalmente quedaron después de verificar la redundancia de la información realmente afectan la salida del modelo es decir la dosificación de coagulante. Para tal fin se recomienda utilizar la metodología propuesta en [53] la cual se basa en un proceso de selección de selección tipo *backward.*

4. Normalización de los datos. La normalización busca distribuir más uniformemente los valores de los datos y es un aspecto que se debe considerar a la hora de una implementación basada en redes neuronales o modelos ANFIS. Los datos pueden normalizarse en rangos entre -1 y 1, 0 y 1 o según su desviación estándar. En el caso de técnicas basadas en *clustering*, la normalización no introduce mejoras significativas en los modelos obtenidos.

5. *Selección de la técnica de inteligencia computacional que se empleará para la implementación del modelo.* Entre las técnicas de inteligencia computacional disponibles para la construcción de modelos de estimación de coagulante se encuentran las redes neuronales, la lógica difusa y los modelos neuro-difusos tipo ANFIS. Si bien la selección de la técnica a utilizar para la implementación del modelo dependerá de las herramientas de hardware y software disponibles y de las preferencias que pueda tener el modelador, por los resultados obtenidos en la presente investigación, se recomienda la utilización de las redes neuronales *MLP* dado su desempeño superior (comparado con las otras técnicas mencionadas) y su implementación más directa.

6. *Desarrollo del modelo de estimación y evaluación de su desempeño.* Una vez seleccionada la técnica de inteligencia computacional se procede a su desarrollo y a la evaluación de su desempeño que garantice un buen comportamiento en todo el rango de las variables incluidas en el modelo. Índices de desempeño como el coeficiente de

correlación (R^2), el error cuadrático medio (*RMSE*) y el error medio absoluto (*MAE*) permiten realizar dicha evaluación. Con los pasos descritos hasta aquí es posible el desarrollo de una herramienta de software que puede asistir al operador de la planta de potabilización en la determinación de la dosificación de coagulante en casos de cambios súbitos en la calidad de agua.

7. *Selección de sensores y actuadores.* Si se desea implementar un sistema de dosificación automático se hará necesario incluir sensores de calidad de agua y una bomba dosificadora. Los sensores a emplearse dependerán del análisis de selección de variables realizado en paso 2. Otro punto a considerar en este punto, es la selección del hardware y software requerido para la implementación del modelo y el control de la bomba dosificadora, la cual puede basarse en equipos industriales tipo PLC o en control basado en PC. Por la robustez y costos de los PLC se recomienda su utilización en la implementación del sistema de dosificación.

8. Definición del sistema de validación de la información suministrada por los sensores. Al incluir sensores, es necesario definir un sistema que permita validar la información suministrada por dichos equipos. Un método podría ser la utilización de técnicas de inteligencia artificial como redes neuronales auto-asociativas y algoritmos genéticos, como los descritos en el capítulo 3. Sin embargo, se debe tener en cuenta que la utilización de estas técnicas podría requerir de prestaciones computacionales propias de sistemas de control basados en *PC* y su implementación en sistemas basados en *PLC* sería prácticamente prohibitiva. Si se emplea *PLC*, sería recomendable realizar la validación con sensores redundantes en las variables más críticas (si se quiere aumentar la disponibilidad del modelo) o simplemente aislando los sensores en falla haciéndose uso de las herramientas de auto-diagnóstico con que normalmente cuentan los sensores de calidad de agua.

9. Implementación del sistema de dosificación. Una vez se cuenta con los sensores, actuadores y *PLC/PC*, se procede a la implementación y puesta en marcha del sistema de dosificación. Entre las actividades que se deben realizar en este punto están la integración de los sensores y actuadores al sistema de control, la programación del *PLC/PC* con el modelo de estimación desarrollado en el punto 6 de la metodología propuesta, la obtención de la curva de descarga de la bomba y el desarrollo de la interfaz que permita la interacción del operador con el sistema de dosificación implementado.

10. *Actualización continua del modelo.* Dado que los modelos de estimación de coagulante, se desarrollan a partir de datos históricos es probable que existan escenarios que no pueden ser tratados con los modelos implementados. Por tanto, se hace necesario realizar periódicamente actualizaciones al modelo utilizado para la dosificación de coagulante, lográndose de esta manera con el paso del tiempo un modelo cada vez más

confiable y con la posibilidad de manejar escenarios de operación no considerados en su implementación inicial.

4.6. CONCLUSIONES

Con la utilización del sistema de dosificación desarrollado en la presente investigación, en un proceso de potabilización real, como el que se lleva a cabo en la planta de potabilización del municipio de Roldanillo, y dados los buenos resultados obtenidos, se demuestra cómo es posible la dosificación en línea de coagulante mediante el uso de técnicas de control inteligente. Entre las ventajas, observadas con la utilización de este esquema de control automático de la dosificación de coagulante, vale la pena destacar como la dosis se ajusta de forma instantánea a los cambios en la calidad y cantidad del agua cruda que ingresa a la planta, dado el control tipo *feedforward* empleado. Dicha rapidez en el ajuste de la dosis siguiendo la forma tradicional de dosificación de coagulante, basada en pruebas de jarras, es prácticamente imposible de lograr. Se debe resaltar igualmente como durante la prueba de validación del sistema de dosificación, éste fue expuesto a una gran variedad de condiciones en cuanto a la calidad del agua cruda se refiere y de acuerdo al comportamiento de la turbiedad del agua a la salida de los sedimentadores, es posible afirmar que el sistema de dosificación respondió de manera satisfactoria a cada uno de estos escenarios. Dados los buenos resultados obtenidos y su bajo costo de implementación comparado con otros sistemas de dosificación de coagulante en línea disponibles, se presenta una metodología que permite la implementación de sistemas de dosificación, similares al aquí implementado, en otras plantas de potabilización. Sin embargo, cabe resaltar cómo el empleo de este sistema de dosificación, no reemplaza la labor ni la experiencia de un operador de planta, sino que se constituye en una herramienta para el operador que le ayudará a tener un mejor control de la coagulación, permitiendo responder de mejor manera ante cambios abruptos en las características del agua cruda como las descritas anteriormente.

5. CONCLUSIONES Y TRABAJO A FUTURO

Con base en el trabajo investigativo y experimental acerca de la dosificación de coagulante aquí presentado, y a las inquietudes que surgieron en el desarrollo del mismo, se presentan a continuación las principales conclusiones y recomendaciones para futuros trabajos.

5.1. CONCLUSIONES

- Se logra a partir de datos históricos, presentar una propuesta consistente en la implementación de un sistema automático (tipo *feedforward*) que permite el ajuste de la dosificación en línea de coagulante en el proceso de potabilización del agua, a partir de las características de calidad del agua cruda y del caudal de entrada que se ingresa a la planta.

- La utilización de las técnicas de inteligencia computacional fue fundamental a lo largo de todo el proceso de implementación del sistema de dosificación. Redes neuronales tipo *MLP*, junto con técnicas estadísticas, fueron empleadas para la detección de *outliers* en los datos históricos que sirvieron de base para la implementación de los diferentes modelos implementados. Nuevamente, redes neuronales tipo *MLP* y mapas auto-organizados de *Kohonen* sirvieron para la selección de las variables de entrada al modelo de estimación. Los modelos de estimación de coagulante fueron desarrollados, mediante redes neuronales tipo *MLP*, modelos difusos tipo Mamdani y Sugeno, y modelos neuro-difusos tipo ANFIS. Finalmente, redes neuronales auto-asociativas y algoritmos genéticos fueron utilizados en una propuesta que permite la

validación de la información proveniente de los sensores de turbiedad, pH y conductividad.

- Con el desarrollo del presente trabajo, se confirma una vez más, como antes de tratar de emplear cualquier técnica de inteligencia artificial para la implementación de un modelo basado en datos históricos, es necesario realizar un pre-procesamiento de la información recolectada, el cual incluye detección de *outliers*, normalización de los datos y selección de las variables de entrada al modelo.

- Al momento de seleccionar las variables que servirán de entradas al modelo, es necesario evaluar el compromiso existente entre la complejidad del modelo y su robustez. Un modelo que maneje únicamente las variables que el proceso de selección determine como necesarias, tendrá baja complejidad pero será menos robusto, ya que la falla en alguno de estos sensores necesarios, generaría estimaciones equivocadas por parte del modelo. Un modelo en el que se incluyan no solo las variables necesarias, sino también otras que estén correlacionadas con aquellas necesarias, generaría un modelo más robusto que podría continuar entregando estimaciones válidas incluso ante fallas en algunos de los sensores de entrada al modelo. En caso de no contar con variables correlacionadas, aumentar la robustez del modelo sería posible mediante la utilización de sensores redundantes, especialmente en aquellos con mayor probabilidad de falla.

- De los modelos desarrollados, el que presenta los mejores índices de desempeño es el basado en redes neuronales, mientras que de los tres modelos que se implementaron usando inferencia difusa el que mejor resultado entregó fue el que empleó la estructura ANFIS, la cual comparte con las redes neuronales el mismo tipo de entrenamiento. Por su parte el modelo Mamdani el cual se obtuvo a partir de información lingüística proporcionada por el operador de planta fue el que peores índices de desempeño presentó, sin embargo, tiene la ventaja de que fue construido con base en reglas fácilmente entendibles por el ser humano.

- Se logró la implementación de modelos de redes neuronales tipo *MLP* y modelos de inferencia difusa tipo *ANFIS* en un *PLC* industrial comercial. La implementación de estos modelos requiere que el *PLC* seleccionado cuente con la capacidad de ejecutar operaciones, en coma flotante, tales como suma, resta, multiplicación, división, potencia y contar con la función exponencial, clave para la implementación de las funciones de activación de las redes neuronales y las funciones de membrecía en el modelo ANFIS.

- Se logra presentar una propuesta basada en redes neuronales auto-asociativas y algoritmos genéticos que permite la reconstrucción de la información proporcionada por sensores de calidad de agua en falla a partir de la existencia de redundancia analítica entre las variables medidas.

- El éxito alcanzado con la aplicación de las técnicas de inteligencia artificial para tratar el tema de la dosificación de coagulante en el proceso de la potabilización del agua, deja abierta la posibilidad del empleo de estas u otras técnicas de inteligencia artificial para abordar el modelamiento de otros sub-procesos que hacen parte de la potabilización, tales como la floculación, la sedimentación y filtrado. La obtención de estos modelos permitirían la implementación de herramientas de software que podrían ser empleadas en el entrenamiento de nuevo personal o para la simulación de ciertas condiciones operativas en la planta.

5.2 TRABAJO A FUTURO

- Se requiere trabajo adicional que permita determinar la mejor forma de actualizar los modelos de estimación de coagulante aquí desarrollados de forma tal que se puedan adaptar a nuevas condiciones de calidad de agua no previstas en la implementación inicial de los mismos.

- Se hace necesario realizar pruebas adicionales que permitan determinar las ventajas que desde el punto de vista del consumo de coagulante presenta el esquema de dosificación aquí desarrollado, respecto al tradicional de la prueba de jarras.

- Para la implementación del esquema de validación de la información basado en redes neuronales auto-asociativas y algoritmos genéticos, se hace necesario profundizar en la metodología que permita determinar cuál de los sensores empleados presenta una falla en sus mediciones, antes de entrar al proceso de aislamiento y reconstrucción del proceso de validación. De igual forma hace falta determinar cuál sería la mejor plataforma hardware/software para la implementación de un sistema de validación como esté en un ambiente industrial.

- Con el fin de poder realizar una comparación con la utilización de las redes neuronales auto-asociativas en la validación de la información, se recomienda abordar este problema mediante mapas auto-organizados de *Kohonen*, permitiendo de esta forma determinar cuál de las dos técnicas se ajusta mejor al problema de validación de la información aquí planteado.

BIBLIOGRAFIA

[1] AUSTRALIA. THE COOPERATIVE RESEARCH CENTRE FOR WATER QUALITY AND TREATMENT. Drinking Water Treatment [online]. *Available from World Wide Web: <http://www.waterquality.crc.org.au/dwfacts/DWF_Drinking_Water_Treatment_Nov08.pdf>*[Citado en Octubre 2009]

[2] FURNESS, R. Water Production and Supply - Measurement and Control Strategies. JDF and Associates Ltd. [online]. *Available from World Wide Web:< http://www.jdfandassociates.com/Technical/Water%20Production.pdf>* [Citado en Octubre 2009]

[3] EDNEY, Daniel. Introduction to the Theory of the Streaming Current Meter [online]. *Available from World Wide Web: <http://www.accufloc.com/downloads/SCMTheory.pdf>* [Citado en Agosto 2009]

[4] CENTRO PANAMERICANO DE INGENIERÍA SANITARIA Y CIENCIAS DEL AMBIENTE. Tratamiento de agua para consumo humano, plantas de filtración rápida Manual I: Teoría, Capítulo 4: Coagulación. 2004.

[5] ADGAR, A.; COX, C.S and JONES, C.A. Coagulation Control Using the Streaming Current Detector: Problems and a possible solution. EEC 03'- European Control Conference, 2003 [online]. *Available from World Wide Web: <http: //www.nt.ntnu.no/users/skoge/prost/proceedings/ecc03/pdfs/494.pdf>* [Citado en Octubre 2009]

[6] USA. UNITED STATES ENVIRONMENTAL PROTECTION AGENCY. Turbidity in Source Water, 1999 [online]. *Available from World Wide Web: < http://www.epa.gov/ogwdw/mdbp/pdf/turbidity/chap_09.pdf >* [Citado en Octubre 2009]

[7] DENTEL, S. K. and KINGERY, K. M. Using Streaming Current Detectors in Water Treatment. Journal American Water Works Association, p. 85-94, 1989.

[8] DENTEL S. K. Use of the Streaming Current Detector in Coagulation Monitoring and Control. Journal of Water Science Research and Technology – Aqua, p. 70-79, 1995.

[9] MILTON ROY. Streaming Current Detector Model SC5200. Instruction Manual, 2001 [online]. *Available from World Wide Web: http://www.miltonroy.com/Files/Milton_Roy/Global/US-en/product_files/339-0031-00.pdf>* [Citado en Julio 2010]

[10] ABLET, L. Use of Streaming Current Detector at Warragul Water Treatment Plant. 66th Annual Water Industry Engineers and Operators Conference. Eastbank Centre. p. 112 - 118, 2003.

[11] EDNEY, D. Control and Optimisation of Coagulant Dosing in Drinking Water Treatment, Ph.D. Thesis (Abstract). University of Auckland, 2005.

[12] NEW ZEALAND. GREATER WELLINGTON REGIONAL COUNCIL. Water Supply Annual Report. For the year ended 30 June 2008 [online]. *Available from World Wide Web: <http://www.gw.govt.nz/assets/council-publications/Water%20Supply%20Annual%20Report %20for%20the%20year%20ended%2030%20June%202008.pdf>* [Citado en Noviembre 2009]

[13] NEW ZEALAND. GREATER WELLINGTON REGIONAL COUNCIL. Divisional report for the year ended 30 September 2008 [online]. *Available from World Wide Web: <http://www.gw.govt.nz/council-reports/pdfs%5Creportdocs%5C2008_721_1_Report .pdf>* [Citado en Noviembre 2009]

[14] S::CAN. Drinking water and open waters application sheets, V2.0. [online]. *Available from World Wide Web: <http://www.s-can.at/fileadmin/scan/xLeftmenu/APPLICATIONS/Drinking_Water/e_App_TWOW_3_0.pdf>* [Citado en Enero 2010]

[15] DCM PROCESS CONTROL. Advanced coagulation control system. Mayo 2007 [online]. *Available from World Wide Web: http://h2ope.co.nz/ra.asp?url=/webfiles/h2opeNZ/files /CompassProductSheet.pdf>* [Citado en Enero 2010]

[16] CRITCHLEY, R., SMITH, E and PETTIT, P. Automatic Coagulation Control at Water-Treatment Plants in the North-West Region of England. Water and Environment Journal, p. 535-543, 1990.

[17] AUSTRALIA. THE COOPERATIVE RESEARCH CENTRE FOR WATER QUALITY AND TREATMENT. Modelling Coagulation to Maximize Removal of Organic Matter, 2007 [online]. *Available from World Wide Web: http://www.waterquality.crc.org.au/publications/report36_modelling_coagulation.pdf>* [Citado en Octubre 2009]

[18] AUSTRALIA. THE COOPERATIVE RESEARCH CENTRE FOR WATER QUALITY AND TREATMENT. Characterisation of Natural Organic Matter of Drinking Water Reservoir – Catchment Systems, 2001 [online]. *Available from World Wide Web: <http://www.waterquality.crc.org.au/publications/Report12_NOM_Reservoir_Catchment.pdf>* [Citado en Octubre 2009]

[19] AUSTRALIA. THE COOPERATIVE RESEARCH CENTRE FOR WATER QUALITY AND TREATMENT. Characterisation of Natural Organic Matter in Relation to Drinking Water and Alum Treatment, 2001 [online] *Available from World Wide Web: <http://www.waterquality.crc.org.au/publications/Report15_NOM_Alum.pdf>* [Citado en Octubre 2009]

[20] MIRSEPASSI, A.; CARTHERS, B. and DHARMAPPA, H.B. Application of Artificial Neural Networks to the Real Time Operation of Water Treatment Plants. Proceedings of the IEEE International Conference on Neural Networks, Vol. 1, p. 516-521 , 1995.

[21] VALENTIN, N.; DENOUX, T.; FOTOOHI, F. An Hybrid Neural Network Based System for Optimization of Coagulant Dosing in a Water Treatment Plant. International Joint Conference on Neural Networks, Vol.5, p. 3380 – 3385, 1999.

[22] YI, XueNong; WEI, QiuMei and LI, ChenGuang. The BP network model for the control of the coagulation and the filter backwashing system. The Second International Conference on Bioinformatics and Biomedical Engineering, p. 1518 – 1521, 2008.

[23] BAXTER, C.W., et al. Model – Based Advanced process control of coagulation. Water Science and Technology, Vol. 45, No. 4-5 p. 9-17, 2002.

[24] LENNOX, Barry, et al. Industrial application of neural networks – An investigation. Journal of Process Control 11, p. 497- 507, 2001.

[25] MAIER, H.; MORGAN, N. and CHOW, W. Use of artificial neural networks for predicting optimal alum doses and treated water quality parameters. Environmental Modelling & Software, Vol. 19, p. 485-494, 2004.

[26] WU, Guan-De and LO, Shang-Lien. Predicting real-time coagulant dosage in water treatment by artificial neural networks and adaptive network-based fuzzy inference system. Engineering Applications of Artificial Intelligence, p. 1189 – 1195, 2008.

[27] JOO, Dae-Sung; CHOI, Dong-Jin and PARK, Heekyung. The effects of data preprocessing in the determination of coagulant dosing rate. Wat. Res., Vol 34, No. 13, p. 3295 – 3302, 2000.

[28] NAHM, E, et al. Development of an optimum software package for coagulant dosing process in water purification system. SICE, p. 1157 – 1161, 1996.

[29] NAHM, E, et al. Optimization of coagulant dosing process in water purification system. SICE, p. 1105 – 1109, 1997.

[30] BAI, H., GAO, L., LI, G.Neural Networks Based Optimum Coagulation Dosing Rate Control Applied to Water Purification System. Proceedings of the 4th World Congress on lntelligent Control and Automation, p.1432- 1435, 2002.

[31] LI, W. RBF Neural Network Predictive Control for Coagulant Dosage. Proceedings of the 5th World Congress on Intelligent Control and Automation.p. 2608 – 2611, 2004.

[32] WANG, Pei-Jein and COX, Chris. Study on the application of Auto-Associative neural network 2004. Proceedings of the Third International Conference on Machine Learning and Cybernetics, (Shanghai, China), p. 26-29, 2004.

[33] WANG, Pei-Jein. Design and Application of Soft Sensor Object in Process Control. Proceedings of the Sixth International Conference on Intelligent Systems Design and Applications, p. 107-11, 2006.

[34] CHUN, Myung-Geun; KWAK, Keun-Chang and RYU, Jeong-Woong. Application of ANFIS for Coagulant Dosing Process in a Water Purification Plant. Fuzzy Systems Conference Proceedings. p. 1743 – 1748, 1999.

[35] TAMBO, Norihito, *et al.* Control of Coagulation Process by Dual Wavelength Article Analyzer. Wat. Sci. Tech. Vol 36.p.135-142, 1997.

[36] SONG, Zheying, *et al.* Research on Prediction Model of Optimal Coagulant Dosage in Water Purifying Plant Based on Neural Networks. International Colloquium on Computing, Communication, Control and Management ISECS. p 258 – 261, 2009.

[37] LAMRINI, B, *et al.* A Neural Network System for modeling of coagulant dosage used in drinking water treatment. Adaptive and Natural Computing Algorithms. Part I. p. 96-99, 2005.

[38] KWAK, Keun – Chang. Genetically Optimized Linguistic Models. International Conference on Control , Automatización and Systems (Seul – Corea del Sur) p. 1403-1406, 2008.

[39] KIM, Sung-Suk and KWAK, Keun – Chang. Development of Quantum-Based Adapted Neuro-Fuzzy Networks. IEEE Transactions on Systems, Man and Cybernetics – Part B: Cybernetics, Vol 40. No. 1. p 91-100, 2010.

[40] BAI, Hua. A Fuzzy Logic Based Coagulant Real Time Control Squeme for Water Purification Systems. Proceedings of the IEEE International Conference on Mechatronics and Automation (Changchun, China).p 2123- 2127, 2009

[41] DUQUE, Mauricio, *et al.* El Uso de la Lógica Difusa para la Potabilización del Agua. Revista de Ingeniería de la Universidad de los Andes, No. 12 p 31-35. Noviembre de 2000.

[42] RANK BROTHERS LTDA. Photometric Dispersion Analyser PDA2000. Operating Manual, 2010 [online]. *Available from World Wide Web: <http://www.rankbrothers.co.uk/download/pda2000.pdf>* [Citado en Enero 2010]

[43] BLOCH, G. and DENOUEX, T. Neural Networks for Process Control and Optimization: Two Industrial Applications. ISA Transactions, p. 39 – 51, 2003.

[44] MEIRELES, R; *et al*. A Comprehensive Review for Industrial Applicability of artificial neural networks, IEEE Transactions on Industrial Electronics,Vol. 50, No. 3, p. 585 – 601, 2003.

[45] HILERA, J; MARTINEZ V. Redes Neuronales Artificiales: Fundamentos Modelos y Aplicaciones. Addison-Wesley, 1995, 390p.

[46] CAICEDO, Eduardo; LOPEZ, Jesús. Una Aproximación Práctica a las Redes Neuronales Artificiales. Universidad del Valle, 2009, 217p.

[47] Ben-Gal I. Outlier Detection, 2005 [online] *Available from World Wide Web: <http://www.eng.tau.ac.il/~bengal/outlier.pdf>* [Citado en Julio 2010]

[48] DEVORE, J. Probabilidad y estadística para ingeniería y ciencias. Thomson, 2005, 794p.

[49] MENDENHALL, W; SCHEAFFER, R; WACKERLY D. Estadística Matemática con Aplicaciones. Grupo Editorial Iberoamérica, 1986, 751p.

[50] MARTINEZ, W; MARTINEZ, A. Exploratory data analysis with Matlab. Chapman & Hall/CRC, 2005, 405p.

[51] SANTOS, M; MONTEIRO, A; SIMEAO, J. Visualization of geospatial data by component planes and U- Matrix, Brasil, 2004 [online] *Available from World Wide Web: <http://www.geoinfo.info/geoinfo2004/papers/6419.pdf>* [Citado en Junio 2010]

[52] ULTSCH, A; SIEMON H. Kohonen's SeIf Organizing Feature Maps for Exploratory Data Analysis. Proceedings of International Neural Networks Conference, p. 305-308, 1990.

[53] CHIU, S. Selecting Input Variables for Fuzzy Models. Journal of Intelligent & Fuzzy Systems, Vol. 4, No. 4, p. 243-256, 1996.

[54] PASSINO, K; YURKOVISH, S. Fuzzy Control. Addison-Wesley, 1998, 502p.

[55] JUUSO, E. Modelling and Simulation with Intelligent Methods. Finlandia, 2005 [online] *Available from World Wide Web: <http://www.sim-serv.com/pdf/whitepapers/ whitepaper_115.pdf>* [Citado en Enero 2010]

[56] <http://www.cs.nthu.edu.tw/~jang/anfisfaq.htm> [Citado en Enero 2010]

[57] KAUR, D; BAUMGARTNER, D. A comparative Analysis of Neuro-Fuzzy and Grammatical Evolution models for simulating Field-Effect Transistors. World Congress on Computer Science and Information Engineering. 2009.

[58] CHIU, S. Extracting Fuzzy Rules from Data for Function Approximation and Pattern Classification, 1997 [online]. *Available from World Wide Web: < http://chius.homestead.com/files/ExtractRulesFromData.pdf>* [Citado en Abril 2010]

[59] KAYMAK, U.; SETNES, M. Extended Fuzzy Clustering Algorithms. Netherlands, 2000 [online] *Available from World Wide Web: < http://publishing.eur.nl/ir/repub/asset/57/ erimrs20001123094510.pdf>* [Citado en Abril 2010]

[60] ZHANG, W; HU, H; LIU W. Rules Extraction of Interval Type-2 Fuzzy Logic System based on Fuzzy c-Means Clustering. Fourth International Conference on Fuzzy Systems and Knowledge Discovery, 2007

[61] JANG, R. ANFIS : Adaptive-Network-Based Fuzzy Inference System. IEEE Transactions on systems, Man and Cybernetics, Vol. 23, No. 3, June 1993

[62] Sistemas Neuro Difusos. Grupo de Investigación Percepción y Sistemas Inteligentes. Universidad del Valle.

[63] MATERN, D; *et al.* Using Neural Networks for Sensor Validation. 34th Joint Propulsion Confrence, NASA, 1998.

[64] LU, P; HSU, T. Application of Autoassociative Neural Network On Gaspath Sensor Data Validation. Journal of Propulssion and Power. Vol. 18, No. 4, p. 879-888, 2002.

[65] GALOTTO, L; *et al*. Auto-Associative Neural Network Based Sensor Drift Compensation in Indirect Vector Controlled Drive System. The 33rd Annual Conference of the IEEE Industrial Electronics Society, Taiwan, 2007.

[66] KRAMER, A. Nonlinear Principal Component Analysis Using Autoassociative Neural Networks. USA, 1991 [online]. *Available from World Wide Web: < http://math.stanford.edu/research/comptop/references/kr.pdf>* [Citado en Abril 2010]

[67] GESTAL, M. Introducción a los algoritmos genéticos [online*]. Available from World Wide Web: < http://sabia.tic.udc.es/mgestal/cv/AAGGtutorial/TutorialAlgoritmos Geneticos.pdf>* [Citado en Julio 2010]