

xx(178633.1)



CINVESTAV
BIBLIOTECA CENTRAL




SSIT000009507

TK165 98

C37

2009



Centro de Investigación y de Estudios Avanzados
del Instituto Politécnico Nacional
Unidad Guadalajara

Control Inteligente Híbrido para el Tratamiento de Aguas Residuales por Lodos Activados

Tesis que presenta:

Rocío Carrasco Navarro

para obtener el grado de:

Maestro en Ciencias

en la especialidad de:

Ingeniería Eléctrica

Directores de Tesis

Dr. Edgar Nelson Sánchez Camperos

Dra. Catherine Cadet

CINVESTAV del IPN Unidad Guadalajara, Guadalajara, Jalisco, Diciembre de 2009.



CENTRO DE INVESTIGACIÓN Y
DE ESTUDIOS AVANZADOS DEL
INSTITUTO POLITÉCNICO
NACIONAL

COORDINACIÓN GENERAL DE
SERVICIOS BIBLIOGRÁFICOS

CLASIF.: TK165.GB C37 2009
ADQUIS.: SSI-585
FECHA: 20-Mayo-2010
PROCESO DON.-2010

164549-1001

Control Inteligente Híbrido para el Tratamiento de Aguas Residuales por Lodos Activados

**Tesis de Maestría en Ciencias
Ingeniería Eléctrica**

Por:

Rocío Carrasco Navarro
Ingeniero en Comunicaciones y Electrónica
Universidad de Guadalajara 2001-2006

Becario de CONACYT, expediente no. 13402

Directores de Tesis
Dr. Edgar Nelson Sánchez Camperos
Dra. Catherine Cadet

CINVESTAV del IPN Unidad Guadalajara, Diciembre de 2009.

Abstract.

The activated sludge is one of the most extended biological wastewater treatment processes. This is due to its easy implementation and the high treatment performance. Even when this process offers advantages and benefits, it is sensitive to alterations on the operating conditions converting it in a problematic technology for many of its users. Most of the issues comes when the wastewaters for treatment present a significant change in their composition and/or their flow rate; these issues does the application of control strategies for the bioprocess a difficult one.

The problem of using control strategies on this kind of processes is the requirement of measures through sensors for main variables as for substrate and biomass; that sensor are very expensive and requires a lot of time for maintenance. Due to this fact, states estimation for a wastewater plant and biological process in general, has been strongly investigated recently.

This thesis presents the design of an identifier and a recurrent high order neural observer, to estimate the concentrations of substrate and biomass in a prototype for wastewater treatment by activated sludge. This identifier and this observer are based on a recurrent high order neural network, trained on line with the extended Kalman filter algorithm. Besides, the observer is associated with an intelligent hybrid system to control the rate of the substrate and biomass, which guarantees optimal operating conditions and the required effluent quality.

Resumen

Los lodos activados constituyen el proceso biológico de tratamiento de aguas residuales más usado. El empleo generalizado de los lodos activados se debe a que se trata de un proceso de fácil implementación y que consigue elevados rendimientos de tratamiento. Aún cuando este proceso ofrece ventajas y beneficios, es sensible a las perturbaciones de proceso convirtiéndolo en una tecnología problemática para muchos de sus usuarios. La mayoría de los problemas se derivan cuando el agua residual a tratar varía significativamente en composición y/o caudal; esta problemática dificulta la aplicación de estrategias de control al bioproceso.

El problema de utilizar las estrategias de control es que requieren las mediciones por medio de sensores de las variables principales como sustrato y biomasa; estos sensores son muy costosos y requieren procedimientos de mantenimiento muy elaborados. Debido a esto, la estimación de estados en una planta de tratamiento de aguas residuales y en procesos biológicos en general, ha sido investigada de forma muy importante recientemente.

Esta tesis presenta el diseño de un identificador y de un observador neuronal recurrente de alto orden, para estimar las concentraciones de biomasa y sustrato en un prototipo de tratamiento de aguas de lodos activados. Este identificador y observador están basados en una red neuronal recurrente de alto orden, entrenada en línea con el algoritmo de filtro de Kalman extendido. Además, dicho observador es asociado con un sistema inteligente híbrido para controlar la proporción de las concentraciones de sustrato y biomasa, que garanticen buenas condiciones de operación, para asegurar la calidad requerida del efluente.

Índice general

1. Introducción	7
2. Descripción del Proceso y Prototipo	11
2.1. Proceso de Lodos Activados	11
2.1.1. Principios del Proceso de Lodos Activados	12
2.1.2. Parámetros del Proceso de Lodos Activados	13
2.2. Descripción del Prototipo	14
2.3. Determinación del Modelo	16
2.3.1. Hipotesis de simplificación	17
2.3.2. Modelo Matemático .	17
2.4. Estructura y composición del influente	19
3. Control Difuso	21
3.1. Bases de Control Difuso	21
3.1.1. Reglas, Variabes y Valores Lingüísticos	22
3.1.2. Módulo de Fuzzificación	23
3.1.3. Máquina de inferencias	24
3.1.4. Módulo de Defuzzificación	25
3.2. Sistemas Difusos Funcionales .	25
3.2.1. Estructura de las Reglas	26
3.2.2. Método de Defuzzificación	26
3.3. Control Supervisor Difuso	26
3.4. Control PI Discreto	27
3.5. La Técnica L/A	28

4. Estimación Neuronal de Estados	31
4.1. Redes Neuronales	32
4.2. Aproximación por una Red Neuronal Discreta de Alto Orden.	33
4.3. El Filtro de Kalman Extendido como Algoritmo de Entrenamiento	34
4.4. Identificación del Prototipo de Tratamiento de Aguas Residuales	35
4.5. Observador Neuronal Discreto	36
4.6. Aplicación del Observador Neuronal Discreto a un Prototipo de Tratamiento de Aguas	38
5. Control Inteligente Híbrido para el Prototipo de Tratamiento de Aguas Residuales	41
5.1. Diseño del Control Inteligente Híbrido	41
5.2. Aplicación del Control Inteligente Híbrido	44
5.3. Técnicas de Control Propuestas para el Prototipo de Tratamiento de Aguas Residuales	47
6. Conclusiones	49
A. Demostración del Teorema 4.1	57
B. Artículos Publicados	61

Índice de figuras

2.1. Esquema del Proceso de Lodos Activados	12
2.2. Prototipo de lodos activados	15
2.3. Esquema del prototipo	16
2.4. Flujo volumétrico del influente	19
3.1. Estructura general de un controlador difuso	21
3.2. Pertenencia trapezoidal .	23
3.3. Estrategia general del controlador supervisor difuso	27
3.4. Principio de la técnica L/A	29
4.1. Variables de estado (línea continua) y su respectiva identificación (línea punteada).	36
4.2. Esquema del observador	38
4.3. Sustrato rápidamente biodegradable (línea continua) y su respectiva estimación (línea punteada).	40
4.4. Biomasa heterotrófica (línea continua) y su respectiva estimación	40
4.5. Concentración de oxígeno disuelto(línea continua) y su respectiva estimación (línea punteada).	40
5.1. Esquema de Control Inteligente Híbrido .	42
5.2. Dependencia de las velocidades de crecimiento de biomasa con respecto a la concentración de oxígeno disuelto.	43
5.3. Funciones de membresía de entrada	43
5.4. Regulación RT, considerando las variabes de la planta (línea continua) y RT utilizando las estimaciones del indentificador (línea punteada).	44
5.5. Acción de control de la constante de aireación	45

5.6. Acción de control del flujo de recirculación	45
5.7. Concentración de oxígeno disuelto con el controlador PI -LA .	47
5.8. Constante de aireación	48
A.1. Ilustración gráfica del Teorema 4.1	59

Agradecimientos

Este trabajo está dedicado

A mis padres, **Jesús R. Carrasco y Alejandrina Navarro** por todo su cariño y por ser mi principal soporte.

A mis hermanos **Karina Carrasco y Jesús Carrasco** por todo su apoyo.

Quiero agradecer

A **Luis F. Luque** por todo su apoyo y amor.

A mis compañeros de generación en especial a **Carmen Guillén, Roberto Ross, Eduardo Castañeday Riemann Ruíz** por su amistad y cariño.

Al **Dr. Edgar N. Sánchez** por sus enseñanzas y la confianza depositada en mi.

A la **Dra. Catherine Cadet** por su hospitalidad.

A mis sinodales el **Dr. Javier Ruíz, Antonio Ramírez y Dr. Salvador Carlos** por sus comentarios que ayudaron a enriquecer este trabajo.

Al **CINVESTAV** por abrirme la posibilidad de realizar mis estudios de posgrado.

Al **CONACyT** por la ayuda económica brindada.

Capítulo 1

Introducción

El agua juega un papel esencial en el desarrollo, crecimiento y supervivencia de los seres vivos. Es un integrante fundamental de la estructura biológica y componente primordial de la higiene personal y comunitaria. Es indispensable para la agricultura y la ganadería y por lo tanto para mantener la capacidad de alimentación de los pueblos. Sin embargo, el agua que procede de fuentes superficiales (ríos, lagos y quebradas), es objeto día a día de una severa contaminación, producto de las actividades del hombre; esta contaminación se ha acrecentado debido al aumento de la población y al incremento de los agentes contaminantes.

Esta problemática se ha tratado de resolver con el uso de plantas tratadoras para la reutilización del agua. Las plantas de tratamiento de aguas residuales (PTAR) involucran métodos físicos, químicos y biológicos para su descontaminación, dejándola utilizable para riego, actividades industriales y en ocasiones para consumo humano.

En nuestro país, los principales procesos de tratamiento de aguas residuales existentes son el proceso de laguna de estabilización y el proceso de lodos activados. El proceso de lodos activados ocupa el segundo lugar nacional en cuanto al número de plantas con 417 y el primer lugar nacional en cuanto al caudal tratado (44.32% del total) [1].

Las plantas de tratamiento de aguas residuales que operan con el proceso de lodos activados presentan muchas dificultades en su operación; entre las más importantes podemos mencionar [2]:

- El volumen diario de aguas residuales tratadas puede llegar a ser muy grande.

El influente es afectado por lluvias y tormentas; por ello las perturbaciones son muy grandes comparadas con otro tipos de procesos industriales.

Existe un rango muy amplio en los tiempos de respuesta de las diferentes dinámicas.

- Los diseñadores a menudo dejan muy pocas variables manipulables y un rango muy reducido en acciones de control.

Los elementos de medición en línea, de las principales variables, no existen o son muy caros.

Las PTAR que operan mediante el proceso de lodos activados son comúnmente utilizadas para el tratamiento de aguas residuales urbanas. Esta clase de plantas son capaces de tratar volúmenes muy grandes, con la calidad adecuada. Para mantener la calidad del efluente y al mismo tiempo disminuir el consumo de energía [3] se requiere de diferentes técnicas de control [4],[5] y [6] lo cual no necesariamente es una tarea fácil. El problema del control radica, por un lado, en las perturbaciones del influente, producidas por las variaciones en la concentración de sustrato y del flujo, que afectan directamente la calidad del efluente; y por otro, en la inexistencia de mediciones en línea de las principales variables involucradas en el proceso. Por lo tanto las estrategias propuestas hasta el momento son difíciles de implementar en procesos reales. Debido a estos problemas surge la necesidad de desarrollar observadores, los cuales estimarán las principales variables de estado para ser usadas conjuntamente con las técnicas de control.

Cuando se diseñan estrategias de control para plantas aeróbicas de tratamiento de aguas residuales deben cumplirse tres objetivos: en primer lugar, garantizar la estabilidad de los lazos locales de control; en segundo lugar, garantizar la buena calidad del efluente de la planta; y en tercer lugar, minimizar los costos de operación sin sacrificar los objetivos anteriores. Debido a la complejidad de los modelos matemáticos de estos procesos, resulta muy difícil la aplicación de técnicas de control basadas en el modelo; por ese motivo se propone utilizar técnicas de control difuso.

En esta tesis se diseña un identificador para sistemas no lineales basado en una red neuronal recurrente de alto orden discreta con el propósito de identificar variables importantes en una PTAR; tales como, el sustrato rápidamente biodegradable, biomasa heterotrófica, biomasa autotrófica, oxígeno disuelto y nitrógeno amoniacal. De igual manera se diseña un observador neuronal con el fin de estimar sustrato rápidamente biodegradable, biomasa heterotrófica y oxígeno disuelto. Ambas estructuras, tanto del identificador como del observador, se basan en sigmoidales como función de activación y se entrenan con el filtro de Kalman extendido. Las principales ventajas que ofrecen el identificador y el observador son su alto desempeño y su bajo nivel de complejidad; además el conocimiento del modelo no es estrictamente necesario. Posteriormente, se propone un esquema de control inteligente híbrido para un prototipo de tratamiento de aguas, el cual tiene por objetivo regular la proporción de sustrato y biomasa; se implementa un supervisor difuso con la finalidad de aplicar las acciones de control en función de las condiciones de operación. La estrategia de control es validada vía simulación.

La presente tesis está organizada de la siguiente manera:

El **capítulo 2** presenta la descripción tanto del proceso de lodos activados como la del prototipo de tratamiento de aguas residuales empleado en este trabajo.

El **capítulo 3** describe las herramientas de control difuso, y de técnicas adicionales como el controlador convencional PI y PI-LA.

El **capítulo 4** presenta las herramienta de redes neuronales y la descripción del proceso de

aprendizaje; también se presenta el diseño de un identificador y un observador neuronal, mostrando los resultados a nivel simulación.

El **capítulo 5** describe los resultados de simulación del identificador neuronal bajo las acciones del controlador aplicadas a la planta.

En el **capítulo 6** se presentan las conclusiones generales de los resultados obtenidos en este trabajo y se plantean perspectivas para trabajos futuros.

En el **Apéndice A** se presenta la demostración del teorema 4.1.

En el **Apéndice B** se enlistan los artículos publicados resultado de este trabajo

Capítulo 2

Descripción del Proceso y Prototipo

En este capítulo se presenta la descripción de un prototipo de tratamiento de aguas residuales. Este prototipo es utilizado para desarrollar el identificador y las estrategias de control descritas en capítulos posteriores. Además, se incluye una descripción de las características físicas de los componentes principales de dicho prototipo y se enlistan las variables de estados que se utilizan en los modelos matemáticos.

2.1. Proceso de Lodos Activados

El proceso de los lodos activados para el tratamiento de aguas residuales está basado en proporcionar un contacto íntimo entre las aguas residuales y lodos biológicamente activos. Los lodos se desarrollan inicialmente por una aireación prolongada bajo condiciones que favorecen el crecimiento de organismos que tienen la habilidad especial de oxidar materia orgánica. Cuando los lodos que contienen estos organismos entran en contacto con las aguas residuales, los materiales orgánicos se oxidan, y las partículas en suspensión y los coloides tienden a coagularse y formar un precipitado que se sedimenta con bastante rapidez. Es necesario un control de operación muy elevado para asegurar que se tenga una fuente suficiente de oxígeno, que exista un contacto íntimo y un mezclado continuo de las aguas residuales y de los lodos, y que la relación del volumen de los lodos activados agregados al volumen de aguas residuales que están bajo tratamiento se mantenga prácticamente constante.

En el proceso de lodos activados, los microorganismos son completamente mezclados con la materia orgánica en el agua residual de manera que ésta les sirve de alimento para su producción. Es importante indicar que la mezcla o agitación se efectúa por medios mecánicos (aeradores superficiales, sopladores, etc) los cuales tienen una doble función:

1. Producir mezcla homogénea .
2. Agregar oxígeno al medio para que el proceso se desarrolle de manera adecuada.




Figura 2.1: Esquema del Proceso de Lodos Activados

La representación esquemática del proceso de lodos activados se muestra en el diagrama mostrado en la Figura 2.1

2.1.1. Principios del Proceso de Lodos Activados

1. Instalación típica

Los elementos básicos de las instalaciones del proceso de lodos activados son:

- *Tanque de aireación:* estructura donde las aguas residuales y los microorganismos son mezclados produciendo una reacción biológica.
- *Tanque sedimentador:* las aguas residuales procedentes del tanque aireador son sedimentadas separando los sólidos suspendidos (lodos activados) y obteniéndose un efluente tratado clarificado.
- *Equipo de aireación:* permite la inyección de oxígeno para activar las bacterias heterotróficas.
- *Sistema de retorno de lodos:* el propósito de este sistema es el de mantener una alta concentración de microorganismos en el tanque de aireación. Una gran parte de sólidos biológicos sedimentables en el tanque sedimentador son retornados al tanque de aireación.
- *Exceso de lodos y su disposición:* el exceso de lodos, debido al crecimiento bacteriano en el tanque de aireación, es eliminado, tratado y dispuesto.

1. Operación básica

- *Pretratamiento de aguas residuales:* en algunos casos las aguas residuales deben ser acondicionadas antes de comenzar con el proceso de lodos activados, esto debido a que ciertos elementos inhiben el proceso biológico (grandes cantidades sólidos, aguas residuales con valores anormales de pH, etc).

Remoción de la demanda bioquímica de oxígeno (DBO) en un tanque de aireación: las aguas residuales crudas mezcladas con el lodo activado retornado del tanque sedimentador es aireado hasta obtener 2mg/L de oxígeno disuelto o más, en donde una parte de materia orgánica contenida en las aguas residuales es mineralizada y gasificada, y la otra parte, es asimilada como nuevas bacterias.

- *Operación sólido-líquido en el tanque de sedimentación:* los lodos activados provenientes del tanque de aireación deben ser separados del licor mezclado, este proceso se realiza en el tanque de sedimentación donde se concentran los lodos activados por gravedad. Las finalidades de este proceso son: conseguir un efluente clarificado con un mínimo de sólidos suspendidos, y asegurar el lodo de retorno.

Descarga del exceso de lodos: con la finalidad de mantener la concentración de los lodos activados en el licor mezclado a un determinado valor, una parte de los lodos son eliminados del sistema a lechos de secado o a espesadores seguidos de filtros mecánicos (filtros prensa, de cinta, etc) para posteriormente disponer el lodo seco como residuo sólido.

2.1.2. Parámetros del Proceso de Lodos Activados

Existen parámetros operacionales que son característicos del proceso de lodos activados y cuyos rangos se deben respetar para mantener un rendimiento óptimo.

Carga másica: es la relación entre la carga de materia orgánica que entra en el reactor biológico por día y la masa de microorganismos existentes en el mismo. Tiene una relación directa con el rendimiento de depuración que puede dar la planta. Se expresa como:

$$C_m = \frac{Q \cdot S_O}{V \cdot X} \text{ (kg DBO}_5\text{/día} \cdot \text{kg MLVSS)} \quad (2.1)$$

donde

Q = caudal a tratar ($\text{m}^3\text{/día}$)

S_O = cantidad de DBO_5 que entra en el bioreactor por unidad de volumen (kg/m^3)

V = volumen del bioreactor (m^3)

X = concentración de sólidos suspendidos en el bioreactor ($\text{kg MLVSS}/\text{m}^3$)¹

¹MLVSS - Sólidos Suspendidos Volátiles en Licor Mezclado

Edad del lodo: es la relación entre la masa de lodos existentes en la tanque de aireación y la masa de lodos purgados por unidad de tiempo, días normalmente. Según la edad del lodo tendremos un cultivo más o menos estable con mayor o menor capacidad para degradar la DBO. Se expresa como:

$$E = \frac{V \cdot X}{Q_p \cdot X_p} (\text{días}) \quad (2.2)$$

donde

Q_p = caudal de purga de lodos

X_p = sólidos en suspensión volátiles de lodos purgados o lodos en exceso

Carga volumétrica: es la relación entre la masa de materia orgánica que entra en el reactor, por unidad de tiempo y el volumen del reactor. Se expresa como:

$$C_v = \frac{Q \cdot S_o}{V} (\text{kg DBO}_5/\text{día}) \quad (2.3)$$

Rendimiento en la depuración: es la relación entre la masa de la materia orgánica eliminada y la del influente que entra en el reactor biológico. Se expresa en porcentaje de eliminación:

$$R = \frac{S_o - S}{S_o} (\%) \quad (2.4)$$

2.2. Descripción del Prototipo

Todos los componentes de un proceso de tratamiento biológico- industrial son incluidos en este prototipo. El proceso se presenta en la Figura 2.2

En este esquema se presentan tres partes principales: 1) el reactor biológico, en el cual la biomasa asimila la contaminación. Un sistema de aireación movable produce compartimientos aerobios para tratar los efluentes urbanos o industriales. Los deflectores movibles permiten adaptar comportamientos hidrodinámicos para configuraciones de procesos diferentes (canal aireador, series CSTR etc); en el reactor biológico es donde se lleva a cabo el tratamiento del influente por medio de lodos activados, 2) el sedimentador secundario, en el cual se lleva a cabo la precipitación de los lodos, y 3) un sistema de recirculación de lodo, el cual permite mantener una concentración de biomasa constante en el proceso

El prototipo ha sido diseñado bajo las referencias de las plantas de tratamiento urbanas e industriales, cuyas características se muestran a continuación:

- Carga volumétrica para ser tratada: 0.8 a 1.3 $C_v(\text{kgDBO}_m^{-3}/\text{día})$




Figura 2.2: Prototipo de lodos activados

- Tiempo de residencia basado en el flujo total de entrada: 2-12 h
- Volumen total del reactor biológico: 0.250 m^3 .
- Constante de aireación: 240 días^{-1} .
- Volumen del sedimentador secundario: 0.107 m^3
- Recirculado interno Q_{ia} , con flujo de diseño de $Q_{i,a,diseño} = 55,338 \text{ m}^3/\text{día}$.
- Recirculado externo Q_r , con flujo de diseño de $Q_{r,diseño} = 18,446 \text{ m}^3/\text{día}$
- Flujo de lodos de desperdicio $Q_w = 385 \text{ m}^3/\text{día}$.
- Flujo promedio del influente de la planta de $Q_{0,prom} = 18,446 \text{ m}^3/\text{día}$.

El rango del flujo de entrada y el volumen del reactor han sido dimensionados como un compromiso entre un tamaño real y las limitaciones previas.

Elementos adicionales complementan el prototipo cuyo esquema es presentado en la Figura 2.3, tales como:

- Un tanque de almacenamiento para obtener el influente.
- Un tanque de reserva que permite ajustes de pH y de nutrientes en el influente
- Un dispositivo eléctrico independiente garantiza la seguridad de todo el proceso, de los materiales y de los humanos.
- Un dispositivo industrial supervisa el proceso en sus diferentes modos de operación. Estos modos son implementados en el bioreactor por medio de lazos de control para el nivel del líquido y para la concentración de oxígeno disuelto.

El prototipo cuenta con diferentes mediciones:

- Sensores en línea: pH, temperatura, concentración de oxígeno disuelto y conductimetría.
- Mediciones fuera de línea con un dispositivo de muestreo automático: demanda química de oxígeno, demanda biológica de oxígeno, concentraciones de nitrógeno para el efluente y el agua tratada.




Figura 2.3: Esquema del prototipo

El objetivo del proceso es mantener el efluente dentro de las normas de calidad. Para alcanzar este objetivo, se debe mantener una buena actividad biológica y rechazar perturbaciones tan eficientemente como sea posible. Este proceso está diseñado para la eliminación de sustancias orgánicas. En esta tesis se toma en cuenta los procesos aeróbicos que tienen lugar en el bioreactor.

2.3. Determinación del Modelo

Para el proceso de lodos activados, un modelo de referencia ha sido propuesto por el grupo COST Action 624 [7], donde el modelo biológico corresponde a lodos activados (ASM1) desarrollado por el grupo de trabajo de la asociación internacional en calidad de agua (IAWQ)[8]. Dado el número de variables de estado y parámetros, este modelo es difícil para manejar para propuestas de estimación, mientras un modelo simplificado es más conveniente, siempre respetando un equilibrio entre la complejidad y la precisión. Gracias a trabajos previos[9], [10], el diseño de un nuevo modelo reducido, cuyas simplificaciones se basan principalmente en consideraciones biológicas es presentado. Este modelo reducido ha sido diseñado para efluentes industriales (tratamiento de materia carbónica).

2.3.1. Hipotesis de simplificación

1. *Hidrodinámica.* Todos los compartimentos del reactor biológico, tanto los aireados como los no aireados, tienen mezcla perfecta (misma concentración en todos los puntos de un mismo compartimento), lo cual proporciona una gran reducción del número de estados.
2. *Consideración de variables de estado.* Sólo los componentes necesarios para las principales reacciones son mantenidos y conducen a cinco variables de estado (en lugar de 13):

1 fracción de nitrógeno amoniacal

- 1 fracción de materia orgánica

2 tipos de microorganismos (biomasa heterotrófica y biomasa autotrófica)

1 fracción de oxígeno disuelto

3. *Proceso biológico.* Sólo cuatro procesos son considerados: desintegración de la biomasa heterotrófica y autotrófica, la oxidación del carbón y la nitrificación.

2.3.2. Modelo Matemático

A continuación se detalla el modelo matemático utilizado para simular las dinámicas del prototipo en fase aerobia. Este modelo y todos los parámetros que lo definen fueron tomados de [11]. El modelo matemático que se utiliza para describir la dinámica del proceso, la configuración de la planta y los valores numéricos de los parámetros, forman parte de un protocolo de simulación desarrollado como una herramienta para evaluar estrategias de PTAR [12]. Para la determinación de este modelo, se empieza realizando un balance de materia por cada componente, la cual se puede escribir de la siguiente manera:

$$\left(\begin{array}{c} \text{Variación de} \\ \text{masa} \end{array} \right) = \left(\begin{array}{c} \text{Masa que entra} \\ \text{al sistema} \end{array} \right) - \left(\begin{array}{c} \text{Masa que sale} \\ \text{del sistema} \end{array} \right) \pm \left(\begin{array}{c} \text{Masa transformada} \\ \text{dentro del sistema} \end{array} \right) \quad (2.5)$$

Este modelo consta de cinco variables de estado, con dos de ellas fácilmente medidas en línea. (S_O y S_{NH}).

$$\begin{aligned}
dx_1 &= \frac{1}{v} (S_{S_O}Q_O + S_{S_r}Q_r - (Q_O + Q_r)) + r_{S_S} \\
dx_2 &= \frac{1}{v} (X_{BH_O}Q_O + X_{BH_r}Q_r - (Q_O + Q_r)) + r_{X_{BH}} \\
dx_3 &= \frac{1}{v} (X_{BA_O}Q_O + X_{BA_r}Q_r - (Q_O + Q_r)) + r_{X_{BA}} \quad (2.6) \\
dx_4 &= \frac{1}{v} (S_{O_O}Q_O + S_{O_r}Q_r - (Q_O + Q_r)) + r_{S_O} + u_4 \\
dx_5 &= \frac{1}{v} (S_{NH_O}Q_O + S_{NH_r}Q_r - (Q_O + Q_r)) + r_{S_{NH}}
\end{aligned}$$

donde $Z_O = [S_{S_O} X_{BH_O} X_{BA_O} S_{O_O} S_{NH_O}]^T$ es un vector que representa las concentraciones de los componentes de influente, $Z_r = [S_{S_r} X_{BH_r} X_{BA_r} S_{O_r} S_{NH_r}]^T$ es el vector que representa las concentraciones de los componentes en el lazo de recirculación, Q_O representa el flujo del influente del prototipo, Q_r representa el flujo del recirculado interno, V es el volumen del reactor, u_4 es la entrada de acción de control, y ρ_i ($i = 1, 3, 4, 5$) son las ecuaciones que describen las velocidades de reacción del proceso, las cuales están dadas por:

$$\rho_1 = \gamma h \frac{S_S}{K_S + S_S} \frac{S_O}{K_{OH} + S_O} \frac{S_{NH}}{K_{NH} + S_{NH}} X_{BH} \quad (2.7)$$

$$\rho_3 = \gamma a \frac{S_{NH}}{K_{NH} + S_{NH}} \frac{S_O}{K_{OA} + S_O} X_{BA} \quad (2.8)$$

$$\rho_4 = b_H X_{BH} \quad (2.9)$$

$$\rho_5 = b_A X_{BA} \quad (2.10)$$

donde $\gamma h = 1,019$ y $\gamma a = 0,097$ son factores de las velocidades de reacción que deben ser sintonizadas. Estos parámetros han sido seleccionados de acuerdo a las funciones de sensibilidad. K_S es el coeficiente de semi-saturación en el sustrato rápidamente biodegradable, K_{OH} es el coeficiente de semi-saturación en la concentración de oxígeno disuelto para la biomasa heterotrófica, K_{NH} es el coeficiente de semi-saturación en el nitrógeno amoniacal, K_{OA} es el coeficiente de semi-saturación en la concentración de oxígeno disuelto para la biomasa autotrófica, b_H es el coeficiente de mortalidad en la biomasa heterotrófica, b_A es el coeficiente de mortalidad en la biomasa autotrófica. Finalmente, las velocidades de conversión de las ecuaciones se expresan en función de las velocidades de reacción y los coeficientes estequiométricos de todos los procesos que ocurren dentro del reactor biológico. Los coeficientes estequiométricos de una reacción son una relación entre masa consumida y masa producida de todas las especies que intervienen en dicha reacción. A continuación se muestran las ecuaciones encargadas de describir las velocidades de conversión de los procesos bioquímicos que tienen lugar en el proceso de lodos activados, de acuerdo con el modelo ASM1

$$r_{Ss} = \frac{-1}{Y_H} \rho_1 + (\rho_4 + \rho_5) \quad (2.11)$$

$$r_{XBH} = \rho_1 - \rho_4 \quad (2.12)$$

$$r_{XBA} = \rho_3 - \rho_5 \quad (2.13)$$

$$r_{So} = -\frac{(1 - Y_H)}{Y_H} \rho_1 - \frac{(4,57 - Y_A)}{Y_A} \rho_3 \quad (2.14)$$

$$r_{SNH} = -i_{XB} \rho_1 - \frac{(i_{XB} + 1)}{Y_A} \rho_3 \quad (2.15)$$

2.4. Estructura y composición del influente

Las perturbaciones están constituidas por grandes variaciones en el influente de la planta, tanto en su composición como en su flujo. Dichas perturbaciones varían enormemente en frecuencia, forma y amplitud; el principal problema que se tiene es que la mayoría de estas variaciones no son predecibles. Los eventos climatológicos como fuertes tormentas o largos periodos de lluvia afectan el influente de la planta y son algunos de los factores por lo que las perturbaciones no son predecibles, no son medibles y es muy difícil su modelado.

Para esta tesis, se describe el influente bajo dos diferentes condiciones climatológicas. Estos archivos presentan información referente a las concentraciones utilizadas en el modelo ASM1, y el flujo del influente, durante ocho días; el primer día considera que se tiene influente constante y los siete días siguientes comprenden un periodo de lluvia.







Figura 2.4: Flujo volumétrico del influente



Perturbación externa concentración de sustrato rápidamente biodegradable



Perturbación externa concentración de biomasa heterotrófica



Perturbación externa concentración de nitrógeno amoniacal

Capítulo 3

Control Difuso

En este capítulo se presentan las técnicas de control difuso que se utilizan para controlar el prototipo de tratamiento descrito en el capítulo anterior. También se presenta el diseño de las estrategias de control difuso jerárquico, que mejora el desempeño de dicho prototipo.

3.1. Bases de Control Difuso

Basado en los principios de lógica difusa [13], el control difuso ofrece la posibilidad de diseñar estrategias de control muy eficientes, sin la necesidad de un modelo matemático detallado del sistema que se quiere controlar.

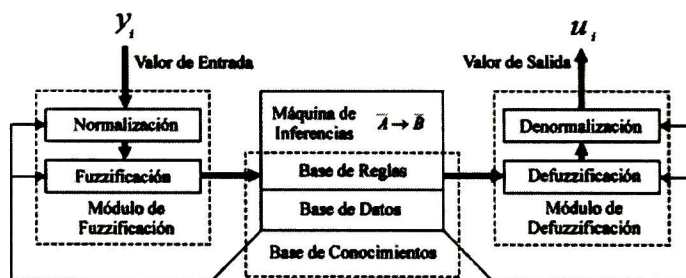


Figura 3.1: Estructura general de un controlador difuso

El diseño de la mayoría de las estrategias de control difuso se basa en la experiencia que se tiene con respecto al comportamiento del sistema, desde un punto de vista más cualitativo que cuantitativo. En la Figura 3.1 se muestra la estructura general de un controlador difuso.

El **valor de entrada** " y_i " al controlador difuso, es la información que procesa el sistema difuso para calcular el valor de la acción de control " u_i ".

El **módulo de fuzzificación** se encarga de convertir los valores numéricos de las entradas en el tipo de información que la máquina de inferencias utiliza para aplicar las reglas de control.

La **máquina de inferencias** utiliza la información difusa de la entrada que proporciona el módulo de fuzzificación, para inferir información difusa de las acciones de control. En esta etapa, la dependencia entre la entrada difusa (o antecedente) y la salida difusa (o consecuente) lo dictan un conjunto de reglas contenidas en la base de conocimientos.

El **módulo de defuzzificación** se encarga de convertir la información difusa que brinda la máquina de inferencias en valores numéricos que serán aplicados al sistema controlado.

3.1.1. Reglas, Variabes y Valores Lingüísticos

La especificación de las reglas contenidas en la base de conocimientos se realiza utilizando una descripción simbólica de las variables y de sus valores; esto se realiza mediante el empleo de **variables lingüísticas** y **valores lingüísticos** [13].

Las variables lingüísticas son una representación simbólica de las variables de entrada y salida del controlador difuso en el lenguaje natural. Denotaremos con " \bar{Y}_i " la variable lingüística que representa la variable de entrada y_i , y con " \bar{U}_i " la variable lingüística que representa la variable de salida u_i . Los valores que pueden tomar las variables lingüísticas son llamados valores lingüísticos y representan simbólicamente las características de las variables. Denotaremos con " \bar{A}_i^j " el j -ésimo valor lingüístico que puede tomar la variable lingüística de entrada \bar{Y}_i ; si esta variable lingüística puede tomar N_i valores lingüísticos entonces decimos que:

$$\bar{Y}_i = \{A_i^j : j = 1, 2, \dots, N_i\} \quad (3.1)$$

De la misma forma, denotaremos con " \bar{B}_i^j " el j -ésimo valor lingüísticos que puede tomar las variables lingüísticas de salida " \bar{U}_i ", si puede tomar M_i valores lingüísticos decimos que:

$$\bar{U}_i = \{B_i^j : j = 1, 2, \dots, M_i\} \quad (3.2)$$

La transformación entrada-salida del control difuso es caracterizado por un conjunto de reglas basada en las variables y los valores lingüísticos, cuya forma general es [13]:

$$\text{Si } \bar{Y} \text{ es } A_1^j \text{ y... } \bar{Y}_n \text{ es } A_n^j \text{ entonces } \bar{U}_i \text{ es } B_i^1 \text{ y ... } \bar{U}_m \text{ es } B_m^j \quad (3.3)$$

En este caso, el control difuso es un sistem MIMO ("multiple input, multiple output")

con " n " entradas y " m " salidas. Para que el controlador difuso quede completamente definido se necesitan " r " reglas que cubran todas las posibles combinaciones entre los distintos valores de todas las variables lingüísticas de entrada.

$$r = \prod_{i=1}^n N_i \quad (3.4)$$

3.1.2. Módulo de Fuzzificación

El conjunto de reglas contenidas en la base de conocimientos sólo es una forma cualitativa de expresar las ecuaciones de control. Para poder aplicarlas es necesario realizar una cuantificación difusa de los valores numéricos de entrada. En la forma general de las reglas (3.3) cada una de las expresiones " Y_i es A_i^j " es una proposición, que puede ser cierta o falsa de acuerdo con la lógica tradicional. Sin embargo, de acuerdo con la lógica difusa, podemos definir el "grado de certeza" de cada proposición mediante lo que llamamos **pertenencia** [13]. Por cada valor lingüístico de cada variable lingüística, tanto de entrada como de salida, necesitamos definir su pertenencia correspondiente. La pertenencia es un función que transforma el universo de discurso (la región dentro de la cual puede tomar valores numéricos la entrada o salida) al intervalo cerrado $[0,1]$; cuando toma el valor de cero, significa que la proposición correspondiente es completamente falsa y cuando toma el valor de uno, significa que es completamente cierta.

Para un valor numérico determinado " y_i " en la entrada del control difuso, el grado de certeza de la proposición " \bar{Y}_1 es A_i^j " queda determinado por la pertenencia " $\mu_{i,k}(y_i)$ ". De la misma manera, para un valor numérico determinado " u_j " en la salida del control difuso, el grado de certeza de la proposición " \bar{U}_i es B_i^r " queda determinado por la pertenencia " $\mu_{j,q}(y_i)$ ".

Los tipos de funciones de pertenencia rectilíneas más comunes pueden ser obtenidos a partir de la pertenencia " π " o trapezoidal [13]. que se muestra en la Figura 3.2




Figura 3.2: Pertenencia trapezoidal

El módulo de fuzzificación se encarga de dos tareas dentro del algoritmo de control difuso: normalización (opcional) y fuzzificación. La normalización consiste en llevar las

variables de entrada a un universo de discurso normalizado mediante el uso de ganancias estáticas u otra transformación.

Dadas las entradas y_1, y_2, \dots, y_n , la fuzzificación consiste en la evaluación de todos los valores de pertenencia correspondientes a estos valores de entrada; en otras palabras, se encuentra el grado de certeza de todas las proposiciones contenidas en los antecedentes de las reglas.

3.1.3. Máquina de inferencias

La máquina de inferencias tiene dos tareas básicas: en primer lugar, determinar la relevancia de cada una de las reglas dependiendo de la situación real caracterizada por los valores de las entradas y_i ($i = 1, 2, \dots, n$) y en segundo lugar, obtener la conclusión correspondiente de acuerdo con los consecuentes de las reglas.

La relevancia de la i -ésima regla viene dada por el nivel de pertenencia de sus antecedentes " $\mu_i(y_1, y_2, \dots, y_n)$ ". Existen varias maneras de evaluar el nivel de membresía de dos o más proposiciones; las más importantes son: el producto de los valores de pertenencia de todas las proposiciones y el valor mínimo de pertenencia de todas las proposiciones. De esta manera, el nivel de membresía del antecedente de la i -ésima regla puede ser calculado por (3.5) o por (3.6) [13].

$$\mu_i(y_1, y_2, \dots, y_n) = \mu_{1,j}(y_1) * \mu_{2,k}(y_2) * \dots * \mu_{n,1}(y_n) \quad (3.5)$$

$$\mu_i(y_1, y_2, \dots, y_n) = \min \{ \mu_{1,j}(y_1), \mu_{2,k}(y_2), \dots, \mu_{n,1}(y_n) \} \quad (3.6)$$

Existen varias maneras de calcular las implicaciones o consecuentes de las reglas; una de las más importantes y la más atractiva es la implicación de Mamdani [13]

$$A \rightarrow B \equiv A \wedge B \quad (3.7)$$

En este caso la conjunción entre el antecedente y el consecuente puede ser calculada tanto como de la fórmula (3.5), como con la fórmula del mínimo (3.6). De esta manera, el consecuente de la máquina de inferencias, mas que ser un conjunto de valores de salida, es un grupo de conjuntos difusos. Por ejemplo, si consideramos la estructura de la i -ésima regla (3.3), y calculamos la implicación de Mamdani con la fórmula del producto, las funciones de pertenencia consecuentes (una para cada variable de salida) son:

$$"m" \text{ consecuentes de la } i\text{-ésima regla} = \begin{cases} \mu_1^{C,i}(u_1) = \mu_i(y_1, y_2, \dots, y_n) * \mu_{1,r}^0(u_1) \\ \mu_m^{C,i}(u_m) = \mu_i(y_1, y_2, \dots, y_n) * \mu_{m,r}^0(u_m) \end{cases} \quad (3.8)$$

donde " $\mu_{j,r}^0(u_j)$ " es la pertenencia del valor lingüístico B_j^r que esta asociado a la variable lingüística de salida \bar{U}_j en la i -ésima regla.

En esta forma de calcular los consecuentes se considera la evaluación independiente de cada una de las reglas; existe otra alternativa [13], que no presentaremos aquí, en la que se considera la evaluación simultánea de todas las reglas y solamente se obtiene un conjunto "global" consecuente por cada salida.

3.1.4. Módulo de Defuzzificación

El módulo de defuzzificación se encarga de transformar la información generada por la máquina de inferencias en valores numéricos de salida y si es necesario desnormalizarlos para aplicarlos al sistema controlado. El método de defuzzificación depende de la manera en que se evaluaron los consecuentes de las reglas. Si se realizó la evaluación independiente de cada regla podemos utilizar el método de la suma de centros de masas [13]; de acuerdo con este método, para un sistema con "r" reglas, la manera de calcular el valor numérico de la salida es:

$$u_j^{sal} = \frac{\sum_{i=1}^r b_j^{i,q} S(\mu_j^{C,i}(u_j))}{\sum_{i=1}^r S(\mu_j^{C,i}(u_j))} \quad (3.9)$$

donde " $b_j^{i,q}$ " es el centro del área de la pertenencia del valor lingüístico B_j^q que está asociado a la variable lingüística \bar{U}_j en la i -ésima regla. La expresión $SF(\mu_j^{C,i}(u_j))$ es el área bajo la curva de la pertenencia consecuente $\mu_j^{C,i}(u_j)$.

$$b_j^{i,q} = \frac{\int \mu_j \mu_{j,q}^0(u_j) du_j}{\int \mu_{j,q}^0(u_j) du_j} \quad (3.10)$$

$$SF(\mu_j^{C,i}(u_j)) = \int \mu_j^{C,i}(u_j) du_j \quad (3.11)$$

donde $\mu_j^{C,i}(u_j)$ es la pertenencia consecuente asociada a la salida " u_j " generada por la i -ésima regla. Todas las integrales se evalúan en todo el universo de discurso correspondiente a cada variable de salida.

3.2. Sistemas Difusos Funcionales

Los sistemas difusos como el que se definió en la sección anterior, en donde los consecuentes de las reglas son proposiciones difusas, son llamados "*sistemas difusos*". Existe otro tipo de sistemas difusos llamados "*sistemas difusos funcionales*", en los cuales, los consecuentes de las reglas son funciones del tipo $b_i = g_i(\bullet)$.

3.2.1. Estructura de las Reglas

Para un sistema difuso funcional MIMO, la i -ésima regla tiene la forma

$$\text{Si } \bar{Y}_1 \text{ es } A_1^i \text{ y } \dots \text{ } \bar{Y}_n \text{ es } A_n^i \text{ entonces } u_1 = g_r(\bullet) \text{ y } \dots \text{ } u_m = g_s(\bullet) \quad (3.12)$$

Generalmente el argumento de g_q contiene elementos de las entradas del sistema, pero también puede emplearse cualquier otra variable. Usualmente todas las variables g_q son funciones lineales; sin embargo, esto no es necesario, y puede definirse cualquier función según la aplicación lo requiera. Cuando el sistema difuso funcional se define mediante el empleo de reglas de la forma

$$\text{Si } \bar{Y}_1 \text{ es } A_1^i \text{ y } \dots \text{ } \bar{Y}_n \text{ es } A_n^i \text{ entonces } u_1 = h^q \text{ y } \dots \text{ } u_m = h^s \quad (3.13)$$

donde $h_q \dots h_s$ son números reales constantes.

3.2.2. Método de Defuzzificación

Debido a que el consecuente de las reglas no es una proposición difusa, no pueden emplearse de la misma manera los métodos de defuzzificación que se emplean en los sistemas difusos convencionales. Para la defuzzificación de un sistema difuso funcional con r reglas podemos emplear la siguiente expresión:

$$u_j^{sal} = \frac{\sum_{i=1}^r g_q(\bullet) \mu(y_1, \dots, y_1)}{\sum_{i=1}^r \mu(y_1, \dots, y_1)} \quad (3.14)$$

donde " $g_q(\bullet)$ " es la función asociada a la salida u_j en la i -ésima regla.

3.3. Control Supervisor Difuso

El control supervisor difuso [13] es una estrategia de control jerárquico en donde el supervisor se encuentra en el nivel más alto. Conceptualmente, para el diseño de control supervisor difuso, se procede de la misma manera que para cualquier controlador difuso. Como lo muestra la Figura 3.3, el supervisor difuso toma información de la salida de la planta y además puede emplear conocimientos del ingeniero de control, quién conoce como sintonizar los parámetros de los controladores bajo diferentes circunstancias de la planta. También puede emplear información externa del sistema e incluso información interna adicional de la planta que no esté incluida en las salidas convencionales.




Figura 3.3: Estrategia general del controlador supervisor difuso

El control supervisor puede ser considerado como un tipo de control adaptable, debido a que observa el comportamiento actual de los lazos de control y modifica los controladores para mejorar su desempeño.

La estrategia de control supervisor difuso puede establecerse de varias maneras. La primera de ellas consiste en la actualización de los parámetros de los controladores, de acuerdo al desempeño que se ha ido obteniendo en los lazos de control y no se utiliza información adicional. En este caso, las reglas del control supervisor difuso pueden ser como la del siguiente ejemplo:

Si "Error es Grande" y "Salida es Oscilatoria" entonces "Disminuir Ganancia Integral" (3.15)

La segunda estrategia consiste en actualizar los parámetros de los controladores mediante el empleo de la información adicional y sin considerar el desempeño de los lazos de control. Suponiendo que "var" es la variable externa adicional de quien depende la adaptación, las reglas de esta estrategia puede ser de la forma mostrada en el siguiente ejemplo :

Si "Var es Grande" entonces "Ganancia Integral es Grande" (3.16)

3.4. Control PI Discreto

La salida de un controlador PI convencional en el dominio de "s" puede escribirse de la siguiente manera:

$$u(s) = \left(K_P^C + \frac{K_I^C}{s} \right) E(s) \quad (3.17)$$

donde K_P^C y K_I^C son las ganancias proporcionales e integrales respectivamente del con-

trolador, $E(s)$ es la transformada de Laplace de la señal del error. Esta ecuación puede ser transformada a su versión discreta mediante la transformación bilineal

$$s = \frac{2z - 1}{Tz + 1} \quad (3.18)$$

$$u(z) = \left(K_P^C - \frac{K_I^C T}{2} + \frac{K_I^C T}{1 - z^{-1}} \right) E(z) \quad (3.19)$$

Ahora definimos nuevas constantes de la siguiente forma

$$K_p = K_P^C - \frac{K_I^C T}{2} \quad \text{y} \quad K_I = \frac{K_I^C T}{1 - z^{-1}} \quad (3.20)$$

Entonces, tomando la transformada "z" inversa y sustituyendo las nuevas ganancias obtenidas llegamos a:

$$u(nT) - u(nT - T) = K_p [e(nT) - e(nT - T)] + K_I e(nT) \quad (3.21)$$

Ahora podemos decir que la salida del controlador PI convencional en su forma discreta queda expresada de la siguiente manera:

$$u(nT) = u(nT - T) + \Delta u(nT) \quad (3.22)$$

$$e(nT) = y(nT - T) + ref(nT) \quad (3.23)$$

$$r(nT) = e(nT) + e(nT - T) \quad (3.24)$$

$$\Delta u(nT) = K_p r(nT) + K_I e(nT) \quad (3.25)$$

donde "T" es el periodo de muestreo, "n" es un entero que representa el número de muestra, "y(nT)" es la variable controlada, "ref(nT)" es la referencia de la variable controlada y "e(nT)" es el error de la variable controlada y "r(nT)" es la razón de cambio del error.

3.5. La Técnica L/A

La técnica L/A se tomó de [14] y [15]. En [4] se muestra que esta técnica es la mejor estrategia para controlar oxígeno disuelto en plantas aeróbicas de tratamiento de aguas residuales. Las principales ventajas en la utilización de un controlador con la técnica L/A son las siguientes:

Considera las restricciones de valores positivos, tanto para las variables de estado como para las acciones de control dentro del proceso.

- No es necesario considerar las ecuaciones del modelo del proceso para diseñar la ley de control.
- Presenta una estructura muy sencilla para la implementación.

La técnica L/A, como lo muestra la Figura 3.4, consiste en llevar las variables de entrada del controlador que se encuentran en un espacio de trabajo con restricción positiva, a un espacio de trabajo sin esta restricción mediante una transformación logarítmica; posteriormente, la señal de control que se obtiene en un espacio de trabajo sin restricción positiva es regresada al espacio de trabajo con restricciones mediante una transformación exponencial. Para mayores detalles ver [14].




Figura 3.4: Principio de la técnica L/A

De esta forma, las transformaciones que utiliza la técnica L/A son las siguientes:

$$Y(t) = \ln(y(t)) \quad (3.26)$$

$$R(t) = \ln(ref(t)) \quad (3.27)$$

$$u(t) = \exp(U(t)) \quad (3.28)$$

En el bloque de "controlador normal", se utiliza un controlador PI discreto como el que se muestra en (3.19), que con las variables en el espacio de trabajo sin restricción positiva queda de la siguiente manera:

$$U(nT) = U(nT - T) + K_p[E(nT) - E(nT - T)] + K_I E(nT) \quad (3.29)$$

donde

$$E(nT) = R(nT) - Y(nT) \quad (3.30)$$

Al sustituir las transformaciones (3.26), (3.27) y (3.28) en (3.29) y considerando que la referencia $ref(t)$ puede ser variable en el tiempo, llegamos a:

$$u(nT) = u(nT - T) \left(\frac{ref(nT)}{y(nT)} \frac{y(nT - T)}{ref(nT - T)} \right)^{K_P} \left(\frac{ref(nT)}{y(nT)} \right)^{K_I} \quad (3.31)$$

A esta estructura de control le llamaremos el controlador PI L/A

Capítulo 4

Estimación Neuronal de Estados

En este capítulo se presenta la identificación de un prototipo de tratamiento de agua; posteriormente se describe el observador neuronal para estimar las concentraciones de sustrato y biomasa utilizando únicamente oxígeno disuelto como variable medible. Ambos, identificador y observador neuronal, están basados en una red neuronal recurrente de alto orden (RHONN). El aprendizaje para la red neuronal es implementado usando un filtro de Kalman extendido (FKE).

Usualmente, los sistemas de control requieren el conocimiento del sistema a controlar; tal conocimiento debe presentarse en término de ecuaciones diferenciales o a diferencias. Básicamente hay dos maneras de obtener un modelo: 1) puede ser obtenido de manera deductiva utilizando leyes físicas, o 2) puede ser inferido de un conjunto de datos obtenidos de manera experimental. El primer método puede ser simple, pero en la mayoría de los casos consume mucho tiempo, y en ocasiones es prácticamente imposible deducir un modelo correcto de esta manera. El segundo, conocido como identificación de sistemas, puede ser de gran ayuda, consume poco tiempo y requiere esfuerzo relativamente menor.

La identificación de sistemas es el hecho de inferir una descripción matemática de un sistema dinámico a partir de una serie de mediciones [16]. Puede haber varios motivos para establecer la descripción matemática de sistemas dinámicos. Aplicaciones típicas abarcan simulación, predicción, detección de error y diseño de sistemas de control. Si el peso asociado con construir un modelo usando leyes físicas, químicas, económicas, etc., es considerado abrumador, las técnicas de identificación de sistemas son naturalmente de particular interés.

Una herramienta útil para la identificación de sistemas no lineales son las redes neuronales por sus inherentes características de adaptabilidad y aproximación de funciones.

4.1. Redes Neuronales

Las redes neuronales artificiales son modelos simplificados de las redes neuronales biológicas. Tratan de extraer las excelentes capacidades del cerebro para resolver ciertos problemas complejos, como: visión, reconocimiento de patrones o control moto-sensorial. Una red neuronal artificial, también llamada neuro-computadora, es un procesador paralelo distribuido y masivamente interconectado que almacena conocimiento experimental [17]. Las redes neuronales artificiales presentan las siguientes características:

- El conocimiento es adquirido experimentalmente
- Los pesos (ganancias) de interconexión (sinapsis) varían constantemente.

Las redes neuronales artificiales ofrecen ventajas como:

- **No linealidad.** El procesador neuronal es básicamente no lineal y por consecuencia, la red neuronal también.
- **Adaptabilidad.** La red tiene la capacidad de adaptar sus parámetros, aun en tiempo real.
- **Tolerancia a fallas.** Debido a la interconexión masiva, la falla de un procesador no altera seriamente la operación.
- **Uniformidad en el análisis y diseño.** Esto permite garantizar características precisas.
- **Analogía con las redes biológicas.** Esto permite la utilización mutua del conocimiento de las dos áreas.

Una de las estructuras de redes neuronales más útiles son las redes neuronales recurrentes, las cuales contienen por lo menos un lazo de retroalimentación, es decir, es un sistema dinámico. Por esta razón la estructura recurrente tiene un gran impacto en la capacidad de aprendizaje y en el funcionamiento de la red neuronal. El uso de redes neuronales permite desarrollar algoritmos de control robustos a incertidumbres y errores de modelado.

Las RHONN son una generalización de la redes Hopfield de primer orden. Este tipo de redes posee características tales como:

Modelado eficiente de sistemas dinámicos complejos.

- Fácil implementación.
- Estructura relativamente simple.
- Capacidad de ajustar sus parámetros en línea.

De igual manera, las RHONN discretas poseen las mismas características que las RHONN continuas y son ideales para su uso en modelado, identificación y control de sistemas dinámicos discretos complejos

4.2. Aproximación por una Red Neuronal Discreta de Alto Orden.

Consideremos un sistema MIMO no lineal

$$x_i(k+1) = F(x(k), u(k)) \quad (4.1)$$

donde $x \in \mathbb{R}^n$, $u \in \mathbb{R}^m$ y $F \in \mathbb{R}^n \times \mathbb{R}^m \rightarrow \mathbb{R}^n$ es una función no lineal.

Sea una red neuronal de alto orden discreta:

$$\hat{x}_i(k+1) = w_i^T z_i(x(k), u(k)), i = 1, \dots, n \quad (4.2)$$

donde x_i ($i = 1, 2, \dots, n$) es el estado de la i -ésima neurona, L_i es el respectivo número de conexiones de alto orden, n es el orden de estado, $\{I_1, I_2, \dots, I_{L_i}\}$ es la colección de subconjuntos de $\{1, 2, \dots, n\}$, w_i ($1, 2, \dots, n$) es el respectivo vector de adaptación de pesos en línea, y $z_i(x(k), u(k))$ está dado por:

$$z_i(x(k), u(k)) = \begin{bmatrix} z_{i_1} \\ z_{i_2} \\ \vdots \\ z_{i_{L_i}} \end{bmatrix} = \begin{bmatrix} \prod_{j \in I_1} y_i^{d_{ij}(1)} \\ \prod_{j \in I_2} y_i^{d_{ij}(2)} \\ \vdots \\ \prod_{j \in I_{L_i}} y_i^{d_{ij}(L_i)} \end{bmatrix} \quad (4.3)$$

donde $d_{ij}(k)$ son enteros no negativos y y_i es definido como:

$$y_i = \begin{bmatrix} y_{i_1} \\ \vdots \\ y_{i_n} \\ y_{i_{n+1}} \\ \vdots \\ y_{i_{n+m}} \end{bmatrix} = \begin{bmatrix} S(x_1) \\ \vdots \\ S(x_n) \\ u_1 \\ \vdots \\ u_m \end{bmatrix} \quad (4.4)$$

En (4.4), $u = [u_1, u_2, \dots, u_m]^T$ es el vector de entrada a la red neuronal (NN), β es la pendiente de la función y $S(\bullet)$ es definida por:

$$S(x) = \frac{1}{1 + \exp(-\beta x)} \quad (4.5)$$

Se considera ahora el problema de aproximar el sistema no lineal (4.1), por la siguiente red neuronal recurrente de alto orden discreta[18]:

$$x_i(k+1) = w_i^{*T} z_i(x(k), u(k)) + \epsilon_{zi}, i = 1, \dots, n \quad (4.6)$$

donde x_i es el i -ésimo estado de la planta, ϵ_z es el error de aproximación, el cual puede ser reducido, incrementando el número de pesos. Se supone que existe un vector de pesos ideal w_i^* tal que $\|\epsilon_z\|$ puede ser minimizado en un conjunto compacto $\Omega_{zi} \subset \mathcal{R}^{L_i}$ [19]. En general, se supone que existe un vector y es constante pero desconocido, ver [20] para mayor información. Si definimos la estimación de w^* como w_i , el error de estimación es

$$w_i(k) = w_i^* - w_i(k) \quad (4.7)$$

4.3. El Filtro de Kalman Extendido como Algoritmo de Entrenamiento

El filtro de Kalman es un conjunto de ecuaciones matemáticas que prevee una solución recursiva para estimar los estados de un sistema lineal perturbado con ruido aditivo en la salida [21]. Para el entrenamiento basado en el filtro de Kalman, los pesos de la red se vuelven los estados a estimar. En este caso, el error entre la salida de la red neuronal y la salida de la planta medible puede ser considerado como ruido blanco. Puesto que la red neuronal constituye una transformación no lineal, entonces un filtro de Kalman extendido (*FKE*) es requerido.

El objetivo del entrenamiento es encontrar los pesos óptimos que minimicen el error de predicción. En este trabajo, usamos un FKE como algoritmo de entrenamiento, dado por:

$$\begin{aligned} w_i(k+1) &= w_i(k) + \eta_i K_i(k) e(k) \\ K_i(k) &= P_i(k) H_i(k) M_i(k) \quad i = 1, \dots, n \\ P_i(k+1) &= P_i(k) - K_i(k) H_i^T(k) P_i(k) + Q_i(k) \end{aligned} \quad (4.8)$$

donde

$$\begin{aligned} M_i(k) &= [R_i(k) + H_i^T(k) P_i(k) H_i(k)]^{-1} \\ e(k) &= y(k) - \hat{y}(k) \end{aligned} \quad (4.9)$$

con $e(k) \in \mathcal{R}^p$ el error de observación y $P_i(k) \in \mathcal{R}^{L_i \times L_i}$ la matriz de covarianza en el paso k , $w_i \in \mathcal{R}^{L_i}$ el vector de pesos, L_i es el respectivo número de pesos en la red

neuronal, $y \in \mathbb{R}^p$ es la salida de la planta, $y \in \mathbb{R}^p$ es la salida neuronal, n es el número de estados, $K_i \in \mathbb{R}^{L_i \times p}$ es la matriz de ganancia de Kalman, $Q_i \in \mathbb{R}^{L_i \times L_i}$ es la matriz de covarianza del ruido del proceso, $R_i \in \mathbb{R}^{p \times p}$ es la matriz de covarianza del ruido de medición, y $H_i \in \mathbb{R}^{L_i \times p}$ es la matriz de medición, donde cada entrada (H_{ij}) es la derivada de la i -ésima salida de la red neuronal con respecto al j -ésimo peso de la red neuronal, (w_{ij}), la cual está dada de la siguiente forma:

$$H_{ij}(k) = \left[\frac{\partial \widehat{y}(k)}{\partial w_{ij}(k)} \right]^T \quad (4.10)$$

donde $i = 1, \dots, n$ y $j = 1, \dots, L_i$. Usualmente P_i y Q_i son inicializadas como matrices diagonales, con entradas $P_i(0)$ y $Q_i(0)$, respectivamente. Es importante remarcar que $H_i(k)$, $K_i(k)$ y $P_i(k)$ para el FKE son acotadas; para mayores detalles, el lector puede consultar [21].

4.4. Identificación del Prototipo de Tratamiento de Aguas Residuales

El esquema de identificación presentado en la sección anterior, se aplica ahora al prototipo de tratamiento de aguas residuales, considerando como medibles los estados. Se realiza la identificación en el bioreactor el cual queda representado por el sistemas de ecuaciones (2.6), es decir de 5 variables de estado, y para ello utilizamos una red neuronal recurrente de alto orden con $n = 5$. La red neuronal utilizada, está dada por:

$$x_1(k+1) = w_{11}S^4(x_1) + w_{12}S^4(x_1)S(x_2)S(x_4) + w_{13}d_1$$

$$x_2(k+1) = w_{21}S^5(x_2) + w_{22}S^3(x_4)S^3(x_2)S(x_1) + w_{23}S(x_2) + w_{24}d_2$$

$$x_3(k+1) = w_{31}S^3(x_3) + w_{32}S(x_4)S(x_2) + w_{33}S(x_3) + w_{34}d_3$$

$$x_4(k+1) = w_{41}S^4(x_1)S(x_2)S(x_4) + w_{42}S(x_5)S^2(x_2)S^4(x_4) + w_{43}u_4$$

$$x_5(k+1) = w_{51}S^4(x_5) + w_{52}S(x_2)S^3(x_1) + w_{53}S(x_3) + w_{54}d_5$$

El entrenamiento es realizado en línea, usando una configuración en serie-paralelo. Todos los estados de la red son inicializados aleatoriamente. Las matrices de covarianza son inicializados aleatoriamente como matrices diagonales: $P_i(0) = 60000$, $Q_i(0) = 2500$ y $R_i(0) = 4400$, ($i = 1, 2, 3$), respectivamente.

Se observa en la Figura 4.1 como la identificación es extremadamente efectiva, ya que converge inmediatamente a los estado de la planta; aunque se introdujeron perturbaciones

en la misma, la estimación de los estados sigue siendo eficaz. Así, una vez que la RHONN ha aprendido la dinámica del proceso es robusta ante cambios y perturbaciones que se puedan presentar en el proceso.




Figura 4.1: Variables de estado (línea continua) y su respectiva identificación (línea punteada).

4.5. Observador Neuronal Discreto

Para llevar a cabo la identificación del prototipo, se supone que tenemos acceso completo a los estados, pero en la mayoría de los casos esto no es posible. Por esta razón, resolver el

problema de estimación de estados en sistemas no lineales es de gran importancia [22]. La mayoría de los observadores propuestos necesitan una transformación especial [23]. Otra clase de observadores son aquellos llamados robustos, los cuales tienen buen desempeño bajo incertidumbres, pero su diseño es muy complejo y sujeto a varias restricciones [24]. El principal problema de estos observadores es que necesitan el conocimiento previo de la planta. Recientemente se han desarrollado observadores neuronales [25], [26], [27], los cuales no necesitan de dicho conocimiento.

En esta sección se presenta el observador neuronal propuesto en [20]. Consideremos el estado de un sistema no lineal discreto, el cual se supone observable, y dado por

$$\begin{aligned}x(k+1) &= F(x(k), u(k)) + d(k) \\y(k) &= Cx(k)\end{aligned}\tag{4.11}$$

donde $x \in \mathfrak{R}^n$ es el vector de estado del sistema, $u \in \mathfrak{R}^m$ es el vector de entrada, $y(k) \in \mathfrak{R}^P$ es el vector de salida, $C \in \mathfrak{R}^{P \times n}$ es conocida como la matriz de salida, $d(k) \in \mathfrak{R}^n$ es el vector de perturbación y $F(\bullet)$ es un campo vector suave, $F_i(\bullet)$ sus entradas; por lo tanto, (4.11) puede escribirse como:

$$\begin{aligned}x(k+1) &= [x_1(k) \dots x_i(k) \dots x_n(k)]^T \\d(k) &= [d_1(k) \dots d_i(k) \dots d_n(k)]^T \\x_i(k+1) &= F_i(x(k), u(k)) + d_i(k), \quad i = 1, \dots, n \\y(k) &= Cx(k)\end{aligned}\tag{4.12}$$

Para el sistema (4.12), el observador neuronal recurrente de alto orden tipo Luenberger es propuesto en [20], con la siguiente estructura:

$$\begin{aligned}\hat{x}(k) &= [\hat{x}_1(k) \dots \hat{x}_i(k) \dots \hat{x}_n(k)]^T \\x_i(k+1) &= w_i^T z_i(\hat{x}_i(k), u(k)) + L_i e(k) \\ \hat{y}(k) &= C\hat{x}(k), \quad i = 1, \dots, n\end{aligned}\tag{4.13}$$

con $L_i \in \mathfrak{R}^P$ w_i y z_i como en (4.2); el vector de los pesos son actualizados en línea con un FKE desacoplado (4.7-4.9). El error de salida es definido por

$$e(k) = y(k) - \hat{y}(k)\tag{4.14}$$

y el error de estimación está dado por

$$\tilde{x}(k) = x(k) - \hat{x}(k)\tag{4.15}$$

El error de estimación es semiglobalmente últimamente acotado como se muestra en el Teorema 4.1, entonces la dinámica de (4.15) puede expresarse como

$$\begin{aligned}\tilde{x}(k+1) &= x_i(k+1) - \hat{x}_i(k+1) \\ \tilde{x}(k+1) &= w_i^{*T} z_i(x(k), u(k)) + \epsilon + d_i(k) - w_i^T z_i(\hat{x}_i(k), u(k)) - L_i e(k) \quad (4.16) \\ \tilde{x}(k+1) &= w_i z_i(\hat{x}_i(k), u(k)) + \epsilon + d_i(k) - L_i e(k)\end{aligned}$$

Teorema 4.1 Para el sistema (4.12), el observador neuronal recurrente de alto orden (4.13), entrenado con el FKE, asegura que el error de estimación (4.15), y el error de salida son semiglobalmente últimamente acotados; además los pesos son acotados. Para detalles de prueba ver [20].

Prueba. Ver Apéndice A. ■

4.6. Aplicación del Observador Neuronal Discreto a un Prototipo de Tratamiento de Aguas

El observador neuronal (4.2) presentado en la sección anterior se aplica al prototipo de tratamiento de aguas residuales, cuya dinámica se considera desconocida. Debido a que sólo se mide la concentración de oxígeno disuelto en el bioreactor, se estiman únicamente los estados relacionados directamente con esta medición y de interés para este trabajo, que son las concentraciones de sustrato rápidamente biodegradable, la biomasa heterotrófica y el nitrógeno amoniacal, considerándose las otras dinámicas como perturbaciones debido a la carencia de mediciones en línea. Para ello se utilizará el observador neuronal recurrente de alto orden (4.13) con $n = 3$, el cual es entrenado en línea usando una configuración en paralelo.

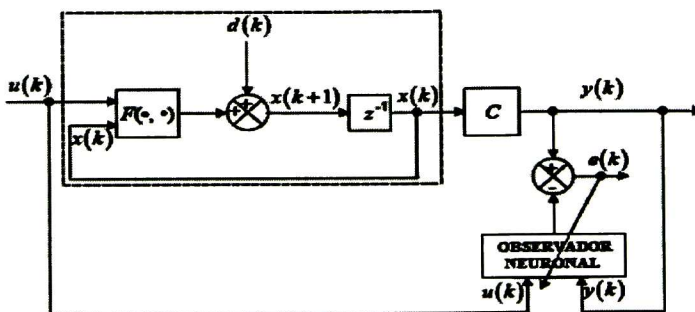


Figura 4.2: Esquema del observador

La red neuronal usada para el observador está dada por:

$$\begin{aligned}
 \hat{x}_1(k+1) &= w_{11}S(\hat{x}_1) + w_{12}S(\hat{x}_1)^2 S(\hat{x}_2) + w_{13}S(\hat{x}_2) + w_{14}S(\hat{x}_3) + w_{15}S(d_1) \\
 \hat{x}_2(k+1) &= w_{21}S(\hat{x}_2) + w_{22}S(\hat{x}_1) S(\hat{x}_2) + w_{23}S(\hat{x}_2) S(\hat{x}_3) + w_{24}S(u_2) \\
 \hat{x}_3(k+1) &= w_{31}S(\hat{x}_1) + w_{32}S(\hat{x}_2) + w_{33}S(\hat{x}_3) + w_{34}S(\hat{x}_2) S(\hat{x}_5) + w_{35}u_3 \\
 \hat{y} &= \hat{x}_3
 \end{aligned}$$

Para el esquema del observador, \hat{x}_1 , \hat{x}_2 y \hat{x}_3 son las estimaciones de sustrato rápidamente biodegradable (S_S), biomasa heterotrófica (X_{BH}) y oxígeno disuelto (S_O), respectivamente. La entrada d_1 es el flujo volumétrico del influente Q_0 el cual es medible pero no manipulable, u_2 es la velocidad del flujo de recirculación Q_r y u_3 es la acción de control del oxígeno disuelto en el reactor. Todos los estados de la red son inicializados aleatoriamente. Las matrices relacionadas a la covarianza del error son inicializados como diagonales, con elementos diferentes de ceros como $P_i(0) = 800000$, $Q_i(0) = 500$ y $R_i(0) = 4400$, ($i = 1, 2, 3$), respectivamente. Adicionalmente la matriz H, es inicializada como $H(0)=0$, ya que se supone que las salidas de la red neuronal no dependen directamente del vector de estados. El termino de Luenberger es $L = [4, 1, ,1]$, estos valores fueron determinados por prueba y error.

Este observador es diseñado para trabajar bajo condiciones de operación constante durante un periodo de ocho días. En las Figuras 4.3 y 4.4, es posible verificar que para estos ocho días, la estimación es eficiente.

Se debe tomar en cuenta que el flujo volumétrico Q_0 no se puede controlar, ya que está determinado por la cantidad de agua que llega a la planta. Además las concentraciones de los componentes del influente no son medibles y por lo tanto se consideran como perturbaciones externas; a pesar de esto, el observador es capaz de estimar las variables de estado.

En la Figura 4.5, se puede ver que existe convergencia muy eficaz para el estado S_O como era de esperarse, debido a que es el estado medible; mientras que para las otras variables de estados, las estimaciones obtenida son aceptables.




Figura 4.3: Sustrato rápidamente biodegradable (línea continua) y su respectiva estimación (línea punteada).




Figura 4.4: Biomasa heterotrófica (línea continua) y su respectiva estimación)




Figura 4.5: Concentración de oxígeno disuelto(línea continua) y su respectiva estimación (línea punteada).

Capítulo 5

Control Inteligente Híbrido para el Prototipo de Tratamiento de Aguas Residuales

En este capítulo se propone una estructura de control inteligente híbrido para un prototipo de tratamiento de aguas residuales que usan lodos activados. Dicha estructura está compuesta por el control difuso explicado en el capítulo 3 y el identificador neuronal cuyo desarrollo se explicó en el capítulo anterior. Además se muestra el control de oxígeno disuelto utilizado en el prototipo de tratamiento de aguas.

5.1. Diseño del Control Inteligente Híbrido

Se conoce como control inteligente híbrido a la combinación de estrategias de control clásico y/o moderno con técnicas de inteligencia computacional como: redes neuronales, lógica difusa y/o sistemas evolutivos [28]. Esta definición también incluye a la combinación de sólo las últimas técnicas mencionadas.

En esta sección, proponemos el desarrollo de un control inteligente híbrido para el prototipo de tratamiento de aguas residuales descrito en el capítulo dos. Para esta estrategia, se necesita conocer el sustrato rápidamente biodegradable y la biomasa heterotrófica, los cuales serán estimados por el identificador neuronal propuesto en el capítulo anterior. La estrategia de control difuso se basa en el siguiente razonamiento: si hay una gran concentración de biomasa, entonces los sólidos suspendidos se incrementan; si la concentración de biomasa es baja y la concentración de sustrato es elevada, entonces los contaminantes del efluente no pueden ser degradados. Ambos casos degradan la calidad del agua tratada; por estas razones, se propone mantener constante la relación RT [29], la cual se describe a continuación:

$$RT = \frac{\widehat{X}_{BH}c}{S_S} \quad (5.1)$$

El esquema de control inteligente híbrido que se propone se basa en la regulación RT , donde c es 10^{-3} , usando el esquema mostrado en la Figura 5.1. En él, se utiliza un PI-LA para controlar la concentración de oxígeno disuelto S_O utilizando como variable manipulable kla (constante de aireación).

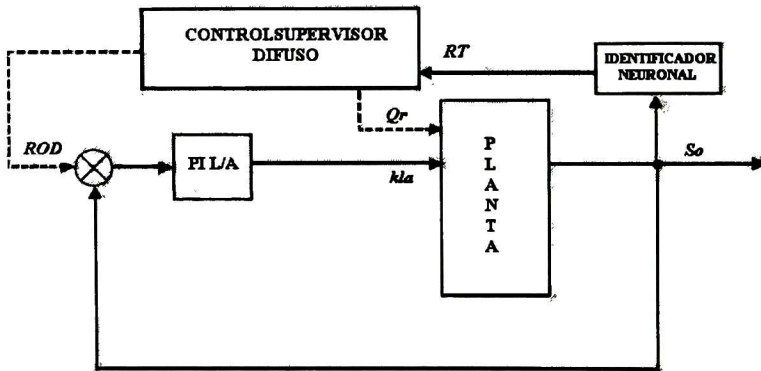


Figura 5.1: Esquema de Control Inteligente Híbrido

El supervisor difuso de la concentración de oxígeno disuelto tiene por objetivo variar la referencia, que originalmente es de $2 \text{ gr}/\text{m}^3$, dependiendo de la cantidad necesaria y cuidando de mantener dicha referencia dentro de los límites que garanticen un crecimiento adecuado de biomasa. Se considera que la cantidad necesaria de oxígeno disuelto depende de la relación RT en el bioreactor; así a mayor valor de RT en el bioreactor, mayor es la referencia de oxígeno disuelto para el bioreactor. Esta consideración obedece al siguiente hecho: si se tiene alta la relación RT , entonces hay una alta concentración de biomasa heterotrófica en el bioreactor, y significa que necesita menor cantidad Q_r y de oxígeno disuelto, para no favorecer el crecimiento de biomasa. En caso contrario, cuando se tiene una baja relación RT , la concentración de biomasa heterotrófica en el bioreactor es baja también, y por ello se necesita incrementar la cantidad de Q_r y oxígeno disuelto para incrementar la población de biomasa.

Los límites máximo y mínimo en la referencia de la concentración de oxígeno disuelto son obtenidos analizando la forma en la que dependen las velocidades de crecimiento de biomasa en función de la concentración de oxígeno disuelto. La Figura 5.2 muestra dicha dependencia.

$$\rho_1(S_O) = \frac{S_O}{K_{OH} + S_O}$$




Figura 5.2: Dependencia de las velocidades de crecimiento de biomasa con respecto a la concentración de oxígeno disuelto.

Por debajo de $0.5 \text{ gr}/m^3$ se observa que la velocidad de reacción comienza a disminuir muy rápidamente; por lo tanto el límite inferior de la referencia será $ROD_{min} = 0.5 \text{ gr}/m^3$ se nota que por encima de $2.5 \text{ gr}/m^3$ el incremento en la concentración de oxígeno disuelto prácticamente no aumenta la velocidad de crecimiento; así que el límite máximo en la concentración de oxígeno disuelto será $ROD_{max} = 2.5 \text{ gr}/m^3$

La variable de entrada de este supervisor difuso es RT ; se define entonces la variable lingüística de entrada RT

$$\overline{RT} = \{baja, mediana, alta\} \quad (5.2)$$

Las funciones de pertenencia de los valores lingüísticos se muestra en la Figura 5.3




Figura 5.3: Funciones de membresía de entrada

En este trabajo los límites de los conjuntos difusos fueron obtenidos por conocimiento empírico.

Junto con la variación de oxígeno disuelto es necesario variar el flujo de recirculación que afecta directamente la concentración de la biomasa heteretrófica. El razonamiento es el siguiente: si la relacion RT es alta, entonces se debe de disminuir el flujo de recirculación para reducir la concentración de biomasa heterotrófica; por otro lado, si la relación RT es baja, es necesario aumentar el flujo de recirculación para aumentar la concentración de biomasa heterotrófica y tratar de mantener la relación RT constante, aun en presencia de perturbaciones. Las reglas difusas son las siguientes:

- Si RT es baja entonces $Q_r = Q_{rI1}$ y $R_{OD} = R_{I1}$
- Si RT es media entonces $Q_r = Q_{rI2}$ y $R_{OD} = R_{I2}$
- Si RT es alta entonces $Q_r = Q_{rI3}$ y $R_{OD} = R_{I3}$

Los valores de estos parámetros fueron encontrados a prueba y error, como sigue:

$$\begin{array}{ll}
 Q_{rI1} = 8000 \text{ m}^3/\text{día} & R_{I1} = 1,5\text{gr}/\text{m}^3 \\
 Q_{rI2} = 18000 \text{ m}^3/\text{día} & R_{I2} = 2,0\text{gr}/\text{m}^3 \\
 Q_{rI3} = 35000 \text{ m}^3/\text{día} & R_{I3} = 2,5\text{gr}/\text{m}^3
 \end{array}$$

5.2. Aplicación del Control Inteligente Híbrido

En esta sección se presentan los resultados del esquema del controlador inteligente híbrido aplicado al prototipo de tratamiento de aguas residuales.




Figura 5.4: Regulación RT , considerando las variables de la planta (línea continua) y RT utilizando las estimaciones del indentificador (línea punteada).

Se puede observar en la Figura 5.4 que el desempeño del controlador inteligente durante las condiciones de operación constante es muy bueno, y es capaz de mantener a RT en su región de operación, la cual es alrededor de 3. Este valor fue encontrado experimentalmente para garantizar la calidad del efluente. Sin embargo, cuando aparece la perturbación ocasionada por la lluvia (primer día), el controlador sólo es capaz de mantener RT cerca del punto deseado; esto se debe a que la perturbación del influente es muy grande y satura los controladores como se muestra en las Figuras 5.5 y 5.6. Esto se puede solucionar colocando un tanque homogenizador al inicio del prototipo, para que uniformice la concentración. También se puede observar como el desempeño del identificador no afecta prácticamente al desempeño del controlador, ya que la diferencia de RT entre la que se obtiene considerando la planta (línea continua) y el identificador (línea punteada) es prácticamente la misma.




Figura 5.5: Acción de control de la constante de aireación





Figura 5.6: Acción de control del flujo de recirculación

A continuación, se muestra el desempeño del identificador neuronal bajo las acciones del control inteligente.



Se observa como la identificación del sustrato rápidamente biodegradable, la biomasa heterotrófica y oxígeno disuelto respectivamente es muy buena durante la perturbación constante y aún en presencia de perturbaciones variables en el tiempo. Para la estimación de oxígeno disuelto, como era de esperarse ya que es la variable medible, no existe problema para identificar su respectivo estado en diferentes escenarios de perturbación.

5.3. Técnicas de Control Propuestas para el Prototipo de Tratamiento de Aguas Residuales

Para este prototipo de tratamiento se propone un PI-L/A para controlar oxígeno disuelto, basado en los buenos resultados en [4].

El control de oxígeno disuelto es el lazo de control más importante dentro del proceso de lodos activados. La concentración de oxígeno disuelto tiene repercusiones importantes en la calidad del efluente (debido a que de ella dependen las velocidades de crecimiento de los microorganismos). La manera de controlar la concentración de oxígeno disuelto es mediante la manipulación de la constante de aireación (kla).

Para la elección del valor de referencia de oxígeno, se debe tomar en cuenta que altas concentraciones de oxígeno disuelto favorecen la velocidad de consumos de substratos y nitrógeno amoniacal; por otro lado, bajas concentraciones de oxígeno disuelto incrementan la velocidad de eliminación de nitratos y nitritos (denitrificación).

El algoritmo de control utilizado para controlar la concentración de oxígeno disuelto es un controlador PI-LA explicado en el capítulo 3. En [4] se muestra que esta técnica es la mejor estrategia para controlar la concentración de oxígeno disuelto en plantas de tratamiento de aguas.

Para evaluar el comportamiento del controlador diseñado se proponen las siguientes condiciones de simulación:

- Referencia normal: 2 gr/m³
- Rango de la variable manipulada: 0 a 240 días⁻¹




Figura 5.7: Concentración de oxígeno disuelto con el controlador PI -LA




Figura 5.8: Constante de aireación

En las Figuras 5.7 y 5.8 se muestra el control de la concentración de oxígeno disuelto con el controlador PI-LA y su respectiva señal de control. Se puede ver que el desempeño del control es satisfactorio, aún cuando se introducen perturbaciones el control de oxígeno disuelto continúa siendo aceptable.

Capítulo 6

Conclusiones

En esta tesis se presentó un identificador neuronal de alto orden discreto para identificar sustrato rápidamente biodegradable, biomasa heterotrófica, biomasa autotrófica, oxígeno disuelto y nitrógeno amoniacal. También se presentó un observador neuronal de alto orden discreto para estimar sustrato rápidamente biodegradable, biomasa heterotrófica utilizando como variable medible el oxígeno disuelto. Ambos son entrenados con el filtro de Kalman extendido. Además se plantea el diseño de un controlador inteligente híbrido para asegurar la buena calidad del efluente.

Se realizó la identificación de un prototipo de tratamiento de aguas residuales basada en una red neuronal recurrente de alto orden, la cual presenta un excelente desempeño a nivel simulación, a pesar de perturbaciones variables. Después se prosiguió a realizar un observador neuronal tipo Luenberger, el cual también da buenos resultados, en condiciones de operación constantes.

Después de esto, se prosiguió a diseñar un control inteligente híbrido basado en las estimaciones del identificador, cuya función es regular la proporción de biomasa/sustrato. El control inteligente híbrido propuesto se encarga de variar la referencia de control de oxígeno disuelto y variar la velocidad de flujo del recirculado externo; emplea como variable de entrada la relación de biomasa/sustrato. La implementación del controlador mejoró la calidad del efluente.

Para el prototipo de tratamiento de aguas, se simula el desempeño de un lazo de control; el control de oxígeno disuelto utilizando la técnica de control: PI-L/A. Para este lazo se presenta un excelente desempeño. Se puede concluir que el identificador neuronal propuesto es una buena herramienta para identificar las concentraciones de sustrato, biomasa y nitrógeno amoniacal.

Como trabajo a futuro se propone el desarrollo del observador neuronal bajo perturbaciones variables y la implementación en tiempo real tanto del observador neuronal, como las técnicas de control antes mencionadas.

Glosario

Biodegradable: propiedad que tienen algunos materiales complejos de ser consumidos por microorganismos.

Biomasa autotrófica: microorganismos que requieren bióxido de carbono (compuesto inorgánico), como principal fuente de carbono para su reproducción y crecimiento.

Biomasa heterotrófica: microorganismos que requieren compuestos orgánicos como su principal fuente de carbono para su reproducción y crecimiento.

Coefficiente estequiométrico: número que expresa la proporción exacta de materia que se consume o produce de cada compuesto, que interviene en una determinada reacción.

Crecimiento Aeróbico: crecimiento de microorganismos en presencia de oxígeno disuelto.

Crecimiento Anóxico: crecimiento de microorganismos en el cual se utilizan nitratos, sulfatos o carbonatos para sustituir el oxígeno disuelto en ausencia de éste.

Demanda bioquímica de oxígeno: medida de la cantidad de oxígeno utilizado por los microorganismos en la estabilización de la materia orgánica biodegradable, bajo condiciones aeróbicas, en un periodo de 5 días y a 20 °C.

Demanda química de oxígeno: representa el contenido orgánico total de una muestra líquida. Su determinación es una medida de la cantidad de oxígeno consumido por la porción de materia orgánica existente en la muestra y oxidable por un agente químico fuerte.

Denitrificación: producción de gas nitrógeno, por el consumo de nitratos bajo condiciones de ausencia de oxígeno disuelto en el crecimiento anóxico de microorganismos.

Nitrificación: oxidación del nitrógeno amoniacal para producir nitratos y nitritos durante el crecimiento aeróbico de microorganismos.

Reactor biológico: cualquier recipiente donde se llevan a cabo reacciones biológicas por el crecimiento y reproducción de microorganismos.

Sedimentación: proceso físico de separación entre partículas sólidas y el medio líquido que las contiene, únicamente por la acción de las fuerzas gravitatorias.

Sustrato: materia orgánica.

Velocidad de conversión: velocidad con la que un determinado compuesto es consumido o producido por la acción de una o varias reacciones, por unidad de volumen del reactor.

Velocidad de reacción: velocidad con la que se lleva a cabo una determinada reacción, por unidad de volumen del reactor donde se efectúa.

Bibliografía

- [1] Conagua, *Estadística del Agua en México 2008*, Talleres Gráficos de México, México D.F., México, 2008.
- [2] G. Olsson and B. Newell, *Wastewater Treatment Systems, Diagnosis and Control*, IWA Publishing, London, England, 1999.
- [3] R. M. Tong, M. Beck, and A. Latten, "Fuzzy control of activated sludge wastewater treatment process", *Automatica*, Vol. 16, 1980.
- [4] G. Vera, E. N. Sanchez, J. F. Bêteau and C. Cadet, "Intelligent Control of an Activated Sludge Wastewater Treatment Plant", *American Control Conference ACC03*, Denver, USA, June 2003.
- [5] M. Hamed, M. G. Khalafallah, E. A. Hassanien, "Prediction of wastewater treatment plant performance using artificial neural networks" *Environmental Modeling & Software*, Vol.19, 2004.
- [6] E. N. Sanchez, J. F. Beteau and S. Carlos, "Hierarchical fuzzy control for a wastewater treatment plant", *IEEE Conference on Systems, Man and Cybernetics*, Tucson, USA, Oct. 2001.
- [7] J.B. Copp, *The COST simulation benchmark description and simulator manual (COST Action 624 & 682)*. Luxembourg: Office for Official Publications of the European Communities, 2002.
- [8] M. Henze, Gredy, W. Gujer, G. Marias and T. Matsuo. *Activated Sludge Model n° 1*. IAWQ Scientific and Technical Report n°1, 1986.
- [9] C. Cadet, N. Lucas, J.F. Beteau, A. Guillet, M. Aurousseau and N. Simonin. "Modelling of wastewater treatment of a pulp and paper mill for monitoring. Environmental", *Engineering and management Journal*, 2003
- [10] C. Cadet, J.F. Beteau and S.C. Hernandez. Multicriterial control strategy for cos/quality compromise in wastewater treatment plants. *Control Engineering Practice*, 2004.
- [11] C. Bassompierre, *Activated Sludge Method for The Treatmet of Effluents Stationers: from The Conception of a Prototype to the Validation of Models*, Ph.D. Thesis (in French), Grenoble, France, February, 2007.

- [12] J. Alex, J. F. Beteau, J. B. Copp, C. Hellings, U. Jepsson and S. Marsili-Libelli, "The COST simulation benchmark: description and simulator manual", *European Control Conference*, Karlsruhe, Germany, BM20, 2000.
- [13] K. Passino and S. Yurkovich, *Fuzzy Control*, Addison Wesley Longman, New York, USA, 1998.
- [14] M. L. Lakrori, *L/A Control Applications*, Ph.D. Thesis, in French, Institut National Polytechnique de Grenoble, France, 1989.
- [15] M. Lakrori, "Control of a continuous bioprocess by simple algorithms of P and L/A types", *IFAC Symposium on Nonlinear Control System Design*, Capri, Italy, pp. 478-483, 1989.
- [16] M. Norgaard, O. Ravn, N.K Poulsen and L.K Hansen, *Neural Networks for Modeling and Control of Dynamic Systems*, Springer-Verlag Berlin, Germany, 1999.
- [17] S. Haykin, *Neural Networks: a Comprehensive Foundation*. New Jersey, USA: Prentice Hall, 1999.
- [18] L. J. Ricalde and E. N. Sanchez, "Inverse optimal nonlinear high order recurrent neural observer", *International Joint Conference on Neural Networks IJCNN 05*, Montreal, Canada, August, 2005.
- [19] G. A. Rovithakis and M. A. Christodoulou, *Adaptive Control with Recurrent High-Order Neural Network*, Springer-Verlag, New York, USA, 2000.
- [20] E. N. Sanchez, A. Y. Alanis, and A. G. Loukianov, *Discrete-Time Recurrent High Order Neural Observer for Induction Motors*, in "Foundations of Fuzzy Logic and Soft computing" Eds. P. Melin et al., Springer-Verlag, Berlin Heidelberg, Germany, 2007
- [21] Y. Song and J. W. Grizzle, "The extended Kalman Filter as a local asymptotic observer for discrete-time nonlinear systems", *Journal of Mathematical Systems, Estimation and Control*, Vol. 5, No.1, pp. 59-78, Boston, USA, 1995.
- [22] E. N. Sanchez, A. Y. Alanis and G. Chen, "Recurrent neural networks trained with Kalman filtering for discrete chaos reconstruction", *Proceedings of Asia-Pacific Workshop on Chaos Control and Synchronization*, Melbourne, Australia, July 2004.
- [23] T. Lopez, A. Pulis, and R. Baratti, "On-line monitoring of a biological reactor for wastewater treatment". *Revista Mexicana de Ingeniería Química*, 3 (1), pp. 51-63, 2004.
- [24] V. Alcaraz and V. Gonzalez, *Robust Nonlinear Observers for Bioprocesses: Application to Wastewater Treatment*, in "Lecture Notes in Control and Information Sciences". Springer-Verlag, Berlin Heidelberg, Germany, 2007.

-
- [25] E. N. Sanchez, J. F. Beteau and S. Carlos, "Hierarchical fuzzy control for a wastewater treatment plant", *IEEE Conference on Systems, Man and Cybernetics*, Tucson, USA, Oct. 2001.
- [26] R. Marino, "Observers for single output nonlinear systems". *IEEE Transactions on Automatic Control*, Vol.35, pp. 1054-1058, September 1990.
- [27] A. S. Poznyak, E. N. Sanchez and W. Yu, *Differential Neural Networks for Robust Nonlinear Control*, World Scientific, Singapore, 2001.
- [28] X. Han and S. Guan, "Hybrid Intelligent Control Strategy", *IEEE Control Systems*, June, 2001.
- [29] G. Vera, *Control Inteligente de una Planta Aeróbica de Tratamiento de Aguas Residuales*, Ph. D. Tesis, CINVESTAV Unidad Guadalajara, México. 2002
- [30] Y. H. Kim and F. L. Lewis, *High-Level Feedback Control with Neural Networks*. Singapore: World Scientific, 1998.

Apéndice A

Demostración del Teorema 4.1

En este anexo se presenta la demostración del Teorema 4.1

Teorema 4.1 Para el sistema (4.12) el RHONO (4.13), entrenado con el algoritmo basado en el FKE (4.8), asegura que el error de estimación (4.15) y el error en la salida (4.14) son semiglobalmente uniformemente ultimamente acotado (SUGUUB de su nombre en inglés "Semiglobally Uniformly Ultimately Bounded"); además, los pesos del RHONO permanecen acotados.

Prueba: Considérese la función de Lyapunov candidata:

$$\begin{aligned} V_i(k) &= \tilde{w}_i(k) P_i(k) \tilde{w}_i(k) + \tilde{x}_i(k) P_i(k) \tilde{x}_i(k) \\ \Delta V_i(k) &= V(k+1) - V(k) \\ \Delta V_i(k) &= \tilde{w}_i(k+1) P_i(k+1) \tilde{w}_i(k+1) + \tilde{x}_i(k+1) P_i(k+1) \tilde{x}_i(k+1) \\ &\quad - \tilde{w}_i(k) P_i(k) \tilde{w}_i(k) - \tilde{x}_i(k) P_i(k) \tilde{x}_i(k) \end{aligned} \quad (\text{A.1})$$

Empleando (4.8) y (4.7) en (A.1):

$$\begin{aligned} \Delta V_i(k) &= [\tilde{w}_i(k) - \eta K_i(k) e(k)]^T [A_i(k)] [\tilde{w}_i(k) - \eta K_i(k) e(k)] \\ &\quad + [f(k) - g_i C \tilde{x}(k)]^T [A_i(k)] [f(k) - g_i C \tilde{x}(k)] \\ &\quad - \tilde{w}_i(k) P_i(k) \tilde{w}_i(k) - \tilde{x}_i(k) P_i(k) \tilde{x}_i(k) \end{aligned} \quad (\text{A.2})$$

con

$$\begin{aligned} A_i(k) &= P_i(k) - D_i(k) + Q_i D_i(k) = k_i(k) H_i^T P_i(k) \\ f(k) &= \tilde{w}_i(k) z_i(x(k), u(k)) + \epsilon_{zi} \end{aligned}$$

Entonces, (A.2) se puede expresar como:

$$\begin{aligned}
\Delta V_i(k) &= \tilde{w}_i^T(k) P_i(k) \tilde{w}_i(k) - \tilde{w}_i^T(k) [B_i(k)] \tilde{w}_i(k) \\
&\quad + \eta^2 \tilde{x}^T(k) C^T K^T [A_i(k)] K_i(k) C \tilde{x}(k) \\
&\quad + f^T(k) P_i(k) f(k) - f^T(k) [B_i(k)] f(k) \\
&\quad + \tilde{x}^T(k) C^T g_i^T [A_i(k)] g_i C \tilde{x}(k) \\
&\quad - \tilde{w}_i^T(k) P_i(k) \tilde{w}_i(k) - \tilde{x}_i^T(k) P_i(k) \tilde{x}_i(k)
\end{aligned}$$

$$\begin{aligned}
\Delta V_i(k) &\leq \|\tilde{x}(k)\|^2 \|\eta K_i C\|^2 \|A_i(k)\| - \|\tilde{x}(k)\|^2 \|g_i C\|^2 \|A_i(k)\| \\
&\quad - \|\tilde{x}(k)\|^2 P_i(k) - \|\tilde{w}_i(k)\|^2 \|B_i(k)\| + |\epsilon_{zi}|^2 \|A_i(k)\| \\
&\quad + 2 \|\tilde{w}_i(k)\| \|z_i(\hat{x}(k)), u(k)\| |\epsilon_{zi}| \|A_i(k)\| \\
&\quad - \|\tilde{w}_i(k)\|^2 \|z_i(\hat{x}(k)), u(k)\|^2 \|A_i(k)\|
\end{aligned}$$

$$\text{con } B_i(k) = D_i(k) - Q_i$$

$$\Delta V_i(k) \leq -\|\tilde{x}(k)\|^2 E_i(k) - \|\tilde{w}_i(k)\|^2 F_i(k) + |\epsilon_{zi}|^2 \|A_i(k)\| + 2G_i(k) \quad (\text{A.3})$$

con:

$$\begin{aligned}
E_i(k) &= P_i(k) - \|\eta K_i C\|^2 \|A_i(k)\| - \|g_i C\|^2 \|A_i(k)\| \\
F_i(k) &= \|B_i(k)\| - \|z_i(\hat{x}(k)), u(k)\|^2 \|A_i(k)\| \\
G_i(k) &= \|w_i^* - w_{i\text{máx}}\| \|z_i(\hat{x}(k)), u(k)\| |\epsilon_{zi}| \|A_i(k)\|
\end{aligned}$$

Entonces $\Delta V_i(k) < 0$ cuando:

$$\|\tilde{x}(k)\| > \sqrt{\frac{|\epsilon_{zi}|^2 \|A_i(k)\| + 2G_i(k)}{E_i(k)}} \equiv k1 \quad (\text{A.4})$$

$$\|\tilde{w}_i(k)\| > \sqrt{\frac{|\epsilon_{zi}|^2 \|A_i(k)\| + 2G_i(k)}{F_i(k)}} \equiv k1 \quad (\text{A.5})$$

Por consiguiente, la solución de (4.16) es estable; por lo tanto el error de estimación y los pesos del RHONO son SGUUB [30]. En la Figura A.1 se muestra una ilustración gráfica del teorema. Considerando (4.13) y (4.14) es fácil ver que el error de salida tiene una relación algebraica con $\tilde{x}(k)$ es acotada, entonces $e(k)$ también es acotada:

$$\begin{aligned}e(k) &= C\tilde{x}(k) \\ \|e(k)\| &= \|C\| \|\tilde{x}(k)\|\end{aligned}$$




Figura A.1: Ilustración gráfica del Teorema 4.1

Apéndice B


Artículos Publicados

Los artículos obtenidos producto de esta tesis son:

- R. Carrasco, E.N. Sanchez and C. Cadet, "Neural Network Identification of a Wastewater Treatment Prototype", in International Joint Conference on Neural Network (IJCNN 2009), Atlanta, Georgia, USA, 2009.
- R. Carrasco, E.N. Sanchez and C. Cadet, "Hybrid Intelligent Control for a Wastewater Treatment Prototype", in Mediterranean Conference on Control and Automation (MED 2009), Thessaloniki, Greece, 2009.

The 2009 International Joint Conference on Neural Networks

IJCNN 2009 Conference Proceedings



Sponsored by:



**INTERNATIONAL
NEURAL NETWORK
SOCIETY**



**IEEE
Computational
Intelligence
Society**

June 14-19, 2009
Westin Peachtree Plaza
Atlanta, Georgia USA
IEEE Catalog Number: CFP09IJS-CDR
ISBN: 978-1-4244-3553-1
ISSN: 1098-7576
©2009 IEEE

©2009 IEEE. Personal use of this material is permitted. However, permission to reprint/republish this material for advertising or promotional purposes or for creating new collective works for resale or redistribution to servers or lists, or to reuse any copyrighted component of this work in other works must be obtained from the IEEE.

Photo: Copyrighted property of 123RF Limited

CD ROM Support:

Documation LLC
1556 International Drive
Eau Claire, WI 54701 USA
Phone: 1-715-839-8899 • Fax: 1-715-836-7411
Email: info@documation.com • www.documation.com

- ▶ Frontmatter
- ▶ Schedule Grids
- ▶ Conference Program
- ▶ Conference Papers
- ▶ Author Index
- ▶ Sponsors
- ▶ Search This CD
- ▶ Adobe® Acrobat® Help

Neuronal Network Identification of a Wastewater Treatment Prototype

R. Carrasco, E.N. Sanchez, C. Cadet

Abstract— This paper presents neuronal network identification of a wastewater treatment prototype. This identification is based on a discrete-time high order neuronal network (RHONN). The neuronal network is trained with an extended Kalman filter (EKF) algorithm. The neuronal identification performance is illustrated via simulations.

I. INTRODUCTION

Usually, control system synthesis requires the knowledge of the system to be controlled, which usually appears in terms of differential equations.

Basically exist two different ways to obtain a model: 1) it can be obtained based on physical laws, or 2) it can be inferred from experimental data. The first method can be simple, but consumes long time, and in some cases it is practically impossible to deduce a correct model. The second one, known as systems identification, is very helpful because consumes a shorter time and requires relatively smaller effort.

System identification is the task of inferring a mathematical description, a model, of a dynamic system from a series of measurements [6]. There can be several motives for establishing mathematical description of dynamical systems. Typical applications encompass simulation, prediction, fault detection, and control system design. If the burden associated with building a model using laws of physics, chemistry, economics, etc., is considered overwhelming, system identification techniques are naturally of particular interest.

A useful tool for the identification of nonlinear systems is the neuronal networks, which are widely used to approximate functions. A question of extreme importance in the identification of systems is the identificability of the system, that is to say, the suitable representation of the system structure. Neuronal networks represent an alternative for the solution of this kind of problems.

In [9], the synthesis of a recurrent high order neural observer (RHONO) [10], based on RHONN and trained on-line with an extended Kalman filter (EKF) is presented [11]. The observer is applied to the aerobic plant benchmark of

the European group COST 624 [4], in order to estimate the substrate and biomass concentration. This observer is associated with a hybrid intelligent system to control the substrate/biomass concentration ratio.

In order to develop a similar observer as in [9] to a WWTP prototype, in this work we use a neural network identification for nonlinear systems, based on RHONN [11], in order to identify the fast biodegradable substrate S_S , active heterotrophic biomass X_{BH} , active autotrophic biomass X_{BA} , dissolved oxygen S_O and amoniacal nitrogen S_{NH} . The neural identification learning is based on extended Kalman filter (EKF) algorithm [12].

Recently, the use of wastewater treatment plants (WWTPs) has increased due to environmental issues. Controlling a WWTP is not a simple task, and several techniques has been proposed [3], [5]. The application of these strategies requires sensors allowing the measurements of the process main variables; these sensors could be very expensive and require elaborated maintenance procedures. Due to these facts, state estimation applied to WWTP and to biological processes has received special attention by many authors, who have obtained interesting results in different directions and for different purposes. Most of the existing results need the use of a special nonlinear transformation [14]. As a viable alternative, which does not require such transformation, we propose in this paper the use of a RHONN to estimate WWTP variables.

II. DISCRETE-TIME RECURRENT HIGH ORDER NEURAL NETWORK

Let consider a MIMO nonlinear system

$$x(k+1) = F(x(k), u(k)) \quad (1)$$

where $x \in \mathcal{R}^n$, $u \in \mathcal{R}^m$ and $F \in \mathcal{R}^n \times \mathcal{R}^m \rightarrow \mathcal{R}^n$ is a nonlinear function. Now a discrete-time recurrent high order neural network (RHONN) can be presented as:

$$x_i(k+1) = w_i^T z_i(x(k), u(k)), \quad i = 1, \dots, n \quad (2)$$

where x_i ($i = 1, 2, \dots, n$) is the state of the i th neuron, n is the number of neural units, $\{I_1, I_2, \dots, I_{Li}\}$ is a collection of non-ordered subsets of $\{1, 2, \dots, n\}$, w_i ($i = 1, 2, \dots, n$) is the respective on-line adapted weight vector, and $z_i(x(k), u(k))$ is given by

R. Carrasco, E.N. Sanchez, CINVESTAV, Unidad Guadalajara, Av. Científica 1145, Col. El bajío, Zapopán, Jal., C.P. 45010, México. Tel. +52(33) 3777 3600, Fax. + 52(33) 3777 3609, e-mail: [carrasco|sanchez]@gd.cinvestav.mx

C. Cadet, Institute National Polytechnique de Grenoble, GIPSA-lab Department of control systems BP 46-38402 St-Martin d'Hères Cedex, France, e-mail: Catherine.Cadet@inpg.fr

$$z_i(x(k), u(k)) = \begin{bmatrix} z_{i_1} \\ z_{i_2} \\ \vdots \\ z_{i_{L_i}} \end{bmatrix} = \begin{bmatrix} \prod_{j \in I_1} y_i^{d_i j(1)} \\ \prod_{j \in I_2} y_i^{d_i j(2)} \\ \vdots \\ \prod_{j \in I_{L_i}} y_i^{d_i j(L_i)} \end{bmatrix} \quad (3)$$

with L_i is the respective number of higher-order connections, $d_i(k)$ being nonnegative integers and y_i is defined as follows:

$$y_i = \begin{bmatrix} y_{i_1} \\ \vdots \\ y_{i_n} \\ y_{i_{n+1}} \\ \vdots \\ y_{i_{n+m}} \end{bmatrix} = \begin{bmatrix} s(x_1) \\ \vdots \\ s(x_n) \\ u_1 \\ \vdots \\ u_n \end{bmatrix} \quad (4)$$

In (4), $u = [u_1, u_2, \dots, u_m]^T$ is the input vector to the neural network (NN), and $S(\blacksquare)$ is defined by

$$s(x) = \frac{1}{1 + \exp(-\beta x)} \quad (5)$$

where β is a parameter.

We consider the problem to approximate the general-time nonlinear system (1), by the following discrete-time RHONN [13], introducing the modeling error :

$$x_i(k+1) = w_i^{*T} z_i(x(k), u(k)) + \varepsilon_z, \quad i=1, \dots, n \quad (6)$$

where x_i is the i th plant state, ε_z is a bounded approximation error, which can be reduced by increasing the number of adjustable weights [7]. Assume that exists an ideal weight vector w_i^* such that $\|\varepsilon_z\|$ can be minimized on a compact set $\Omega_D \subset \mathfrak{R}^{L_i}$; in general, it is assumed that this vector exists and is constant but unknown. Let us define its estimate as \tilde{w}_i and the estimation error as

$$\tilde{w}_i(k) = w_i^* - w_i(k) \quad (7)$$

III. THE EKF TRAINING ALGORITHM

The well known Kalman filter is a set of mathematical equations which provides an efficient computational (recursive) solution of the least-square method; this filter which estimates the state of a linear system with additive state and output with noises [8]. For Kalman filter based neural network training, the network weights become the states to be estimated. In this case, the error between the neural network output and the measured plant output can be

considered as additive white noise. Due to the fact that the neural network mapping is nonlinear, an EKF-type is required. The training goal is to find the optimal weight values which minimize the predictions error. In this work, we use an EKF-based training algorithm described by

$$\begin{aligned} w_i(k+1) &= w_i(k) + \eta_i k_i(k) e(k), e(k) = y(k) - \hat{y}(k) \\ k_i(k) &= P_i(k) H_i(k) M_i(k), \quad i=1, \dots, n \\ P_i(k+1) &= P_i(k) - k_i(k) H_i^T(k) P_i(k) + Q_i(k) \end{aligned} \quad (8)$$

with

$$M_i(k) = [R_i(k) + H_i^T(k) P_i(k) H_i(k)]^{-1} \quad (9)$$

where $e(k) \in \mathfrak{R}^p$ is the output estimation error and $P_i(k) \in \mathfrak{R}^{L_i \times L_i}$ is the weight estimation error covariance matrix at step k , $w_i \in \mathfrak{R}^{L_i}$ is the weight (state) vector, L_i is the respective number of neural network weights, $y \in \mathfrak{R}^p$ is the plant output, $\hat{y} \in \mathfrak{R}^p$ is the neural network output, n is the number of states, $K_i \in \mathfrak{R}^{L_i \times p}$ is the Kalman gain matrix, $Q_i \in \mathfrak{R}^{L_i \times L_i}$ is the NN weight estimation noise covariance matrix, $R_i \in \mathfrak{R}^{p \times p}$ is the error noise covariance, and $H_i \in \mathfrak{R}^{L_i \times p}$ is a matrix, in which each entry (H_{ij}) is the derivative of the i th neural output with respect to ij th NN weight, (w_{ij}), given as follows:

$$H_{ij}(k) = \left[\frac{\partial \hat{y}(k)}{\partial w_{ij}(k)} \right] \quad (10)$$

where $i=1, \dots, n$ and $j=1, \dots, L_i$. Usually P_i and Q_i are initialized as diagonal matrices, with entries $P_i(0)$ and $Q_i(0)$, respectively. It is important to remark that $H_i(k)$, $K_i(k)$ and $P_i(k)$ for the EKF are bounded; for a detailed explanation of this fact see [8].

IV. PROTOTYPE DESCRIPTION

All the components of an industrial biological treatment process, following the primary treatment, are included in this prototype [1]; a picture of the activated sludge prototype is presented in Fig. 1. The three main parts of this process are: a) The bioreactor, in which the biomass assimilates pollutions. A movable aeration system produces aerobic compartments to treat either urban or industrial effluents. Movable baffles allow adapting hydrodynamic behavior to different real process configurations (channel aerator, carousel, CSTR series) and a stirrer moves the liquid. b) The settler, in which the biomass agglomerates in falling flocks (sludge) letting the superficial water purified. Real settling conditions are obtained thanks to its industrial shape (a slight slope cone surmounted by a cylinder and a scraper). c) A sludge recirculation system which allows maintaining a constant biomass concentration in the process.

V. PROTOTYPE MODEL

The mathematical model used to simulate the prototype dynamics in aerobic phase is described below [2]. It consists of five state variables, with two of them easily measured on line (S_O and S_{NH}).

$$\frac{ds_s}{dt} = \frac{1}{V} (s_{s-o} Q_O + s_{s-r} Q_r - (Q_O + Q_r)) + r_{s_s} \quad (11)$$

$$\frac{dX_{BH}}{dt} = \frac{1}{V} (X_{BH-o} Q_O + X_{BH-r} Q_r - X_{BH} (Q_O + Q_r)) + r_{X_{BH}} \quad (12)$$

$$\frac{dX_{BA}}{dt} = \frac{1}{V} (X_{BA-o} Q_O + X_{BA-r} Q_r - X_{BA} (Q_O + Q_r)) + r_{X_{BA}} \quad (13)$$

$$\frac{dS_O}{dt} = \frac{1}{V} (s_{o-o} Q_O + s_{o-r} Q_r - S_O (Q_O + Q_r)) + r_{S_O} + u_4 \quad (14)$$

$$\frac{dS_{NH}}{dt} = \frac{1}{V} (s_{NH-o} Q_O + s_{NH-r} Q_r - S_{NH} (Q_O + Q_r)) + r_{S_{NH}} \quad (15)$$




Fig.1. The Activated Sludge Prototype.

Additional elements enhance the prototype, whose scheme is presented in Fig. 2, such as:

- a stirred and cooled storage tank to obtain an influent supply;
- a buffer tank allows pH and nutrient adjustments of the influent;
- an independent electrical device ensures the security of the whole process, and human and material safety;
- an industrial device supervises the process through different operating modes, and control loops on the liquid level and the dissolved oxygen concentration in the bioreactor are implemented;
- several on-line industrial sensors.

where $Z_0 = [S_{s-o} X_{BH-o} X_{BA-o} S_{O-o} S_{NH-o}]$ is a vector that represents the concentrations of the influent components, $Z_r = [S_{s-r} X_{BH-r} X_{BA-r} S_{O-r} S_{NH-r}]$ is a vector that represents the concentrations of the components in the recycling loop, Q_O is the flow rate of the influent, Q_r is the internal recycle flow rate, V is the reactor volume, u_4 is the input control action, ρ_i ($i = 1,3,4,5$) are the equations describing the rates of reaction. Those are given by

$$\rho_1 = \gamma_h \frac{s_s}{K_S + s_s} \frac{S_O}{K_{OH} + S_O} \frac{S_{NH}}{K_{NH} + S_{NH}} X_{BH} \quad (16)$$

$$\rho_3 = \gamma_a \frac{S_{NH}}{K_{NH} + S_{NH}} \frac{S_O}{K_{OA} + S_O} X_{BA} \quad (17)$$

$$\rho_4 = b_H X_{BH} \quad (18)$$

$$\rho_5 = b_A X_{BA} \quad (19)$$

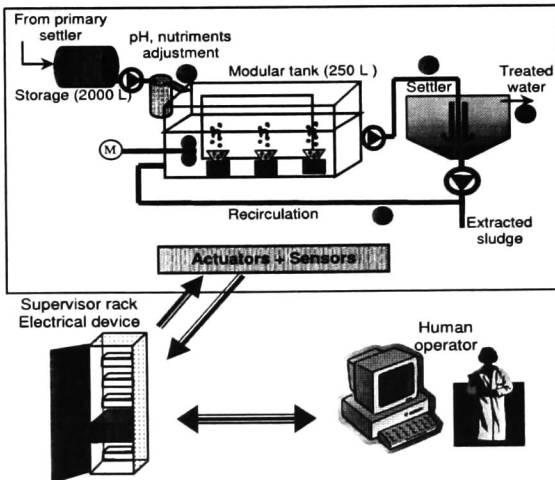


Fig.2. Prototype Scheme

The objective of the process is to maintain the effluent within the quality norms. In order to reach this objective, there must maintain a good biological activity and disturbances rejection need to be ensured.

where $\gamma_h = 1.019$, $\gamma_a = 0.097$, K_S is the half-saturation coefficient in fast biodegradable substrate, K_{OH} is the half-saturation coefficient in dissolved oxygen for heterotrophic biomass, K_{NH} is the half-saturation coefficient of in amoniacal nitrogen, K_{OA} is the half-saturation coefficient in dissolved oxygen for autotrophic biomass, b_H is the mortality coefficient of the heterotrophic biomass, b_A is the mortality coefficient of the autotrophic biomass. Finally, the conversion rates which are expressed in function of the reaction rates and the stoichiometric coefficients of all the processes taking place within the biological reactor are given by:

$$r_{S_5} = \frac{-1}{Y_H} \rho_1 + (1-f_p)(\rho_4 + \rho_5) \quad (20)$$

$$r_{X_{BH}} = \rho_1 - \rho_4 \quad (21)$$

$$r_{X_{BA}} = \rho_3 - \rho_5 \quad (22)$$

$$r_{S_O} = -\frac{(1-Y_H)}{Y_H} \rho_1 - \frac{(4.57-Y_A)}{Y_A} \rho_3 \quad (23)$$

$$r_{S_{NH}} = -i_{XB} \rho_1 - \frac{(i_{XB}+1)}{Y_A} \rho_3 \quad (24)$$

where Y_H is the substrate conversion in biomass of the heterotrophic bacteria is, Y_A is substrate conversion in biomass of the autotrophic bacteria, f_p is the DCO fraction, i_{XB} is nitrogen fraction in the heterotrophic biomass.

VI. IDENTIFICATION APPLICATION

To this end, neural network identification is applied to the wastewater treatment prototype presented in section V; it is assumed that all the state variables are measured. For this identification, we use a RHONN with $n=5$ as

$$\hat{x}_1(k+1) = w_{11}s^4(x_1) + w_{12}s^4(x_1)s(x_2)s(x_4) + w_{13}d_1$$

$$\hat{x}_2(k+1) = w_{21}s^5(x_2) + w_{22}s^3(x_4)s^3(x_2)s(x_1) + w_{23}s(x_2) + w_{24}d_2$$

$$\hat{x}_3(k+1) = w_{31}s^3(x_3) + w_{32}s(x_4)s(x_2) + w_{33}s(x_6) + w_{34}d_3$$

$$\hat{x}_4(k+1) = w_{41}s^4(x_1)s(x_2)s(x_4) + w_{42}s(x_5)s^2(x_2)s^4(x_4) + w_{43}u_4$$

$$\hat{x}_5(k+1) = w_{51}s^4(x_5) + w_{52}s(x_2)s^3(x_1) + w_{53}s(x_3) + w_{54}d_5$$

where x_1, x_2, x_3, x_4, x_5 correspond to the fast biodegradable substrate S_S , active heterotrophic biomass X_{BH} , active autotrophic biomass X_{BA} , oxygen S_O and amoniacal nitrogen S_{NH} , respectively. u_4 is the oxygen control action and d_i are the concentration of the components.

The training is performed on-line, using a serie-parallel configuration as displayed in Fig.3.

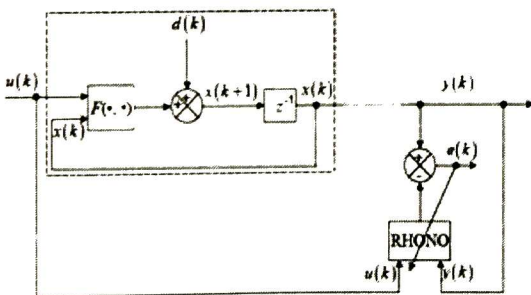


Fig.3. Identification scheme.

All the neural network states are initialized randomly. The covariance matrices are initialized as diagonal, with nonzero elements as: $P_i(0) = 60000$, $Q_i(0) = 2500$ and $R_i(0) = 4400$, ($i=1,2, 3, 4,5$), respectively.

VII. SIMULATION RESULTS

Simulations are implemented using Matlab/ Simulink®; two different scenarios are considered: for the first day a constant disturbance is included; then, for the next seven days a variable disturbance is inserted as can be seen in Fig. 4. The model is tested with the prototype configuration and the input measurements proposed by the European group COST Action 624 [4].

Fig. 5, Fig. 6, Fig. 7, Fig. 8 and Fig. 9 display each state variable and its respective identification. We can see that the identification is extremely effective, and the convergence time is small. We have to mention that even when we introduce disturbances, the estimation of the states continues to be acceptable.

Fig. 10, Fig. 11, Fig. 12, Fig. 13 and Fig. 14 display each identification error.




Fig. 4. Disturbance Q_0 .




Fig.5. Fast biodegradable substrate (solid line) and its respective identification (dashed line).




Fig.6. Heterotrophic biomass (solid line) and its respective identification (dashed line).




Fig.9. Dissolved oxygen (solid line) and its respective identification (dashed line).




Fig.7. Autotrophic biomass (solid line) and its respective identification (dashed line)




Fig.10. Error identification for fast biodegradable substrate.




Fig.8. Ammoniacal nitrogen (solid line) and its respective identification (dashed line).




Fig.11. Error identification for heterotrophic biomass.




Fig.12. Error identification for autotrophic biomass




Fig.13. Error identification for amoniacal nitrogen




Fig.14. Error identification for dissolved oxygen

Table 1 shows the mean and standard deviation for each identification error.

Identification error	mean (μ)	Standard deviation (σ)
e_{s_t}	0.0097	0.3952
$e_{x_{NH}}$	0.1618	11.9763
$e_{x_{BA}}$	-0.0054	1.0268
$e_{s_{NH}}$	6.3199e-004	0.1086
$e_{s_{O_2}}$	1.5476e-004	0.0056

Table 1. Spread measures of the identification error.

VIII. CONCLUSIONS

In this paper, the identification of fast biodegradable substrate, heterotrophic biomass, autotrophic, dissolved oxygen and amoniacal nitrogen in a wastewater treatment prototype has been developed, using a discrete-time high order neuronal network considering all the space states measurable; the neural identifier is trained with an extended Kalman filter based algorithm, which is implemented on-line. Simulations results show the effectiveness of the proposed identification scheme. The model is now ready to be tested on the prototype plant, and be further used for estimating on-line biomasses and carbonaceous pollution or to be included in an intelligent control strategy.

ACKNOWLEDGMENT

The authors thank the support of CONACYT, Mexico, on project 57801.

REFERENCES

- [1] C. Bassompierre, *activated sludge method for the treatmet of effluents stations: of the conception of a prototype to the validation of models*, (in French), Grenoble, France, February, 2007.
- [2] C. Bassompierre and C. Cadet, J.F. Bêteau, M. Arousseau, A. Guillet. "Towards an integrated co-operative supervision system for activated sludge processes optimisation", International Symposium on Advanced Control of Chemical Processes, ADCHEM'06, April 25, 2006, Gramado, Brazil.
- [3] M.A. Brdys, M. Grochowski, T. Gminski, K. Konarczak and M. Drewa, "Hierarchical predictive control of integrated wastewater treatment systems", *Control Engineering Practice*, January 2007.
- [4] J.B. Copp, "The COST Simulation benchmark: Description and Simulator Manual," *Office for official Publications of the European Communities*, Luxembourg, 2002.
- [5] T. Lopez, A. Pulis, and R. Baratti, "On-line monitoring of a biological reactor for wastewater treatment", *Revista Mexicana de Ingenieria Química*, 3 (1), 51-63, 2004.
- [6] M. Norgaard, O. Ravn, N.K Poulsen and L.K Hansen, *Neural Networks for Modeling and Control of Dyamic Systems*, Springer-Verlag Berlin, Germany, 1999.
- [7] G.A. Rovithakis and M.A. Christodoulou, *Adaptive Control with Recurrent High-Order Neural Network*, Springer-Verlag, Berlin, Germany, 2000.
- [8] L. J. Ricalde and E.N. Sanchez, "Inverse optimal nonlinear high order recurrent neural observe", *International Joint Conference on Neural Networks*, Montreal, Canada, August, 2005.
- [9] E.N. Sanchez, E. A. Hernandez, C. Cadet, J. F. Beteau, "Discret-Time Recurrent High Order Neural Observer for Activated Sludge

- Wasterwater Treatment", *IEEE World Congres on Computational Intelligence, Hong Kong, june 1-6, 2008*.
- [10] E.N. Sanchez and A. Y. Alanis, Alexander G. Loukianov, "Discret-Time Recurrent High Order Neural Observer for Induction Motors", Springer-Verlang, Berlin, 2007.
 - [11] E.N. Sanchez and A. Y. Alanis, *Neuronal networks, fundamental concepts and application to automatic control* (in Spanish), Pearson Education, Madrid, España, 2006.
 - [12] E.N. Sanchez, A.Y. Alanis and G. Chen, "Recurrent neural networks trained with Kalman filtering for discrete chaos reconstruction", *Workshop on Chaos Control and Synchronization '04*, Melbourne, Australia, July, 2004.
 - [13] Y. Song and J. W. Grizzle, *The extended Kalman filter as a local asymptotic observer for discrete-time nonlinear systems*, Journal of Mathematical Systems, Estimation and Control, Vol. 5, No.1, pp. 59-78, Birkhauser-Boston, 1995.
 - [14] G. Vera, E.N. Sanchez, J.F. Bêteau and C. Cadet, "Intelligent control of an activated sludge wastewater treatment plant", *American Control Conference ACC03*, Denver, USA, June 2003.



Celebrating 125 Years
of Engineering the Future

IEEE Catalog Number: CP09MED-CDR
ISBN: 978-1-4244-4645-8
Library of Congress: 2009004787

Sponsor



Technical Co-Sponsors



Patron



Supporters



17th Mediterranean Conference on Control and Automation

June 24-26, 2009, Makedonia Palace, Thessaloniki, Greece

Welcome

Program at a Glance

Chairs & IPC

Table of Contents

Author Index

Keyword Index

Plenaries

Workshops & Courses

Search this CD

Upcoming and Past Conferences

Copyright

©2009 IEEE. Personal use of this material is permitted. However, permission to reprint/republish this material for advertising or promotional purposes or for creating new collective works for resale or redistribution to servers or lists, or to reuse any copyrighted component of this work in other works must be obtained from IEEE.

CD-ROM support, contact The Printing House, Inc. at +1-408-873-4500. For more information, please see the "Copyright" page.

Help

Hybrid Intelligent Control for a Wastewater Treatment Prototype

R. Carrasco, E.N. Sanchez, C. Cadet

Abstract— This paper presents a hybrid intelligent control based on nonlinear PI controller and a recurrent high order neural network (RHONN) identifier. This control scheme is applied to a wastewater treatment prototype. The hybrid intelligent control and neuronal identification performance is illustrated via simulations.

I. INTRODUCTION

The aerobic wastewater treatment plants have few variables to manipulate in comparison with the number of states variables. Between the more important variables to manipulate we can mention the following: the aeration speed (that is related with the aeration constant (kla)), the speed of internal and external recycled flow, the speed of waste sludge flow, external addition of nutrients (not considered in the mathematical models) and the flow speed of effluent (applicable only in certain cases).

Similarly, there are some state space variables of the process which are typically chosen as variables to control. Between them the ones used more frequently are: the dissolved oxygen concentration, the nitrates and nitrites concentration, the sludge amount in the biological reactor and in the settler, sludge age and the reaction speed [10].

The control of the dissolved oxygen concentration is the most important control loop within the activated sludge process. The dissolved oxygen concentration in the aeration system has very important repercussions in the quality of the effluent because the microorganism growth rate depends on it. The way to control the dissolved oxygen concentration is by the manipulation of the aeration constant (kla).

This work is related to two main aspects: 1) the development of a hybrid intelligent control based on nonlinear PI controller, which is applied to a WWTP prototype in order to control dissolved oxygen concentration and ensure effluent quality even in presence of external disturbances. 2) The development of a neural network identifier, based on a discrete-time high order neural network (RHONN) [7]. The neural identification learning is based on extended Kalman filter (EKF) algorithm [8]. Furthermore, we incorporate this neural identification to the mentioned control.

R. Carrasco, E.N. Sanchez, CINVESTAV, Unidad Guadalajara, Av. Científica 1145, Col. El bajío, Zapopán, Jal., C.P. 45010, México. Tel. +52(33) 3777 3600, Fax. + 52(33) 3777 3609, e-mail: [carrasco|sanchez]@gd.cinvestav.mx

C. Cadet, Institute National Polytechnique de Grenoble, GIPSA-lab Department of control systems BP 46-38402 St-Martin d'Hères Cedex, France, e-mail: Catherine.Cadet@inpg.fr

II. DISCRETE-TIME RECURRENT HIGH ORDER NEURAL NETWORK

Let consider a MIMO nonlinear system

$$x(k+1) = F(x(k), u(k)) \quad (1)$$

where $x \in \mathfrak{R}^n$, $u \in \mathfrak{R}^m$ and $F \in \mathfrak{R}^n \times \mathfrak{R}^m \rightarrow \mathfrak{R}^n$ is a nonlinear function. Now a discrete-time recurrent high order neural network (RHONN) can be presented as:

$$x_i(k+1) = w_i^T z_i(x(k), u(k)), \quad i = 1, \dots, n \quad (2)$$

where x_i ($i = 1, 2, \dots, n$) is the state of the i th neuron, n is the number of neural units, $\{I_1, I_2, \dots, I_L\}$ is a collection of non-ordered subsets of $\{1, 2, \dots, n\}$, w_i ($i = 1, 2, \dots, n$) is the respective on-line adapted weight vector, and $z_i(x(k), u(k))$ is given by

$$z_i(x(k), u(k)) = \begin{bmatrix} z_{i_1} \\ z_{i_2} \\ \vdots \\ z_{i_{L_i}} \end{bmatrix} = \begin{bmatrix} \prod_{j \in I_1} y_j^{d_i(j_1)} \\ \prod_{j \in I_2} y_j^{d_i(j_2)} \\ \vdots \\ \prod_{j \in I_{L_i}} y_j^{d_i(j_{L_i})} \end{bmatrix} \quad (3)$$

with L_i is the respective number of higher-order connections, $d_i(k)$ being nonnegative integers and y_i is defined as follows:

$$y_i = \begin{bmatrix} y_{i_1} \\ \vdots \\ y_{i_n} \\ y_{i_{n+1}} \\ \vdots \\ y_{i_{nm}} \end{bmatrix} = \begin{bmatrix} s(x_1) \\ \vdots \\ s(x_n) \\ u_1 \\ \vdots \\ u_m \end{bmatrix} \quad (4)$$

In (4), $u = [u_1, u_2, \dots, u_m]^T$ is the input vector to the neural network (NN), and $S(\bullet)$ is defined by

$$s(x) = \frac{1}{1 + \exp(-\beta x)} \quad (5)$$

where β is a parameter.

We consider now the problem to approximate the general-time nonlinear system (1), by the following discrete-time RHONN [9], introducing the modeling error :

$$x_i(k+1) = w_i^T z_i(x(k), u(k)) + \varepsilon_d, \quad i=1, \dots, n \quad (6)$$

where x_i is the i th plant state, ε_d is a bounded approximation error, which can be reduced by increasing the number of adjustable weights [11]. Assume that exists an ideal weight vector w_i^* such that $\|\varepsilon_d\|$ can be minimized on a compact set $\Omega_d \subset \mathcal{R}^L$, in general, it is assumed that this vector exists and is constant but unknown. Let us define its estimate as \bar{w}_i and the estimation error as

$$\bar{w}_i(k) = w_i^* - w_i(k) \quad (7)$$

III. THE EKF TRAINING ALGORITHM

The well known Kalman filter is a set of mathematical equations that provides an efficient computational (recursive) solution of the least-square method; this filter which estimates the state of a linear system with additive state and output white noises [12]. For Kalman filter based neural network training, the network weights become the states to be estimated. In this case, the error between the neural network output and the measured plant output can be considered as additive white noise. Due to the fact that the neural network mapping is nonlinear, an EKF-type is required. The training goal is to find the optimal weight values which minimize the predictions error. In this work, we use, an EKF-based training algorithm described by

$$\begin{aligned} w_i(k+1) &= w_i(k) + \eta_i k_i(k) e(k) \\ k_i(k) &= P_i(k) H_i(k) M_i(k), \quad i=1, \dots, n \\ P_i(k+1) &= P_i(k) - k_i(k) H_i^T(k) P_i(k) + Q_i(k) \end{aligned} \quad (8)$$

with

$$M_i(k) = [R_i(k) + H_i^T(k) P_i(k) H_i(k)]^{-1} \quad (9)$$

where $e(k) \in \mathcal{R}^p$ is the observation error and $P_i(k) \in \mathcal{R}^{L_i \times L_i}$ is the weight estimation error covariance matrix at step k , $w_i \in \mathcal{R}^{L_i}$ is the weight (state) vector, L_i is the respective number neural network weights, $y \in \mathcal{R}^p$ is the plant output, $\hat{y} \in \mathcal{R}^p$ is the neural network output, n is the number of states, $K_i \in \mathcal{R}^{L_i \times p}$ is the Kalman gain matrix, $Q_i \in \mathcal{R}^{L_i \times L_i}$ is the NN weight estimation noise covariance matrix, $R_i \in \mathcal{R}^{p \times p}$ is the error noise covariance, and $H_i \in \mathcal{R}^{L_i \times p}$ is a matrix, in which each entry (H_{ij}) is the derivative of the i -th neural output with respect to ij -th NN weight, (w_{ij}), given as follows:

$$H_{ij}(k) = \left[\frac{\partial \hat{y}(k)}{\partial w_{ij}(k)} \right] \quad (10)$$

where $i=1, \dots, n$ and $j=1, \dots, L_i$. Usually P_i and Q_i are initialized as diagonal matrices, with entries $P_i(0)$ and $Q_i(0)$, respectively. It is important to remark that $H_i(k)$, $K_i(k)$ and $P_i(k)$ for the EKF are bounded; for a detailed explanation of this fact see [12]. To obtain the H matrix is not an easy task.

IV. PROTOTYPE DESCRIPTION

All the components of an industrial biological treatment process, following the primary treatment, are included in this prototype [1]; a picture of the activated sludge prototype is presented in Fig. 1. The three main parts of this process are: a) The bioreactor, in which the biomass assimilates pollutions. A movable aeration system produces aerobic compartments to treat either urban or industrial effluents. Movable baffles allow adapting hydrodynamic behavior to different real process configurations (channel aerator, carousel, CSTR series) and a stirrer moves the liquid. b) The settler, in which the biomass agglomerates in falling flocks (sludge) letting the superficial water purified. Real settling conditions are obtained thanks to its industrial shape (a slight slope cone surmounted by a cylinder and a scraper). c) A sludge recirculation system which allows maintaining a constant biomass concentration in the process.




Fig.1. The Activated Sludge Prototype.

Additional elements enhance the prototype, whose scheme is presented in Fig. 2, such as:

- a stirred and cooled storage tank to obtain an influent supply;
- a buffer tank allows pH and nutrient adjustments of the influent;
- an independent electrical device ensures the security of the whole process, and human and material safety;
- an industrial device supervises the process through different operating modes, and control loops on the liquid level and the dissolved oxygen concentration in the bioreactor are implemented;
- several on-line industrial sensors.

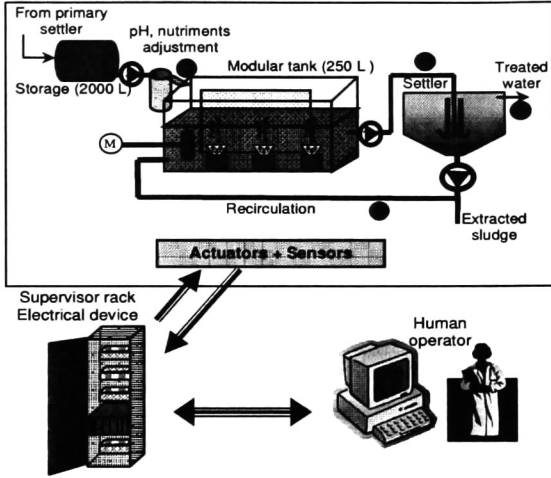


Fig.2. Prototype Scheme

The objective of the process is to maintain the effluent within the quality norms. In order to reach this objective, there must maintain a good biological activity and disturbances rejection needs to be ensured.

V. PROTOTYPE MODEL

The mathematical model used to simulate the prototype dynamics in aerobic phase is described below [2]. It consists of five state variables, with two of them easily measured on line (S_O and S_{NH}).

$$\frac{dS_s}{dt} = \frac{1}{V} (S_{S_o} Q_o + S_{S_r} Q_r - (Q_o + Q_r)) + r_{S_s} \quad (11)$$

$$\frac{dX_{BH}}{dt} = \frac{1}{V} (X_{BH_o} Q_o + X_{BH_r} Q_r - (Q_o + Q_r)) + r_{X_{BH}} \quad (12)$$

$$\frac{dX_{BA}}{dt} = \frac{1}{V} (X_{BA_o} Q_o + X_{BA_r} Q_r - (Q_o + Q_r)) + r_{X_{BA}} \quad (13)$$

$$\frac{dS_O}{dt} = \frac{1}{V} (S_{O_o} Q_o + S_{O_r} Q_r - (Q_o + Q_r)) + r_{S_O} + u_4 \quad (14)$$

$$\frac{dS_{NH}}{dt} = \frac{1}{V} (S_{NH_o} Q_o + S_{NH_r} Q_r - (Q_o + Q_r)) + r_{S_{NH}} \quad (15)$$

where $Z_0 = [S_{S_o} X_{BH_o} X_{BA_o} S_{O_o} S_{NH_o}]$ is a vector that represents the concentrations of the influent components, $Z_r = [S_{S_r} X_{BH_r} X_{BA_r} S_{O_r} S_{NH_r}]$ is a vector that represents the concentrations of the components in the recycling loop, Q_0 is the flow rate of the influent, Q_r is the internal recycle flow rate, V is the reactor volume, u_4 is the input control action, ρ_i ($i = 1, 3, 4, 5$) are the equations which describe the rates of reaction. Those are given by

$$\rho_1 = \gamma_h \frac{S_s}{K_s + S_s} \frac{S_o}{K_{OH} + S_o} \frac{S_{NH}}{K_{NH} + S_{NH}} X_{BH} \quad (16)$$

$$\rho_3 = \gamma_a \frac{S_{NH}}{K_{NH} + S_{NH}} \frac{S_o}{K_{OA} + S_o} X_{BA} \quad (17)$$

$$\rho_4 = b_H X_{BH} \quad (18)$$

$$\rho_5 = b_A X_{BA} \quad (19)$$

where $\gamma_h = 1.019$, $\gamma_a = 0.097$, K_s is the half-saturation coefficient in fast biodegradable substrate, K_{OH} is the half-saturation coefficient in dissolved oxygen concentration for heterotrophic biomass, K_{NH} is the half-saturation coefficient of in amoniacal nitrogen, K_{OA} is the half-saturation coefficient in dissolved oxygen concentration for autotrophic biomass, b_H is the mortality coefficient of the heterotrophic biomass, b_A is the mortality coefficient of the autotrophic biomass. Finally, the conversion rates which are expressed in function of the reaction rates and the stoichiometric coefficients of all the processes taking place within the biological reactor are given by:

$$r_{S_s} = \frac{-1}{Y_H} \rho_1 + (1 - f_p) (\rho_4 + \rho_5) \quad (20)$$

$$r_{X_{BH}} = \rho_1 - \rho_4 \quad (21)$$

$$r_{X_{BA}} = \rho_3 - \rho_5 \quad (22)$$

$$r_{S_O} = -\frac{(1 - Y_H)}{Y_H} \rho_1 - \frac{(4.57 - Y_A)}{Y_A} \rho_3 \quad (23)$$

$$r_{S_{NH}} = -i_{XB} \rho_1 - \frac{(i_{XB} + 1)}{Y_A} \rho_3 \quad (24)$$

where Y_H is the substrate conversion in biomass of the heterotrophic bacteria is, Y_A is substrate conversion in biomass of the autotrophic bacteria, f_p is the chemical oxygen demand (COD) fraction, i_{XB} is nitrogen fraction in the heterotrophic biomass.

VI. IDENTIFICATION APPLICATION

To this end, neural network identification is applied to the wastewater treatment prototype presented in section V; it is assumed that all the state variables are measured. For this identification, we use a RHONN with $n=5$ as

$$\hat{x}_1(k+1) = w_{11} s^4(x_1) + w_{12} s^4(x_1) s(x_2) s(x_4) + w_{13} d_1$$

$$\hat{x}_2(k+1) = w_{21} s^5(x_2) + w_{22} s^3(x_4) s^3(x_2) s(x_1) + w_{23} s(x_2) + w_{24} d_2$$

$$\hat{x}_3(k+1) = w_{31} s^3(x_3) + w_{32} s(x_4) s(x_2) + w_{33} s(x_6) + w_{34} d_3$$

$$\hat{x}_4(k+1) = w_{41} s^4(x_1) s(x_2) s(x_4) + w_{42} s(x_5) s^2(x_2) s^4(x_4) + w_{43} u_4$$

$$\hat{x}_5(k+1) = w_{51} s^4(x_5) + w_{52} s(x_2) s^3(x_1) + w_{53} s(x_3) + w_{54} d_5$$

where x_1, x_2, x_3, x_4, x_5 correspond to the fast biodegradable substrate S_s , active heterotrophic biomass X_{BH} , active autotrophic biomass X_{BA} , oxygen S_O and amoniacal nitrogen S_{NH} , respectively. u_4 is the control action

of oxygen and d_i are the concentration of the components.

The training is performed on-line, using a serie-parallel configuration as displayed in Fig.3.




Fig.3. Identification scheme.

All the neural network states are initialized randomly. The covariance matrices are initialized as diagonal, with nonzero elements as: $P_i(0) = 60000$, $Q_i(0) = 2500$ and $R_i(0) = 4400$, ($i=1,2,3$), respectively.

VII. HYBRID INTELLIGENT CONTROL.

To control the dissolved oxygen concentration a PI-L/A controller is used [4]. In [3], it is shown that this technique is the best strategy to control the dissolved oxygen concentration in wastewater treatment aerobic plants. The main advantages of using this technique are: a) the process model is not required and b) it has a very simple structure for its implementation.

L/A Technique, as it is shown in figure 6, consists of taking the controller input variables which are in a work space with positive restriction, to a work space without this restriction by means of the logarithmic transformation; subsequently the control signal which is obtained in a work space without positive restriction is returned to the work space with restrictions by means of an exponential transformation [6].




Fig. 4 L/A Controller.

This structure is based on the following transformations

- Logarithmic transformation

$$\begin{aligned} Y(t) &= \ln y(t) \\ Y^*(t) &= \ln y^*(t) \\ U(t) &= \ln u(t) \end{aligned} \quad (25)$$

- Exponential transformation

$$\begin{aligned} y(t) &= \exp Y(t) \\ y^*(t) &= \exp Y^*(t) \\ u(t) &= \exp U(t) \end{aligned} \quad (26)$$

where $y(t)$ is the output, $y^*(t)$ is the set point, and $u(t)$ is the control action.




Fig.5 Hybrid intelligent control scheme.

The hybrid intelligent control is based on nonlinear PI controller using the scheme shown in Fig. 5. In this scheme a PI-L/A is considered to control dissolved oxygen concentration, using as manipulated variable (kla); for a detailed explanation see [13].

VIII. SIMULATION RESULTS

Simulations are implemented using Matlab/ Simulink®; two different scenarios are considered: for the first day a constant disturbance is included; then, for the next five days a variable disturbance is inserted as can be seen in Fig. 6. The model is tested with the prototype configuration and the input measurements proposed by the European group COST Action 624 [5].

To evaluate the performance of the designed controllers, we propose the following simulation conditions:

- Reference: 2 gr/m^3
- Control signal range: $0-240 \text{ l/day}$

The limits maximum and minimum in the reference of dissolved oxygen concentration are obtained analyzing the way in which the microorganism growth rate depend on dissolved oxygen concentration.

Fig. 7, Fig.8, Fig.9 and Fig.10, display each state variable and its respective identification. We can see that the identification is extremely effective and the convergence time is small.

Fig. 11 and Fig.12 display the dissolved oxygen concentration control with a PI-L/A controller and its respective control signal. We can see that the performance of the control is satisfactory even when we introduce disturbance, the dissolved oxygen concentration control continues to be acceptable.

Fig. 13, Fig. 14, Fig. 15 and Fig. 16 display each identification error.




Fig. 6. Disturbance Q_o




Fig.7. Fast biodegradable substrate (solid line) and its respective identification (dashed line).




Fig.8. Heterotrophic biomass (solid line) and its respective identification (dashed line).




Fig.9. Autotrophic biomass (solid line) and its respective identification (dashed line)




Fig.10. Ammoniacal nitrogen (solid line) and its respective identification (dashed line).




Fig.11. Dissolved Oxygen Concentration with PI-L/A controller.




Fig.12 Aeration Constant with PI-L/A controller.




Fig.13. Error identification for fast biodegradable substrate.

ACKNOWLEDGMENT

The authors thank the support of CONACYT, Mexico, on project 57801.

REFERENCES

- [1] C. Bassompierre, *Activated Sludge Method for the Treatment of Effluents Stationers: from the conception of a prototype to validation of models*, (in French), Grenoble, France, February, 2007.
- [2] C. Bassompierre and C. Cadet, J.F. Béteau, M. Arousseau, A. Guillet. "Towards an integrated co-operative supervision system for activated sludge processes optimisation", International Symposium on Advanced Control of Chemical Processes, ADCHEM'06, April 25, 2006, Gramado, Brazil.
- [3] J. F. Béteau, *An Industrial Wastewater Treatment Bioprocess Modeling and Control*, in French, Ph. D. thesis, Institut National Polytechnique de Grenoble, France, 1988.
- [4] S. Carlos-Hernández, *Control Inteligente de Plantas Anaeróbicas de Tratamiento de Aguas Residuales, Tesis de Maestría*, CINVESTAV Unidad Guadalajara, México, 2001.
- [5] J.B. Copp, "The COST Simulation benchmark: Description and Simulator Manual," *Office for official Publications of the European Communities*, Luxembourg, 2002.
- [6] M. L. Lakrori, *L/A Control Applications*, Ph.D. Thesis, in French, Institut National Polytechnique de Grenoble, France, 1989.
- [7] E.N. Sanchez and A. Y. Alanis, *Neuronal networks, fundamental concepts and application to automatic control* (in Spanish), Pearson Education, Madrid, España, 2006.
- [8] E.N. Sanchez, A.Y. Alanis and G. Chen, "Recurrent neural networks trained with Kalman filtering for discrete chaos reconstruction", *Workshop on Chaos Control and Synchronization '04*, Melbourne, Australia, July, 2004.
- [9] Y. Song and J. W. Grizzle, *The extended Kalman filter as a local asymptotic observer for discrete-time nonlinear systems*, *Journal of Mathematical Systems, Estimation and Control*, Vol. 5, No.1, pp. 59-78, Birkhauser-Boston, 1995.
- [10] D. Orhon and N. Artan, *Modeling of Activated Sludge Systems*, Technomic Publishing, Primera Edición, 1994.
- [11] G.A. Rovithakis and M.A. Christodoulou, *Adaptive Control with Recurrent High-Order Neural Network*, Springer-Verlag, Berlin, Germany, 2000.
- [12] L. J. Ricalde and E.N. Sanchez, "Inverse optimal nonlinear high order recurrent neural observe", *International Joint Conference on Neural Networks*, Montreal, Canada, August, 2005.
- [13] G. Vera, E.N. Sanchez, J.F. Béteau and C. Cadet, "Intelligent Control of an Activated Sludge Wastewater Treatment Plant" "American Control Conference 2003" ACC03, 4 - 6 June 2003, Denver (U.S.A.).




Fig.14. Error identification for heterotrophic biomass.




Fig.15. Error identification for autotrophic biomass.




Fig.16. Error identification for amoniacal nitrogen.

IX. CONCLUSIONS

In this paper, the identification and a hybrid intelligent control in a wastewater treatment prototype has been developed using a discrete-time high order neural network considering all the space states measurable and a nonlinear PI controller respectively. Simulations results show the effectiveness of the propose identification and control scheme. The proposed hybrid intelligent control gives promising guidelines to tackle in the future the problem of WWTP control.

El Jurado designado por la Unidad Guadalajara del Centro de Investigación y de Estudios Avanzados del Instituto Politécnico Nacional aprobó la tesis

Control Inteligente Híbrido para el Tratamiento de Aguas Residuales por Lodos Activados

del (la) C.

Rocío CARRASCO NAVARRO

el día 18 de Diciembre de 2009.



Dr. Edgar Nelson Sánchez Camperos
Investigador CINVESTAV 3D
CINVESTAV Unidad Guadalajara



Dr. José Javier Ruíz León
Investigador CINVESTAV 3B
CINVESTAV Unidad Guadalajara



Dr. Antonio Ramírez Treviño
Investigador CINVESTAV 3A
CINVESTAV Unidad Guadalajara



Dr. Salvador Carlos Hernández
Investigador CINVESTAV 2A
CINVESTAV Unidad Saltillo

