

Estrategia Neurodifusa para el Control de un Proceso Anaeróbico de Tratamiento de Aguas Residuales

Rubén Belmonte Izquierdo¹, Salvador Carlos Hernández², Edgar Nelson Sánchez¹,

¹ Departamento de Control Automático, CINVESTAV del IPN, Unidad Gdl.,
Av. Científica 1145, Col. El Bajío, CP. 45015, Zapopan, Jalisco, México
[rbelmonte,sanchez}@gdl.cinvestav.mx](mailto:{rbelmonte,sanchez}@gdl.cinvestav.mx)

² Grupo de Recursos Naturales Energéticos, CINVESTAV del IPN, Unidad Saltillo,
Carr. Saltillo-Mty Km. 13, CP. 25900, Ramos Arizpe, Coahuila, México
salvador.carlos@cinvestav.edu.mx

Resumen—En este artículo se propone una estrategia de control compuesta por un observador neuronal y un supervisor difuso. El observador se basa en una red neuronal recurrente de alto orden cuyo objetivo es estimar variables difíciles de medir: biomasa y sustrato, en un reactor completamente agitado. La red neuronal se entrena mediante un filtro de Kalman extendido. El supervisor difuso emplea la estimación de biomasa y la producción de metano para determinar la actividad biológica al interior del reactor, y en función de ésta, aplicar la acción de control más adecuada para evitar el lavado. Los controladores considerados son de tipo L/A (logaritmo/anti-logaritmo). La eficiencia del esquema propuesto se ilustra vía simulaciones.

Palabras clave: Observador neuronal recurrente de alto orden; digestión anaeróbica; supervisor difuso.

I. INTRODUCCIÓN

La digestión anaeróbica es uno de los métodos más eficientes para el tratamiento de aguas residuales con alta carga orgánica. Los productos derivados de la digestión anaeróbica se pueden emplear para compensar los costos del tratamiento. Sin embargo, la digestión anaeróbica es un proceso complejo y sensible a cambios en las condiciones de operación, tales como *pH*, temperatura, sobrecargas, etc. Además, algunas variables y parámetros son difíciles de medir debido a restricciones técnicas o económicas. Por tal motivo, para garantizar un funcionamiento adecuado de los procesos anaeróbicos se requieren de la estimación de variables aunado a la aplicación de estrategias de control.

En este trabajo se propone una estrategia neurodifusa de control para un proceso anaeróbico de tratamiento de aguas residuales, el cual se desarrolla en un reactor completamente agitado (CSTR: completely stirred tank reactor) que opera en modo continuo. Primero, se diseña un observador neuronal para estimar biomasa y sustrato. La principal ventaja de este observador es su alto desempeño y su estructura simple. Después, se implementa un supervisor difuso para aplicar las acciones de control (agregar una base, razón de dilución) en función de las condiciones de

operación. El supervisor se basa en un algoritmo Takagi-Sugeno y requiere de las variables: carga orgánica diaria por unidad de biomasa (ODL/X_2) e incremento en la producción de metano (ΔQCH_4).

II. DIGESTIÓN ANAERÓBICA

La digestión anaeróbica es un proceso biológico natural a través del cual las moléculas complejas de materia orgánica (sustrato) son degradadas por varios grupos de microorganismos (biomasa) en ausencia de oxígeno. Además del agua tratada, se produce un biogás constituido principalmente de metano (CH_4) y dióxido de carbono (CO_2), así como una cantidad mínima de residuos orgánicos estables.

Descripción del proceso

La digestión anaeróbica es un proceso secuencial que ocurre en cuatro etapas: hidrólisis, acidogénesis, acetogénesis y metanogénesis. En cada etapa se tiene una dinámica específica; las primeras tres presentan una dinámica rápida en comparación con la metanogénesis, que es la más lenta. Esta fase impone la dinámica global del proceso y se considera la etapa limitante.

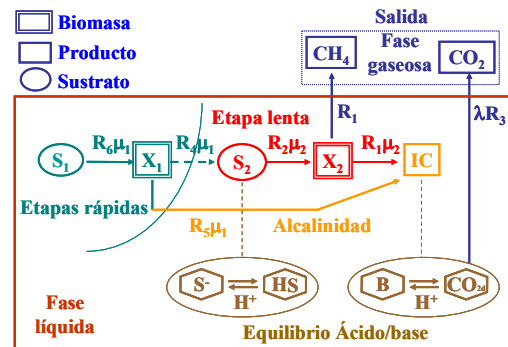


Figura 1. Diagrama funcional de la digestión anaeróbica.

Un diagrama funcional propuesto en (Rozzi, 1984) para la digestión anaeróbica se muestra en la Figura 1. La biomasa se clasifica en X_1 , que corresponde a las bacterias hidrolíticas, acidogénicas y acetogénicas; y X_2 , que

corresponde a las bacterias metanogénicas. Por otra parte, la carga orgánica se clasifica en S_1 , que modela las moléculas complejas y S_2 , que representa las moléculas que son transformadas en ácido acético.

A partir del diagrama funcional se deduce un modelo matemático que consta de un conjunto de cinco ecuaciones algebraicas que modelan los fenómenos físico-químicos (equilibrio ácido-base y conservación de la materia), un conjunto de seis ecuaciones diferenciales ordinarias que modelan los fenómenos biológicos y dos ecuaciones para la fase gaseosa (CH_4 y CO_2) que se considera como la salida del proceso. El modelo general resultante tiene la forma:

$$\begin{aligned} 0 &= g(x_a, x_d), \\ \dot{x}_d &= f(x_a, x_d, u), \\ y &= h(x_a, x_d), \end{aligned} \quad (1)$$

con:

$$\begin{aligned} x_a &= [HS \quad H^+ \quad S^- \quad CO_{2d} \quad B]^T, \\ x_d &= [X_1 \quad S_1 \quad X_2 \quad S_2 \quad IC \quad Z]^T, \\ u &= [S_{1in} \quad S_{2in} \quad IC_{in} \quad Z_{in} \quad D_{in}]^T, \end{aligned} \quad (2)$$

donde HS es el ácido acético no ionizado (mol/L), H^+ es el ión hidrógeno (mol/L), S^- es el ácido acético ionizado (mol/L), CO_{2d} es el dióxido de carbono disuelto (mol/L), B es el bicarbonato medido (mol/L), IC es el carbono inorgánico (mol/L), Z es el total de cationes (mol/L), S_{1in} es la entrada de sustrato rápidamente degradable (mol/L), S_{2in} es la entrada de sustrato lentamente degradable (mol/L), IC_{in} es la entrada de carbono inorgánico (mol/L), Z_{in} es la entrada de cationes (mol/L) y D_{in} es la tasa de dilución (h^{-1}).

La validación experimental del modelo matemático (1) se puede encontrar en (Béteau, 1992; Otton, 1998; Soehartanto, 1999; Carlos-Hernández *et al*, 2009). En este artículo, dicho modelo se utiliza para validar el esquema de control propuesto.

Problemática de medición de variables

La producción de metano, el crecimiento de biomasa y la degradación de sustrato son buenos indicadores de la actividad biológica al interior del reactor. Tales variables se pueden emplear para monitorear el proceso y para diseñar estrategias de control. Actualmente existen sensores comerciales de biogás para medir la producción de metano en los bioprocesos (Bluesens, 2009). Sin embargo, tanto la biomasa como el sustrato son más restrictivos. Por un lado, los sensores de biomasa son de alto costo y se diseñan desde un punto de vista de la Biología, presentando poca factibilidad para propósitos de Control. Por otra parte, la medición de sustrato se hace fuera de línea mediante análisis químicos que requieren al menos de dos horas, este retraso dificulta el empleo del sustrato en estrategias de control.

Los observadores de estado son una alternativa interesante para enfrentar esta problemática, ya que permiten estimar variables no disponibles a partir de mediciones de

las señales de entradas y salidas.

Problemática de control

Tras realizar un análisis global del modelo matemático mediante retratos de fase, se concluye que el proceso tiene dos regiones de operación asociadas a dos puntos de equilibrio (ambos estables): lavado y funcionamiento. Este último es deseable y el otro no; dado que hay trayectorias que conducen al sistema hacia el lavado, se requiere lo siguiente para evitarlo: a) un sistema de supervisión que detecte la evolución del sistema y b) acciones de control que se apliquen cuando una trayectoria este yendo al lavado para mantener al sistema en la región de operación del punto de funcionamiento. La idea principal es desarrollar acciones de control eficientes y fáciles de implementar.

III. OBSERVADOR NEURONAL PARA ESTIMACIÓN DE VARIABLES DE UN PROCESO ANAERÓBICO

Los observadores neuronales son una estrategia interesante que minimiza los problemas asociados a los observadores basados en el modelo del sistema. Los observadores neuronales requieren de mediciones factibles de salidas y entradas; y de un algoritmo de entrenamiento con la finalidad de aprender la dinámica del proceso. Las ventajas de este observador son que el conocimiento del modelo no es estrictamente necesario (Ponznnyak *et al*, 2001; Ricalde y Sanchez, 2005; Urrego-Patorrogo *et al*, 2008), su alto desempeño, la robustez ante presencia de incertidumbres, además del bajo nivel de complejidad en la implementación.

Se propone un observador neuronal discreto (RHONO: recurrent high order neural observer) para estimar biomasa y sustrato (X_2 y S_2). La estimación de X_2 será utilizada en la estrategia de control (sección IV); la estimación de S_2 podrá ser empleada para validaciones experimentales en proyectos futuros.

Estructura y algoritmo de entrenamiento

La estructura del RHONO se muestra en la Figura 2 y se basa en el diseño propuesto en (Sanchez *et al*, 2008). Donde $x \in \mathbb{R}^n$ es el vector de estados del sistema, $u \in \mathbb{R}^m$ es el vector de entrada, $y \in \mathbb{R}^p$ es el vector de salida, C es una función no lineal de los estados del sistema, $d(k) \in \mathbb{R}^n$ es el vector de perturbación, $e(k)$ es el error de la salida y $F(\bullet, \bullet)$ es un vector de campo suave.

El RHONO se basa en una red neuronal recurrente de alto orden (RHONN: recurrent high order neural network) cuyas funciones de activación son del tipo antisimétricas. La RHONN se entrena mediante un filtro de Kalman extendido (EKF: extended Kalman filter) dado que este método provee una solución computacional eficiente para estimar los estados de un sistema dinámico no lineal con estados aditivos y salidas con ruido blanco (Song y Grizzle, 1995).

Además, se supone que las mediciones de pH , Q_{CH_4} , Q_{CO_2} y las entradas del sistema están disponibles.

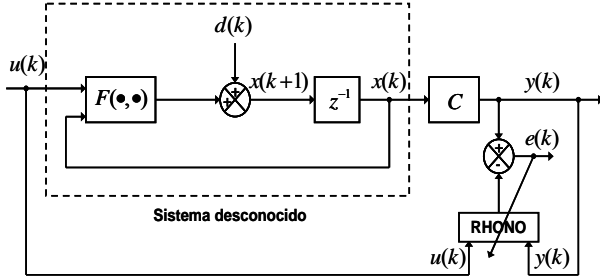


Figura 2. Esquema de observación.

La estructura del RHONO se muestra en (3):

$$\begin{aligned} \hat{X}_2(k+1) &= w_{11}S(\hat{X}_2(k)) + w_{12}S^2(\hat{X}_2(k)) \\ &\quad + w_{13}S(IC(k)) + w_{14}S^2(\hat{X}_2(k))D_m(k) + g_1e(k), \\ \hat{S}_2(k+1) &= w_{21}S(\hat{S}_2(k)) + w_{22}S^2(\hat{S}_2(k)) \\ &\quad + w_{23}S(IC(k)) + w_{24}S^2(\hat{S}_2(k))D_m(k) \\ &\quad + w_{25}S^2(\hat{S}_2(k))S_{2m}(k) + g_2e(k), \end{aligned} \quad (3)$$

con las salidas dadas por:

$$\hat{Q}_{CH_4} = R_1R_3\hat{\mu}_2(k)\hat{X}_2(k), \quad (4)$$

$$\hat{Q}_{CO_2} = \hat{\lambda}(k)R_2R_3\hat{\mu}_2(k)\hat{X}_2(k). \quad (5)$$

donde w_i es el respectivo vector de pesos adaptado en línea, $g_i \in \mathbb{R}^p$ es el i -ésimo vector de ganancia tipo Luenberger del observador, $e(k)$ es el error de salida, μ_2 es la tasa de crecimiento específico de los microorganismos metanogénicos dependiente de \hat{S}_2 , $\hat{\lambda}$ es un coeficiente que considera la ley de presión parcial para el CO_2 y depende de IC , y $R_1 \dots R_3$ son coeficientes de rendimiento producto/biomasa.

Teorema 1. Para el sistema discreto de (1) el RHONO (3), entrenado con el algoritmo basado en el EKF, asegura que el error de estimación de estado y el error de salida $e(k)$ sean semiglobalmente uniformemente últimamente acotados (SGUUB: semiglobally uniformly ultimately bounded); además, los pesos del RHONO permanecen acotados. La demostración de este teorema se hace en (Sanchez *et al*, 2008).

Como se muestra en (3), el observador propuesto tiene una configuración paralela. El entrenamiento del RHONO se hace en línea. Se emplea la tangente hiperbólica como función de activación:

$$S(x) = \alpha \tanh(\beta x), \quad (6)$$

con $\alpha = \beta = 1$. Se emplea (6) puesto que las funciones antisimétricas permiten un aprendizaje más rápido de la dinámica en comparación con otras funciones de activación (Sanchez y Alanís, 2006).

Sintonización

La mayor dificultad en este tipo de observadores es encontrar la estructura que estime adecuadamente los estados. Una vez que se tiene dicha estructura, se debe sintonizar para lograr la mayor eficiencia del observador. A continuación se muestra un procedimiento a fin de sintonizar el observador propuesto.

Las matrices de covarianza se inicializan como diagonales y deben cumplir con la desigualdad:

$$P_i(0) > R_i(0) > Q_i(0). \quad (7)$$

Esta condición implica que no se requiere un conocimiento *a priori* para inicializar el vector de pesos (Haykin, 2001). Dado que los valores de entrada elevados en $P_i(0)$ corresponden a una incertidumbre mayor en el conocimiento *a priori*, es recomendable seleccionar $P_i(0)$ en un valor en el rango 100-1000 y así sucesivamente para las otras matrices de covarianza pero respetando (7). Así, las matrices de covarianza para el filtro de Kalman se inicializan como matrices diagonales, cuyos elementos diferentes de cero son:

$$\begin{aligned} P_1(0) = P_2(0) = P_3(0) &= 1000, \\ R_1(0) = R_2(0) &= 10, \quad R_3(0) = 1, \end{aligned} \quad (8)$$

$$Q_1(0) = Q_2(0) = 1, \quad Q_3(0) = 0.1.$$

Se puede aplicar un escalamiento arbitrario a $P_i(0)$, $R_i(0)$ y $Q_i(0)$ sin alterar la evolución del vector de pesos. Dado que las salidas de la red neural no dependen directamente del vector de pesos, la matriz H se inicializa $H(0) = 0$.

Se supone que los valores de los pesos se inicializan en valores aleatorios pequeños con media cero y distribución normal. La razón de aprendizaje (η) determina la magnitud del término de corrección aplicado para ajustar los pesos de las neuronas cuando se entrena. Usualmente requiere de valores pequeños para lograr un buen entrenamiento, para ello, se acota en $0 < \eta < 1$; además, la razón de aprendizaje tiene una gran repercusión en la convergencia del observador, por consiguiente, se recomienda asignarle un valor pequeño e incrementarlo gradualmente si es necesario. Más detalles respecto al ajuste de los parámetros se abordan en (Haykin, 2001).

La ganancia tipo Luenberger (g_i) del observador, con $g_i \in \mathbb{R}^p$ se ajusta por prueba y error. Hay pocos fundamentos científicos claros que permitan definirla; sin embargo, se acota en $0 < g_i < 0.1$ para un buen funcionamiento en base a la experiencia de entrenamiento. La acotación de g_i , bajo un enfoque de Lyapunov, está establecida en (Sanchez *et al*, 2008).

Resultados

El modelo del proceso y el observador neuronal se implementan en Matlab/Simulink®. Se prueba la tolerancia del observador a los cambios en los parámetros del sistema; los parámetros que se alteran son las tasas de crecimiento de las biomazas μ_{1max} y μ_{2max} . Se consideran una variación positiva de 30% en μ_{2max} , una variación negativa de 30% en

μ_{1max} y una perturbación de 100% en la entrada S_{2in} . El funcionamiento del RHONO se ilustra en la Figura 3. Se observa con claridad que tanto la biomasa como el sustrato se estiman adecuadamente desde el inicio de la simulación. Así, se verifica la robustez del RHONO propuesto a la variación de parámetros, el análisis teórico para la comprobación de este hecho se encuentra en (Sanchez *et al*, 2008).




Figura 3. Funcionamiento del observador neuronal considerando una variación en μ_{1max} , μ_{2max} y una perturbación en la entrada S_{2in} .

IV. SUPERVISOR DIFUSO PARA UN PROCESO ANAERÓBICO

Se propone un esquema de control para la digestión anaeróbica que permite elegir la acción de control más apropiada en función de las condiciones de operación del sistema. Las ventajas que presenta el esquema propuesto son las siguientes: a) combina ventajas de diferentes acciones de control, b) se hace una reconfiguración en línea de la estrategia en comparación con (Soehartanto, 2009), c) rechazo de perturbaciones de gran magnitud en comparación con acciones de control individuales y d) producción de metano elevada.

Las acciones de control son generadas por un controlador L/A, que es la técnica más apropiada para procesos anaeróbicos (Lakrori, 1989; Béteau, 1992), ya que ofrece ventajas como: a) Toma en cuenta las restricciones físicas del proceso (positividad) y la saturación de los actuadores y b) No requiere del conocimiento del modelo matemático del proceso.

Operación en lazo abierto

Se sabe por conocimiento empírico que la digestión anaeróbica es capaz de trabajar en presencia de perturbaciones pequeñas. Sin embargo, ante perturbaciones mayores, se requiere de una acción de control para mantener la estabilidad del proceso.

Acción de control: agregar una base

El agregar una base, *e.g.* bicarbonato, es una de las acciones frecuentemente utilizadas. Esta acción permite la regulación del *pH* a un nivel deseado en la zona óptima para la actividad biológica, favoreciendo la producción de metano. La técnica L/A (Lakrori, 1989; Béteau, 1991, Béteau, 1992) se adapta para la acción agregar una base como:

$$b_{inc_k} = (b_{inc_{k-1}} - b_{inc_{min}}) \left(\frac{B_{k-1}}{B_k} \right)^{K_p} \left(\frac{B^*}{B_k} \right)^{K_i} + b_{inc_{min}} \quad (9)$$

Las ganancias se calculan de la siguiente manera:

$$K_p = \alpha K_i,$$

$$K_i = \frac{1}{1 + \alpha} \frac{\ln \left(\frac{b_{inc_{max}} - b_{inc_{min}}}{-b_{inc_{min}}} \right)}{\ln \left(\frac{B^*}{B^* - \Delta} \right)}, \quad (10)$$

donde α y Δ son los parámetros de regulación, $b_{inc_{max}}$ y $b_{inc_{min}}$ representan la saturación de los actuadores (Soehartanto, 1999), y B^* es el valor deseado de bicarbonato (mol/L). Las perturbaciones de amplitud grande no pueden compensarse por esta vía, por lo que se requiere de otra acción de control.

Acción de control: razón de dilución

Esta acción permite que las variables biológicas puedan rechazar perturbaciones de gran magnitud. Sin embargo, la desventaja de esta acción es que la producción de metano se reduce debido al decremento en la tasa de dilución. La técnica L/A se adapta para la acción razón de dilución como:

$$D_k = D_{k-1} \left(\frac{B_{k-1}}{B_k} \right)^{K_{pd}} \left(\frac{B^*}{B_k} \right)^{K_{id}} \quad (11)$$

Las ganancias se calculan con:

$$K_{pd} = \alpha_D K_{id},$$

$$K_{id} = \frac{1}{1 + \alpha_D} \frac{\ln \left(\frac{D_{max}}{D^*} \right)}{\ln \left(\frac{B^*}{B^* + \Delta_D} \right)}, \quad (12)$$

donde α_D , Δ_D , y D_{max} son los parámetros de regulación (Soehartanto, 1999), B^* es el valor deseado de bicarbonato (mol/L) y D^* es la tasa de dilución en equilibrio (h^{-1}).

Supervisor difuso: Takagi-Sugeno

Con la finalidad de obtener, al mismo tiempo, las ventajas de las técnicas de control antes descritas, se emplea un supervisor difuso basado en un algoritmo Takagi-Sugeno (Takagi y Sugeno, 1985; Tanaka y Wang, 2001), que permite la combinación de las tres acciones dependiendo de la evolución del sistema. Dicho supervisor emplea dos variables: ODL/X_2 y ΔQCH_4 . Mediante la combinación de estas acciones de control se obtiene una mejor operación frente a perturbaciones en la entrada.

La ODL/X_2 es la cantidad de carga orgánica que una unidad de biomasa puede tratar en un día de trabajo y su importancia radica en que permite conocer los límites de operación del proceso. La ODL/X_2 se define como:

$$ODL_{\hat{X}_2} = \frac{D_k A_2 S_{2,0}}{\hat{X}_2}, \quad (13)$$

donde D_k es la tasa de dilución (h^{-1}), A_2 es la amplitud de la

perturbación en el sustrato de entrada (mol/L), $S_{2,0}$ es el valor inicial del sustrato S_{2in} (mol/L) y \hat{X}_2 es el valor estimado de X_2 (UA).

En presencia de una perturbación en S_{2in} , la ODL/X_2 puede incrementarse abruptamente a un valor que excede las condiciones de los límites de estabilidad (valor crítico); por consiguiente el proceso tiende al lavado. Si ODL/X_2 está sobre su valor crítico entonces se debe aplicar una acción de control que permita el crecimiento de la biomasa y por lo tanto, disminuir el valor de ODL/X_2 y rechazar la perturbación. Por el contrario, si está debajo de su valor crítico, entonces el sistema puede operar en lazo abierto. Dependiendo del valor de ODL/X_2 , la conmutación entre los modos de operación (lazo abierto, acción b_{inc} , acción D) se realiza mediante un supervisor Takagi-Sugeno. Dicha conmutación es progresiva para evitar comportamientos oscilatorios provocados por una conmutación abrupta. Los conjuntos difusos se definen como se muestra en la Figura 4.




Figura 4. Conjuntos difusos para la variable ODL/X_2 .

Por otra parte, ΔQCH_4 permite tener una idea de la amplitud de la perturbación y a partir de esto se pueda decidir la acción de control a aplicar. El ΔQCH_4 se define como:

$$\Delta QCH_4 = QCH_4 - QCH_{4,eq}, \quad (14)$$

donde QCH_4 es la producción de metano (mol/h) y $QCH_{4,eq}$ es la producción de metano en el punto de equilibrio (mol/h). Los conjuntos difusos para ΔQCH_4 se definen como muestra la Figura 5.

Los límites de los conjuntos difusos se obtienen haciendo pruebas, independientemente, de las acciones de control y de los modos de operación de la digestión anaeróbica.




Figura 5. Conjuntos difusos para la variable ΔQCH_4 .

Resultados

El esquema de control propuesto se implementa en Matlab/Simulink®. Se considera una perturbación típica, un escalón sobre S_{2in} con amplitud $A_2 = 0.5$ (incremento de 50% en S_{2in}), el cual se introduce en $t = 200$ horas. El funcionamiento de la estrategia propuesta se ilustra en la Figura 6. Se puede observar que el valor de ΔQCH_4

pertenece al conjunto difuso BAJO, mientras que ODL/X_2 pertenece al conjunto BAJO. Ambos conjuntos difusos están asociados al modo de operación correspondiente al lazo abierto. Esto implica que la variación corresponde a una perturbación pequeña; por lo tanto, no se requiere una acción de control. Así, el supervisor permite una operación en lazo abierto (b_{inc} y D mantienen sus valores de equilibrio durante toda la simulación); en consecuencia, X_2 y B presentan un comportamiento típico de lazo abierto.




Figura 6. Funcionamiento de la estrategia neurodifusa para una perturbación pequeña sobre S_{2in} .

Por otra parte, se introduce un escalón sobre S_{2in} con amplitud $A_2 = 2.5$ (incremento de 250% en S_{2in}), en $t = 200$ horas. El funcionamiento de la estrategia propuesta se observa en la Figura 7. Cuando ocurre la perturbación, ΔQCH_4 incrementa su valor hasta pertenecer al conjunto difuso ALTO, el cual es asociado al modo de operación en lazo cerrado. ODL/X_2 adquiere un nivel de pertenencia al conjunto ALTO; esto implica que la perturbación es grande y el proceso requiere la acción de control D . El supervisor permite la aplicación de dicha acción, con lo que X_2 y B presentan un comportamiento de lazo cerrado. Conforme la acción se aplica, ΔQCH_4 mantiene su pertenencia al conjunto ALTO (lazo cerrado) mientras que ODL/X_2 disminuye su valor hasta pertenecer al conjunto MEDIO, el cual está asociado a la acción b_{inc} . En ese momento la acción D se detiene y se aplica la acción b_{inc} . En respuesta a esta situación, X_2 y B disminuyen su valor cuando D se detiene; cuando b_{inc} se aplica X_2 y B vuelven a crecer hasta llegar a un nuevo punto de equilibrio. También puede advertirse un incremento en la producción de metano gracias al efecto de la acción b_{inc} . Finalmente, ΔQCH_4 sale del conjunto ALTO y llega al BAJO (lazo abierto) mientras que ODL/X_2 disminuye su valor hasta pertenecer al conjunto BAJO (lazo abierto). Esta situación implica que la perturbación ha sido rechazada completamente. Bajo esas condiciones, el supervisor detiene la acción b_{inc} y el proceso vuelve a su operación en lazo abierto.




Figura 7. Funcionamiento de la estrategia neurodifusa para una perturbación grande sobre S_{2in} .

Haciendo una comparación cualitativa, se puede concluir que la estrategia propuesta es más fácil de diseñar con respecto a otras, tales como las descritas en (Holubar *et al*, 2002; Baruch *et al*, 2008) puesto que no se requiere una identificación del sistema ni de sistemas de control adaptable. Además, se obtiene un alto desempeño.

V. CONCLUSIONES

Por un lado, se propone un RHONO entrenado con un EKF. El objetivo es estimar la concentración de biomasa y la degradación de sustrato en un proceso de digestión anaeróbica considerando un CSTR con filtro de biomasa que opera en modo continuo. El entrenamiento del RHONO se hace en línea. Las variables se estiman a partir de las razones de flujo de metano y dióxido de carbono, las entradas del sistema y la medición de pH . Los resultados en simulación ilustran la efectividad y la robustez del RHONO propuesto. Por otro lado, se propone un esquema de control para un proceso anaeróbico de tratamiento de aguas para evitar el lavado. El supervisor difuso detecta la actividad biológica al interior del reactor basándose en la biomasa estimada y aplica una acción de control. Los resultados en simulación ilustran la eficiencia de la estrategia de control propuesta. Como trabajo futuro se contempla la formalización en la selección de los límites de los conjuntos difusos y la implementación en tiempo real del esquema propuesto. Así las aportaciones del artículo son: a) diseño y validación de un nuevo observador, b) integración del observador en una estrategia de control que cumple diferentes objetivos a la vez (rechazo de perturbaciones, producción elevada de metano).

Finalmente, la dinámica del proceso es muy lenta en comparación con el tiempo de cálculo de la tecnología informática actual, por lo que el tiempo de muestreo no representa un problema crítico. Uno de los objetivos del

esquema es minimizar el efecto del retraso en la medición de variables como el sustrato, mediante el observador.

VI. AGRADECIMIENTOS

Este trabajo está financiado por el proyecto CONACYT 57801Y.

REFERENCIAS

- Baruch, I. S., Galvan-Guerra R. y Nenkova, B. (2008). Centralized Indirect Control of an Anaerobic Digestion Bioprocess Using Recurrent Neural Identifier. *Lecture Notes in Computer Science*, pp. 297-310, Springer-Verlag, Berlin, Germany.
- Béteau, J. F. *et al* (1991). Bioprocess control: an original approach taking into account some bioprocess constraints, *American Control Conference*, Boston, USA.
- Béteau, J. F. (1992). *Modeling and control of an Industrial Bioprocess for municipal waste treatment*, in French, Ph. D. Thesis, INPG, France.
- Bluesens (2009). <http://www.bluesens.de/>
- Carlos-Hernández, S. *et al* (2004). Fuzzy Observer for the anaerobic digestion process. *Proceedings of IFAC Symposium on Structures Systems and Control*, Oaxaca, Mexico.
- Carlos-Hernández, S., Sanchez, E. N. y Beteau, J.F. (2009). Fuzzy observers for anaerobic WWTP: Development and implementation. *Control Engineering Practice*, vol. 17 pp.690-702.
- Haykin, S. (2001). *Kalman Filtering and Neural Networks*, John Wiley & Sons, N.Y., USA.
- Holubar, P., *et al* (2002). Advanced controlling of anaerobic digestion by means of hierarchical neural networks. *Water Research*, vol. 36 pp. 2582-2588.
- Lakrori, M. (1989). *L/A command applications*, in French, Ph. D. Thesis, INPG, France.
- Otton, V. (1998). *Modeling and analysis of a distributed parameters Process: Study of the Anaerobic Digestion in a Fluidized bed reactor*, in French, Ph. D. Thesis, INPG, France.
- Poznyak, A.S., Sanchez, E. N. y Yu, W. (2001). *Differential Neural Networks for Robust Nonlinear Control*. World Scientific Publishing Co., Singapore.
- Ricalde, L. J. y Sanchez, E. N. (2005). Inverse optimal nonlinear high order recurrent neural observer. *International Joint Conference on Neural Networks*, Montreal, Canada.
- Rozzi, A. (1984). Modelling and control of anaerobic digestion process. *Transactions Instrumentation, Modelling and Control*, vol. 6, no. 3, pp.153-159.
- Sanchez, E.N. y Alanis, A.Y. (2006). *Redes Neuronales: conceptos fundamentales y aplicaciones a control automático*, Pearson Education, Madrid, España.
- Sanchez, E. N., Alanis, A. Y. y Loukianov, A. G. (2008). *Discrete Time High Order Neural Control Trained with Kalman Filtering*. Springer-Verlag, Germany.
- Soehartanto, T. (1999). *Stability analysis and control of wastewater treatment processes*, in French, Ph. D. Thesis, INPG, France.
- Song Y. y Grizzle, J. W. (1995). 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.
- Takagi, T. y Sugeno, M. (1985). M. Fuzzy identification of systems and its applications to modeling and control. *IEEE Transactions on Systems, Man and Cybernetics*, vol. 15, no. 1, pp. 116-132.
- Tanaka, K. y Wang, H.O. (2001). *Fuzzy Control Systems, Design and Analysis*. John Wiley, New Jersey, USA.
- Urrego-Patarroyo, D. *et al* (2008). Recurrent Neural Networks Observer for Anaerobic Processes. *XIII Latin-American Congress of Automatic Control*, Mérida, Venezuela.