

Control Neuronal Óptimo inverso con Gradiente de Velocidad para Regular la Producción de Metano en un Proceso de Digestión Anaeróbica

K. J. Gurubel¹, E. N. Sánchez¹, S. Carlos-Hernández² y F. Ornelas¹

¹Departamento de Control Automático, CINVESTAV del IPN, Unidad Guadalajara, Av. Del Bosque 1145, Col. El Bajío, CP. 45019, Zapopan, Jalisco, México
 {kgurubel,sanchez,ornelas}@gdl.cinvestav.mx

²Grupo 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 un control neuronal óptimo inverso con gradiente de velocidad para seguimiento de trayectorias es aplicado a un proceso de digestión anaeróbica. La ley de control calcula la razón de dilución y la cantidad de bicarbonato requeridos, para seguir una trayectoria de referencia de producción de metano bajo condiciones controladas y evitar el lavado. Un observador neuronal no lineal en tiempo discreto (RHONO) es usado para estimar la concentración de biomasa, degradación de sustrato y carbono inorgánico. Este observador está basado en una red neuronal recurrente de alto orden en tiempo discreto (RHONN) entrenado con un algoritmo de filtro de Kalman extendido (FKE); esto permite la aplicabilidad del control neuronal óptimo inverso con gradiente de velocidad. La aplicabilidad del esquema propuesto es ilustrada vía simulación.

Palabras clave: Observador neuronal de alto orden, digestión anaeróbica, control neuronal óptimo inverso con gradiente de velocidad

I. INTRODUCCIÓN

La digestión anaeróbica es un proceso biológico en el cual la materia orgánica (sustrato) es degradada por las bacterias anaeróbicas (biomasa), en ausencia de oxígeno. Tal degradación produce biogás, que consiste en metano (CH_4), dióxido de carbono (CO_2), y residuos orgánicos estables. Los procesos anaeróbicos son muy atractivos debido a sus características de tratamiento de desechos y su capacidad para generar metano de los materiales de desecho, que se puede utilizar para la generación de energía eléctrica (Roos, 1991). El proceso anaeróbico es un proceso complejo y secuencial que ocurre en cuatro etapas básicas: Hidrólisis, Acidogénesis, Acetogénesis y Metanogénesis (Belmonte-Izquierdo *et al.*, 2009). Cada etapa tiene una dinámica específica; la hidrólisis, la acidogénesis y la acetogénesis son etapas rápidas en comparación con la metanogénesis, que es la más lenta; esta fase impone la dinámica del proceso y se considera la etapa limitante. Hay dos maneras para sintetizar

el metano; la primera por la división del ácido acético, que produce CH_4 y CO_2 ; y la segunda por la reducción del CO_2 con el hidrógeno, que genera el CH_4 y H_2O . La reacción del acetato es el principal productor de CH_4 , debido a la cantidad de hidrógeno disponible en este proceso (Monnet, 2003). Por lo tanto, la fase de metanogénesis es la más importante. Este proceso se desarrolla en un reactor continuo de tanque agitado (RCTA) con filtro de biomasa. Una variedad de factores afectan a la velocidad de digestión y a la producción del biogás, tal como pH, temperatura, sobrecargas, etc. Un resumen comparativo detallado de la investigación sobre la inhibición de procesos anaeróbicos es presentado en (Chen *et al.*, 2007). Además, algunas variables y parámetros son difíciles de medir debido a problemas económicos o técnicos. Entonces, se requieren estrategias de estimación y control para garantizar un desempeño adecuado. En procesos biológicos existen variables difícilmente medibles o no medibles que son necesarias para el control de proceso (Carlos-Hernandez *et al.*, 2004). Por lo tanto, el diseño de un observador es un problema importante que debe de ser resuelto, en adición a la adecuada selección de sensores. Diversos sensores de biogás se han desarrollado para medir el CH_4 . Sin embargo, las mediciones de sustrato y la biomasa son más restrictivas. Un observador neuronal no lineal en tiempo discreto para sistemas no lineales desconocidos en presencia de perturbaciones externas e incertidumbre de parámetros es propuesto en (Belmonte-Izquierdo *et al.*, 2009; Sanchez *et al.*, 2008). Este observador se basa en una RHONN entrenada con un algoritmo de FKE. El objetivo es estimar la concentración de biomasa, la degradación del sustrato y el carbono inorgánico en el proceso anaeróbico. El entrenamiento del RHONO se realiza en línea. Las variables son estimadas de los flujos de CH_4 y de CO_2 , medidos comúnmente en este proceso. Se supone que el pH, producción de CH_4 (Y_{CH_4}), producción de CO_2 (Y_{CO_2}) y las entradas del proceso son medidos en línea. En las últimas dos décadas se ha visto un creciente interés en mejorar la operación de bioprocesos aplicando esquemas de control avanzados (Alcaraz-Gonzalez *et al.*, 2007; Yamuna

Rani y Ramachandra Rao, 1999). Para controlar el proceso anaeróbico, en este artículo, un controlador neuronal óptimo inverso con gradiente de velocidad es considerado; este controlador es desarrollado sobre la base del observador neuronal mencionado. La meta del controlador es seguir una trayectoria de referencia de Y_{CH_4} y evitar la inhibición del proceso anaeróbico. Un diagrama funcional de un proceso de digestión anaeróbica es propuesto en (Beteau, 1992) como se muestra en la fig. 1.




Fig. 1 Diagrama funcional de la digestión anaeróbica.

La biomasa está clasificada como: 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 , la glucosa equivalente de los componentes, que modela las moléculas complejas y S_2 , el ácido acético equivalente de los componentes, que representan las moléculas transformadas directamente en ácido acético. Esta clasificación permite que el proceso sea representado por una etapa rápida, que implica la hidrólisis, acidogénesis y acetogénesis y una etapa lenta, que corresponde principalmente a la metanogénesis. Así, un modelo matemático del proceso es deducido como sigue. Por un lado, el fenómeno biológico es modelado por ecuaciones diferenciales ordinarias (1), que representa la parte dinámica del proceso como:

$$\begin{aligned}
 \frac{dX_1}{dt} &= (\mu_1 - k_{d1})X_1, \\
 \frac{dS_1}{dt} &= -R_6\mu_1X_1 + D_{in}(S_{1in} - S_1), \\
 \frac{dX_2}{dt} &= (\mu_2 - k_{d2})X_2, \\
 \frac{dS_2}{dt} &= -R_3\mu_2X_2 + R_4\mu_1X_1 + D_{in}(S_{2in} - S_2), \\
 \frac{dIC}{dt} &= R_2R_3\mu_2X_2 + R_5\mu_1X_1 - \lambda R_1R_3\mu_2X_2 + \\
 &\quad D_{in}(IC_{in} - IC), \\
 \frac{dZ}{dt} &= D_{in}(Z_{in} - Z)
 \end{aligned} \tag{1}$$

donde μ_1 es la razón de crecimiento (tipo Haldane) de X_1 (h⁻¹), μ_2 es la razón de crecimiento (tipo Haldane) de X_2 (h⁻¹), k_{d1} el índice de mortalidad de X_1 (mol L⁻¹), k_{d2} el índice de mortalidad de X_2 (mol L⁻¹), D_{in} la razón de dilución (h⁻¹), S_{1in} la entrada del sustrato rápidamente

degradable (mol L⁻¹), S_{2in} la entrada del sustrato lentamente degradable (mol L⁻¹), IC carbono inorgánico (mol L⁻¹), Z el total de cationes (mol L⁻¹), IC_{in} la entrada de carbono inorgánico (mol L⁻¹), Z_{in} la entrada de cationes (mol L⁻¹), λ es un coeficiente que considera la ley de la presión parcial para el CO_2 disuelto, y R_1, \dots, R_6 son los coeficientes de producción. Por otro lado, el fenómeno físico-químico (equilibrio ácido-base y conservación de la materia) son modelados por ecuaciones algebraicas (2).

$$\begin{aligned}
 HS + S^- - S_2 &= 0, \\
 H^+ S^- - K_a HS &= 0, \\
 H^+ B - K_b CO_{2d} &= 0, \\
 B + CO_{2d} - IC &= 0, \\
 B + S^- - Z &= 0,
 \end{aligned} \tag{2}$$

donde HS es el ácido acético no ionizado (mol L⁻¹), S^- es el ácido acético ionizado (mol L⁻¹), H^+ es el hidrógeno ionizado (mol L⁻¹), B es el bicarbonato medido (mol L⁻¹), CO_{2d} es el dióxido de carbono disuelto (mol L⁻¹), K_a es una constante de equilibrio ácido-base, K_b es una constante de equilibrio entre B y CO_{2d} . Finalmente, la fase gaseosa (CH_4 y CO_2) es considerada como la salida de proceso:

$$Y_{CH_4} = R_1 R_2 \mu_2 X_2 \tag{3}$$

$$Y_{CO_2} = \lambda R_2 R_3 \mu_2 X_2 \tag{4}$$

El crecimiento de la biomasa, la degradación del sustrato y Y_{CH_4} , son buenos indicadores de actividad biológica dentro del reactor. Esas variables pueden ser usadas para monitorear el proceso y para diseñar el control neuronal óptimo inverso con gradiente de velocidad.

II. RHONO

El RHONO en tiempo discreto estima las variables de la etapa de la metanogénesis: biomasa (X_2), sustrato (S_2) y carbono inorgánico (IC). La propiedad de observabilidad del modelo del proceso anaeróbico es analizado en un trabajo previo (Alcaraz-Gonzalez y Gonzalez-Alvarez, 2007). En la Fig. 2, se despliega el esquema propuesto del observador y la estructura del RHONO es mostrada en las ecuaciones (5).




Fig. 2 Esquema del observador

$$\begin{aligned}
 \hat{X}_{2,k+1} &= w_{11}S(\hat{X}_{2,k}) + w_{12}S^2(\hat{X}_{2,k}) + w_{13}S(IC_k) \\
 &\quad + w_{14}S^2(\hat{X}_{2,k})D_{in,k} + w_{15}S^2(\hat{X}_{2,k})IC_{in,k} + g_1e_k, \\
 \hat{S}_{2,k+1} &= w_{21}S(\hat{S}_{2,k}) + w_{22}S^2(\hat{S}_{2,k}) + w_{23}S(IC_k)
 \end{aligned}$$

IV. CONTROL NEURONAL ÓPTIMO INVERSO CON GRADIENTE DE VELOCIDAD

Considere un sistema no lineal en tiempo discreto afin como

$$(5) \quad x_{k+1} = f(x_k) + g(x_k)u_k \quad (7)$$

donde $x_k \in R^n$ es el estado del sistema al tiempo $k \in Z_+$, $u \in R^m$ es el control de entrada, $f: R^n \rightarrow R^n$, $g: R^n \rightarrow R^{n \times m}$ son funciones de mapeo suaves. Se asume $f(0)=0$ y $\text{rango}\{g\} = m \quad \forall x_k \neq 0$. En (Ornelas, 2011), se propone una función de Lyapunov para control en tiempo discreto para asegurar estabilidad del sistema (7), como

$$V_c(x_k) = \frac{1}{2} x_k^T P_k x_k, \quad P_k = P_k^T > 0 \quad (8)$$

Empleando esta función en la ley de control, queda de la siguiente forma

$$u_k^* = -\frac{1}{2} \left(R(x_k) + \frac{1}{2} g^T(x_k) P_k g(x_k) \right)^{-1} g^T(x_k) P_k f_d(x_k) \quad (9)$$

P_k y R son matrices definidas positivas y simétricas; así la existencia de la inversa en (9) es asegurada. Para computar P_k , que asegure estabilidad del sistema (7) con (9), usaremos el algoritmo gradiente de velocidad. La ley de control (9) depende de la matriz P_k en cada paso de tiempo. Definimos la matriz P_k en cada paso de tiempo k como:

$$P_k = p_k P' \quad (10)$$

Donde $P' = P'^T > 0$ es una matriz constante dada y p_k es un parámetro escalar a ser ajustado por el algoritmo gradiente de velocidad. Entonces (9) es transformado en:

$$u_k^* = -\frac{p_k}{2} \left(R(x_k) + \frac{p_k}{2} g^T(x_k) P' g(x_k) \right)^{-1} g^T(x_k) P' f_d(x_k). \quad (11)$$

La variación dinámica del parámetro p_k dado en (10) es calculada como:

$$P_{k+1} = p_k + 8\gamma_{d,k} \frac{f_d^T(x_k) P' g(x_k) R(x_k)^2 g^T(x_k) f_d^T(x_k)}{(2R(x_k) + p_k g^T(x_k) P' g(x_k))^3} \quad (12)$$

que es positiva para todo paso de tiempo k si $p_0 > 0$. Por lo tanto la positividad de p_k es asegurada y el requerimiento $P_k = P_k^T > 0$ para (8) es garantizado. Además, con la función de Lyapunov definida por (8) y $p_k = \bar{p}$ (\bar{p} es un valor constante cuando el algoritmo gradiente de velocidad concluye), la ley de control (11) es óptima inversa en el sentido de que minimiza la variedad funcional dada como

$$J = \sum_{k=0}^{\infty} (l(x_k) + u_k^T R(x_k) u_k) \quad (13)$$

donde w_{ij} es el respectivo vector de pesos adaptado en línea; \hat{X}_2, \hat{S}_2 y $\hat{I}C$ son los estados estimados; $S(\bullet)$ es la función sigmoideal definida como $S(x) = \alpha \tanh(\beta x)$; (g_1, g_2, g_3) son las ganancias Luenberger del observador, e_k es el error de salida, D_{in}, S_{2in} y IC_{in} son definidas como antes.

III. ALGORITMO DE ENTRENAMIENTO FKE

El algoritmo FKE se ha introducido para entrenar a la red neuronal mejorando la convergencia de aprendizaje. Puesto que la función de transformación de la red neuronal es no lineal, se requiere un algoritmo basado en el FKE. La meta del entrenamiento es encontrar los valores de los pesos óptimos, que minimizan el error de predicción. Más detalles son presentados en (Sanchez *et al*, 2006, 2008). Un algoritmo de entrenamiento basado en el FKE es descrito por (6).

$$(6) \quad \begin{aligned} w_{i,k+1} &= w_{i,k} + \eta_i K_{i,k} e_{i,k}, \\ K_{i,k} &= P_{i,k} H_{i,k} M_{i,k}, \\ P_{i,k+1} &= P_{i,k} - K_{i,k} H_{i,k}^T P_{i,k} + Q_{i,k}, \\ i &= 1, \dots, n, \end{aligned}$$

with :

$$M_{i,k} = \left[R_{i,k} + H_{i,k}^T P_{i,k} H_{i,k} \right]^{-1}$$

donde $e_{i,k} = y_k - \hat{y}_k$, \hat{y}_k es la salida de la red neuronal, η_i es la razón de aprendizaje, $K_{i,k} = P_{i,k} H_{i,k}$ es la matriz de ganancia de Kalman, $Q_{i,k} = P_{i,k} R_{i,k} P_{i,k}^T$ es la matriz de covarianza del ruido de estimación, $R_{i,k} = R^{p \times p}$ es la covarianza del ruido de medición, y $H_{i,k} = R^{L_i \times p}$ es la matriz en la que cada entrada (H_{ij}) es la derivada de la i -ésima salida neuronal con respecto al ij -ésimo peso de la red (w_{ij}). Donde $i = 1, \dots, n$ y $j = 1, \dots, L_i$. Usualmente P_i, Q_i y R_i son inicializadas como matrices diagonales, con entradas $P_i(0), Q_i(0)$ y $R_i(0)$ respectivamente. Es importante comentar que $H_{i,k}, K_{i,k}$ y $P_{i,k}$ para el FKE son acotados (Song y Grizzle, 1995).

V. RHONO COMO SISTEMA AFIN

El RHONO es presentado como un sistema afín con el propósito de aplicar el control neuronal óptimo inverso con gradiente de velocidad. La ecuación (14) muestra las ecuaciones f y g del sistema afín. La ecuación (15) muestra las ecuaciones en forma matricial y el vector de trayectorias de referencia f_{ref} .

$$\begin{aligned}
 f_1(\hat{X}_{2,k}, \hat{IC}_k) &= w_{11}S(\hat{X}_{2,k}) + w_{12}S^2(\hat{X}_{2,k}) + w_{13}S(\hat{IC}_k) + g_1e_k, \\
 G_{11}(\hat{X}_{2,k}) &= w_{14}S^2(\hat{X}_{2,k}) \quad G_{12}(\hat{X}_{2,k}) = w_{14}S^2(\hat{X}_{2,k}) \\
 f_2(\hat{S}_{2,k}, \hat{IC}_k) &= w_{21}S(\hat{S}_{2,k}) + w_{22}S^2(\hat{S}_{2,k}) + w_{23}S(\hat{IC}_k) \\
 &\quad + w_{25}S^2(\hat{S}_{2,k})S_{2in,k} + g_2e_k, \\
 G_{21}(\hat{S}_{2,k}) &= w_{24}S^2(\hat{S}_{2,k}) \\
 f_3(\hat{X}_{2,k}, \hat{IC}_k) &= w_{31}S(\hat{IC}_k) + w_{32}S^2(\hat{IC}_k) + w_{33}S(\hat{X}_{2,k}) + g_3e_k \\
 G_{31}(\hat{IC}_k) &= +w_{34}S^2(\hat{IC}_k) \quad G_{32}(\hat{IC}_k) = w_{35}S^2(\hat{IC}_k)
 \end{aligned} \tag{14}$$

$$\begin{aligned}
 g(x_k) &= \begin{bmatrix} G_{11} & G_{12} \\ G_{21} & 0 \\ G_{31} & G_{32} \end{bmatrix} \quad P' = \begin{bmatrix} P_{11} & P_{12} & P_{13} \\ P_{21} & P_{22} & P_{23} \\ P_{31} & P_{32} & P_{33} \end{bmatrix} \\
 f(x_k) &= \begin{bmatrix} f_1 \\ f_2 \\ f_3 \end{bmatrix} \quad P_k = p_k P' \quad R = 0.6 \\
 f_{ref}(x_{\delta,k+1}) &= \begin{bmatrix} X_{2ref} \\ S_{2ref} \\ IC_{ref} \end{bmatrix} \quad f_d(x_k) = f(x_k) - f_{ref}(x_{\delta,k+1})
 \end{aligned} \tag{15}$$

VI. RESULTADOS DE SIMULACIÓN

El modelo del proceso anaeróbico y el observador son implementados usando Matlab/M-file™. El observador es inicializado en valores aleatorios para verificar la convergencia de estimación. Para probar la sensibilidad del observador en cambios de la entrada, una perturbación del 50% en el sustrato de entrada S_{2in} es insertada en $t = 200$ horas. También, una variación de parámetros en las tasas de crecimiento de las biomazas es considerada: una variación positiva del 30% en μ_{2max} y variación negativa del 30% en μ_{1max} . El desempeño del RHONO propuesto es ilustrado en las Fig. 3, Fig. 4 y Fig. 5. Está claro que la biomasa, sustrato y el carbono inorgánico son bien estimados desde el principio. Así, el observador neuronal propuesto es una buena alternativa para estimar los estados importantes del proceso anaeróbico considerado.




Fig. 3 Estimación de biomasa X_2




Fig. 4 Estimación de sustrato S_2




Fig. 5 Estimación de carbono inorgánico IC

El algoritmo de control neuronal óptimo inverso requiere trayectorias de referencia para forzar al sistema a seguirlas. Las trayectorias de referencia propuestas fueron tomadas en (Belmonte-Izquierdo *et al*, 2009), como resultados obtenidos de un sistema controlado ante una máxima perturbación en el sustrato de entrada S_{2in} . El algoritmo de control es probado ante una perturbación en S_{2in} del 200% en $t=200$ h, como se muestra en la Fig. 6.




Fig. 6 Perturbación en S_{2in}

El desempeño de seguimiento, los errores de seguimiento y las señales de control son desplegados en Fig. 7, Fig. 8, Fig. 9, Fig. 10, Fig. 11 y Fig. 12.

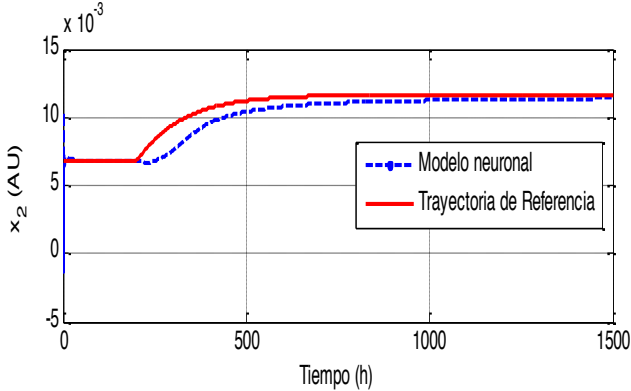


Fig. 7 Desempeño de seguimiento para X_2

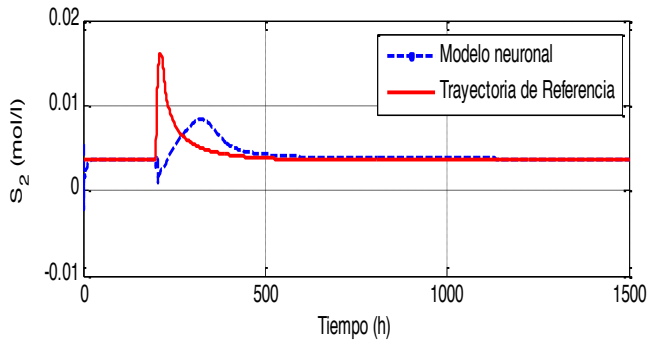


Fig. 8 Desempeño de seguimiento para S_2

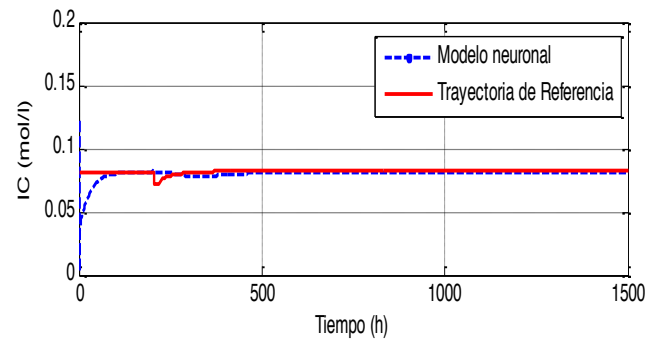


Fig. 9 Desempeño de seguimiento para IC

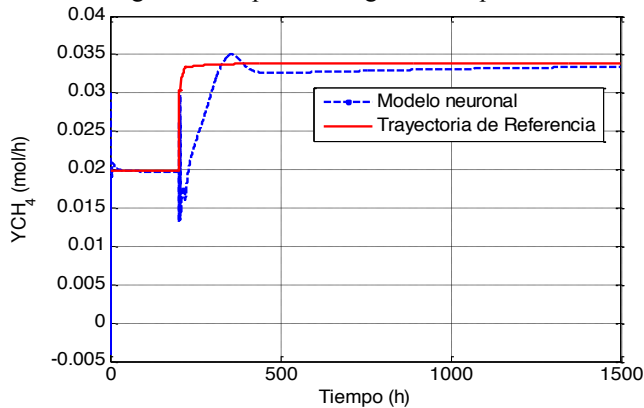


Fig. 10 Desempeño de seguimiento para YCH_4







Fig. 11 Errores de seguimiento





Fig. 12 Señales de control

La Fig. 6, la Fig. 7 y la Fig. 8 ilustran el desempeño de seguimiento para la biomasa, el sustrato y el carbono inorgánico respectivamente. Como se puede ver el seguimiento de trayectorias es eficiente y el error se acerca a cero en el estado estable. Los errores de seguimiento son desplegados en Fig. 10. Estos errores podrían ser debidos a la estructura simple del observador; es posible que la red neuronal no sea capaz de aprender la dinámica no lineal relacionada con las variables y también es posible que las ganancias de la ley de control necesiten ser ajustadas. La Fig. 9 ilustra el desempeño del seguimiento de la producción de metano. La producción de metano es calculada con la ecuación (3) que está en función de los estados observados del sistema, por lo cual el error en el seguimiento es debido al error de seguimiento de los estados observados del

sistema. La Fig. 11 muestra las señales de control para las entradas B y D_{in} .

VII. CONCLUSIONES

En este artículo un observador neuronal recurrente de alto orden no lineal en tiempo discreto (RHONO) es empleado para estimar la concentración de biomasa, degradación del sustrato y carbono inorgánico. Se basa en una red neuronal recurrente de alto orden en tiempo discreto entrenada con un algoritmo basado en un filtro de Kalman extendido (FKE). Un modelo matemático afin es obtenido con el propósito de aplicar control neuronal óptimo inverso con gradiente de velocidad. Una vez obtenido el modelo neuronal, una ley de control óptimo inverso, basada en este modelo, es desarrollado. La meta es forzar al sistema para seguir señales de referencia deseadas, que es alcanzado diseñando una ley de control como fue descrito en la sección IV. Los resultados en simulación ilustran que el controlador propuesto asegura estabilización y seguimiento de trayectorias de un sistema no lineal y minimiza una variedad funcional de costo. El seguimiento de trayectorias con el controlador propuesto es novedoso para el modelo de digestión anaeróbica descrito en este artículo. Como trabajo futuro se determinarán trayectorias de referencia óptimas para la producción de metano.

AGRADECIMIENTOS

Este trabajo está financiado por el proyecto CONACyT 131678.

REFERENCIAS

- Alanis, A. Y. *et al* (2011). Real-Time Recurrent Neural State Estimation. *IEEE Transactions on, Neural Networks*, no.99, pp. 1-9.
- Alcaraz-Gonzalez, V. y Gonzalez- Alvarez, V. (2007). *Robust nonlinear observers for Bioprocesses: Application to wastewater treatment* (Book Chapter in Selected Topics in Dynamics and Control of Chemical and Biological Processes), pp. 119–164, Springer-Verlag, Berlin, Germany.
- Bastin, G. y Dochain, D. (1990). *On-Line Estimation and Adaptive Control of Bioreactors*. Elsevier Science Publications, Amsterdam.
- Belmonte-Izquierdo, R. (2009). Estimación de Estado y Control Inteligente de Procesos Anaeróbicos de Tratamiento de Aguas Residuales. M.S. dissertation, Cinvestav, Unidad Guadalajara, Guadalajara, Jalisco, México,.
- Belmonte-Izquierdo, R., Carlos-Hernandez, S. y Sanchez, E. N. (2010). A new neural observer for an anaerobic bioreactor. *International Journal of Neural Systems*, Vol. 20, No. 1, pp. 75–86.
- Belmonte-Izquierdo, R., Carlos-Hernandez, S. y Sanchez, E. N. (2009). A new neural observer for an anaerobic wastewater treatment process. *Advances in Computational Intell.*, AISC 61, pp. 123–132. Springer-Verlag, Berlin, Germany.
- Belmonte-Izquierdo, R., Carlos-Hernandez, S. y Sanchez, E. N. (2009). Hybrid intelligent control scheme for an anaerobic wastewater treatment process. *Advances in Computational Intell.*, AISC 61, pp. 249–258. Springer-Verlag, Berlin, Germany.
- Beteau, J. F. (1992). *An industrial wastewater treatment bioprocess modeling and control*, in French, Ph. D. Thesis, INPG, France.
- Carlos-Hernandez, S. (2005). Integrated intelligent control strategy for wastewater treatment plants by anaerobic digestion. Ph. D. Thesis, INPG, France.
- Carlos-Hernandez, S., Mallet, G. y Beteau, J. F. (2004). Modeling and analysis of the anaerobic digestion process, in *Proceedings of IFAC Symposium on Structures Systems and Control*, Oaxaca, Mexico.
- Carlos-Hernandez, S., Sanchez, E. N. y Beteau, J. F. (2009). Fuzzy observers for anaerobic WWTP: Development and implementation, in *Control Engineering Practice*, vol. 17, no. 6, pp. 690–702.
- Chen, Y., Cheng, J. J. y Creamer, K. S. (2007). Inhibition of anaerobic digestion process: A review, in *Bioresource Technology*, vol. 99 no. 10, pp. 4044–4064.
- Giraldo-Gomez, E. y Duque, M. (1998). Automatic startup of a high rate anaerobic reactor using a fuzzy logic control system, in *Fifth Latin-American Workshop-Seminar in Wastewater Anaerobic Treatment*, Viña del Mar, Chile.
- Méndez-Acosta, H. O. *et al* (2005). A Robust Feedforward/Feedback Control for an Anaerobic Digester, *Computers & Chemical Engineering*, Vol. 29, pp. 1613-1623.
- Méndez-Acosta, H. O. *et al* (2004). Improving the Performance on the Chemical Oxygen Demand Regulation in Anaerobic Digestion, *Industrial & Engineering Chemistry Research*, Vol. 43, pp. 95-104.
- Monnet, F. (2003). An Introduction to Anaerobic Digestion of Organic Wastes. Technical, Report Remade Scotland.
- Muller, A. *et al* (1997). Fuzzy control of disturbances in a wastewater treatment process, in *Water Research*, vol. 31, no. 12, pp. 3157–3167.
- Ornelas, F. *et al* (2011). Speed-Gradient Inverse Optimal control for Discrete-Time Nonlinear Systems, 50th IEEE Conference on Decision and Control and European Control Conference (IEEE CDC-ECC 2011), Orlando, Florida. (Accepted paper)
- Ricalde, L. J. y Sanchez, E. N. (2005). Inverse optimal nonlinear high order recurrent neural observer, *International Joint Conference on Neural Networks*, Montreal, Canada.
- Roos, K. F. (1991). Profitable alternatives for regulatory impacts on livestock waste management, in National Livestock, Poultry and Aquacultural Waste Management National Workshop, USDA Extension Service, Kansas, MI.
- Rozzi, A. (1984). Modelling and control of anaerobic digestion process. *Modelling and Control*, in *Transactions Instrumentation*, vol. 6, no. 3, pp. 153–159.
- Sanchez, E. N., Alanis, A. Y. y Chen, G. R. (2006). Recurrent neural networks trained with the Kalman filtering for discrete chaos reconstruction. *Dyn. Continuous Discrete Impulsive Syst. B*, vol. 13c, pp. 1–18.
- Sanchez, E. N., Alanis, A. Y. y Loukianov, A. G. (2008). *Discrete Time High Order Neural Control Trained with Kalman Filtering*, Springer-Verlag, Germany.
- Song, Y. y Grizzle, J. W. (1995). The extended Kalman filter as a local asymptotic observer for discrete-time nonlinear systems, in *Journal of Mathematical Systems, Estimation and Control*, vol. 5, no. 1, pp. 59–78.
- Theilliol, D. *et al* (2003). On-line estimation of unmeasured inputs for anaerobic wastewater treatment processes”, in *Control Engineering Practice*, vol. 11, no. 9, pp. 1007–1019.
- Yamuna Rani, K. y Ramachandra Rao, V.S. (1999). Control of fermenters, *Bioprocess Engineering*, no. 21, pp. 77–78, Springer-Verlag, Germany.