

Control Híbrido Inteligente Neuronal Óptimo Inverso con Gradiente de Velocidad para Producción de Metano en un Proceso Anaeróbico

K. J. Gurubel¹, E. N. Sánchez¹, F. Ornelas-Tellez² y S. Carlos-Hernández³

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

²División de Estudios de Posgrado, Facultad de Ingeniería Eléctrica, UMSNH, F.J. Mujica SN, Ciudad Universitaria, Morelia, Michoacán, México 58030.
fornelast@gmail.com

³Grupo 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—Los procesos de digestión anaeróbica son muy atractivos por sus propiedades de tratamiento de materiales de desecho y su capacidad para generar metano que puede ser usado como fuente de energía renovable. Un control inteligente híbrido para un proceso anaeróbico es propuesto en este artículo. La ley de control calcula la razón de dilución y la adición de bicarbonato necesarios para forzar al sistema a seguir una trayectoria de referencia de producción de metano. Un observador neuronal no lineal recurrente de alto orden en tiempo discreto es propuesto para estimar la concentración de biomasa, sustrato y carbón inorgánico. La estrategia de control usa la biomasa estimada y un supervisor Takagi-Sugeno que detecta el estado del proceso, selecciona y aplica la acción de control más adecuada, permitiendo un cambio suave entre las acciones lazo abierto a lazo cerrado. La aplicabilidad del esquema propuesto es ilustrada vía simulación.

Palabras clave: Observador neuronal de alto orden, digestión anaeróbica, producción de metano, control híbrido inteligente

I. INTRODUCCIÓN

Motivados por el rápido crecimiento de la demanda de electricidad, en vista del agotamiento de combustibles fósiles, y debido a la conciencia ambiental creciente, los países desarrollados comenzaron a investigar la posibilidad de usar fuentes de energía renovable eficientemente. En los últimos años, con diversos grados de éxito, diversas fuentes de energía renovable continúan siendo estudiadas para la generación de energía eléctrica, entre ellos, geotérmico, biomasa, solar, viento, hidroelectricidad por las micro-turbinas y las ondas de marea. La investigación sobre la optimización de la generación de la energía en los sistemas híbridos que utilizan diversas fuentes renovables es discutida por (Liang *et al*, 2007 y Marwali *et al*, 1998). La biomasa es atractiva como recurso energético potencial, y es un

combustible importante en varios países en vías de desarrollo. Hay diversas razones de utilización de la biomasa como fuente de energía. Una de ellas es que la cantidad de fuentes tradicionales del petróleo para los combustibles convencionales no es ilimitada, mientras que la biomasa es potencialmente renovable. Otra razón es que sustituyendo los combustibles fósiles por la biomasa reduciría las emisiones netas del dióxido de carbono que están contribuyendo al calentamiento global. Por otra parte, los combustibles de biomasa tienen un calor de combustión razonable, y generalmente tienen contenido bajo de sulfuro, de nitrógeno y de ceniza con respecto a muchos carbones y aceites. La biomasa se puede convertir en una variedad de formas de energía incluyendo calor, vapor, electricidad, hidrógeno, etanol, metanol y metano (Roos, 1991). 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 (CH₄), dióxido de carbono (CO₂), y residuos orgánicos estables. 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. 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). Diferentes sensores de biogás han sido desarrollados para medir CH₄. No obstante las mediciones de biomasa y el sustrato son más restrictivos. Por lo tanto un observador neuronal no lineal de alto orden en tiempo discreto (RHONO) para sistemas no lineales desconocidos en presencia de perturbaciones externas e incertidumbre de parámetros es propuesto (Belmonte-Izquierdo *et al*, 2009; Sanchez *et al*, 2008). Este observador se basa en una red neuronal recurrente de alto orden (RHONN) entrenada con un algoritmo de filtro de Kalman extendido (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 CH₄ y de CO₂, medidos comúnmente en este proceso. Se asume que el pH, producción de CH₄ (YCH₄), producción de CO₂ (YCO₂) 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 es propuesto un controlador híbrido inteligente neuronal óptimo inverso con gradiente de velocidad; este controlador es desarrollado sobre la base del observador neuronal mencionado. El controlador es diseñado para regular el bicarbonato en el reactor por dos acciones: el abastecimiento de una base (b_{inc}) y la razón de dilución (D). Un supervisor difuso es implementado para aplicar dichas acciones de control para rechazar perturbaciones grandes en el sustrato de entrada y para seguir una trayectoria de referencia de producción de metano. Un supervisor Takagi-Sugeno (Takagi, 1985 y Tanaka *et al*, 2001) detecta el estado del proceso, selecciona y aplica la acción del control más adecuada, permitiendo una conmutación suave entre el lazo abierto y el lazo cerrado. El supervisor mejora el funcionamiento del proceso anaeróbico y es factible para procesos en tiempo real, puesto que el esquema de control demuestra un buen compromiso entre la eficiencia y la complejidad.

I. MODELO MATEMÁTICO

Un diagrama funcional de la digestión anaeróbica es propuesta por (Beteau, 1992) como se muestra en la figura 1. 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.

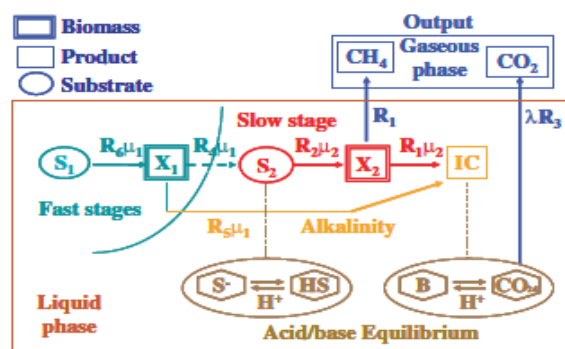


Fig. 1 Diagrama funcional de la digestión anaeróbica.

Así, un modelo matemático no lineal en tiempo discreto del proceso es deducido como sigue. El fenómeno biológico es modelado por ecuaciones en diferencias (1), que representa la parte dinámica del proceso como:

$$\begin{aligned}
 X_{1,k+1} &= X_{1,k} + (\mu_{1,k} - k_{d1})X_{1,k}, \\
 S_{1,k+1} &= S_{1,k} - R_6\mu_{1,k}X_{1,k} + \\
 &\quad D_{in,k}(S_{1in,k} - S_{1,k}), \\
 X_{2,k+1} &= X_{2,k} + (\mu_{2,k} - k_{d2})X_{2,k}, \\
 S_{2,k+1} &= S_{2,k} - R_3\mu_{2,k}X_{2,k} + \\
 &\quad R_4\mu_{1,k}X_{1,k} + D_{in,k}(S_{2in,k} - S_{2,k}), \\
 IC_{k+1} &= IC_k + R_2R_3\mu_{2,k}X_{2,k} + \\
 &\quad R_5\mu_{1,k}X_{1,k} - \lambda_k R_1 R_3\mu_{2,k}X_{2,k} + \\
 &\quad D_{in,k}(IC_{in,k} - IC_k), \\
 Z_{k+1} &= Z_k + D_{in,k}(Z_{in,k} - Z_k),
 \end{aligned} \tag{1}$$

donde μ_1 es la razón de crecimiento (tipo Haldane) de X_1 (1/h), μ_2 es la razón de crecimiento (tipo Haldane) de X_2 (1/h), k_{d1} el índice de mortalidad de X_1 (mol/L), k_{d2} el índice de mortalidad de X_2 (mol/L), D_{in} la razón de dilución (1/h), S_{1in} la entrada del sustrato rápidamente degradable (mol/L), S_{2in} la entrada del sustrato lentamente degradable (mol/L), IC carbono inorgánico (mol/L), Z el total de cationes (mol/L), IC_{in} la entrada de carbono inorgánico (mol/L), Z_{in} la entrada de cationes (mol/L), λ es un coeficiente que considera la ley de la presión parcial para el CO₂ disuelto, y R_1, \dots, R_6 son los coeficientes de producción. La fase gaseosa (CH₄ y CO₂) es considerada como la salida de proceso:

$$Y_{CH_4} = R_1 R_2 \mu_2 X_2 \tag{2}$$

$$Y_{CO_2} = \lambda R_2 R_3 \mu_2 X_2 \tag{3}$$

El crecimiento de la biomasa, la degradación del sustrato y YCH₄, son buenos indicadores de actividad biológica y pueden ser usadas para diseñar el control neuronal óptimo inverso con gradiente de velocidad.

II. OBSERVADOR NEURONAL EN TIEMPO DISCRETO

En este artículo, proponemos usar un RHONO en tiempo discreto que estima las variables de la etapa de

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). La estructura del RHONO es mostrada en las ecuaciones (4).

$$\begin{aligned}\hat{X}_{2,k+1} &= w_{11}S\left(\hat{X}_{2,k}\right) + w_{12}S^2\left(\hat{X}_{2,k}\right) + w_{13}S\left(\hat{IC}_k\right) \\ &+ w_{14}S^2\left(\hat{X}_{2,k}\right)D_{in,k} + w_{15}S^2\left(\hat{X}_{2,k}\right)IC_{in,k} + g_1e_k, \\ \hat{S}_{2,k+1} &= w_{21}S\left(\hat{S}_{2,k}\right) + w_{22}S^2\left(\hat{S}_{2,k}\right) + w_{23}S\left(\hat{IC}_k\right) \\ &+ w_{24}S^2\left(\hat{S}_{2,k}\right)D_{in,k} + w_{25}S^2\left(\hat{S}_{2,k}\right)S_{2in,k} + g_2e_k, \\ \hat{IC}_{k+1} &= w_{31}S\left(\hat{IC}_k\right) + w_{32}S^2\left(\hat{IC}_k\right) + w_{33}S\left(\hat{X}_{2,k}\right) \\ &+ w_{34}S^2\left(\hat{IC}_k\right)D_{in,k} + w_{35}S^2\left(\hat{IC}_k\right)IC_{in,k} + g_3e_k,\end{aligned}\quad (4)$$

donde w_{ij} es el respectivo vector de pesos adaptado en línea; \hat{X}_2, \hat{S}_2 y \hat{IC} 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 (5).

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

con :

$$\begin{aligned}M_{i,k} &= \left[R_{i,k} + H_{i,k}^T P_{i,k} H_{i,k} \right]^{-1} \\ e_{i,k} &= y_k - \hat{y}_k,\end{aligned}\quad (5)$$

donde $e_{i,k} \in R^p$ es el error de observación, $P_{i,k} \in R^{L_i \times L_i}$ es la matriz de covarianza del error de predicción en el paso k , $w_{i,k} \in R^{L_i}$ es el vector de pesos (estados), L_i es el numero respectivo de pesos de la red, y $\epsilon \in R^p$, es la salida de la planta, $\hat{y} \in R^p$ es la salida de la red neuronal, η_i es la razón de aprendizaje, $K_{i,k} \in R^{L_i \times p}$ es la matriz de ganancia de Kalman, $Q_{i,k} \in R^{L_i \times L_i}$ es la matriz de covarianza del ruido de estimación, $R_{i,k} \in R^{p \times p}$ es la covarianza del ruido de medición, y $H_{i,k} \in R^{L_i \times p}$ es la matriz en la que cada entrada (H_{ij}) es la derivada de la 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_{i0}, Q_{i0} y R_{i0} respectivamente. Es importante comentar que $H_{i,k}, K_{i,k}$ y $P_{i,k}$ para el FKE son acotados (Song y Grizzle, 1995).

IV. CONTROL NEURONAL ÓPTIMO INVERSO CON GRADIENTE DE VELOCIDAD

Considere un sistema no lineal en tiempo discreto afín como

$$x_{k+1} = f(x_k) + g(x_k)u_k \quad (6)$$

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 (6), como

$$V_c(x_k) = \frac{1}{2} x_k^T P_k x_k, \quad P_k = P_k^T > 0 \quad (7)$$

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

$$u_k^* = -\frac{1}{2} \left(R(x_k) + \frac{1}{2} g^T(x_k) P_k g(x_k) \right)^{-1} g^T(x_k) P_k f_d(x_k) \quad (8)$$

P_k y R son matrices definidas positivas y simétricas; así la existencia de la inversa en (8) es asegurada. Para computar P_k , que asegure estabilidad del sistema (6) con (8), usaremos el algoritmo gradiente de velocidad. La ley de control (8) depende de la matriz P_k en cada paso de tiempo. Definimos la matriz P_k en cada paso de tiempo k como:

$$P_k = p_k P' \quad (9)$$

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 (8) es transformado en:

$$u_k^* = -\frac{p_k}{2} \left(R(x_k) + \frac{p_k}{2} g^T(x_k) P' g(x_k) \right)^{-1} g^T(x_k) P' f_d(x_k). \quad (10)$$

La variación dinámica del parámetro p_k dado en (9) es calculada como:

$$P_{k+1} = p_k + 8\gamma_{d,k} \frac{f_d^T(x_k) P' g(x_k) R(x_k)^2 g^T(x_k) f_d^T(x_k)}{(2R(x_k) + p_k g^T(x_k) P' g(x_k))^3} \quad (11)$$

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 (7) es garantizado. Además, con la función de Lyapunov definida por (7) y $p_k = \bar{p}$ (\bar{p} es un valor constante cuando el algoritmo gradiente de velocidad concluye), la ley de control (10) es óptima inversa en el sentido de que minimiza la variedad funcional dada como

$$J = \sum_{k=0}^{\infty} (l(x_k) + u_k^T R(x_k) u_k). \quad (12)$$

El RHONO es presentado como un sistema afín con el propósito de aplicar el control neuronal óptimo inverso con gradiente de velocidad. Definimos las siguientes vectores:

$$\begin{aligned} g_1(\hat{x}_k) &= \begin{bmatrix} G_{11} \\ G_{21} \\ G_{31} \end{bmatrix} & g_2(\hat{x}_k) &= \begin{bmatrix} G_{12} \\ G_{22} \\ G_{32} \end{bmatrix} \\ f(\hat{x}_k) &= \begin{bmatrix} f_1 \\ f_2 \\ f_3 \end{bmatrix} & f_{ref}(x_{\delta,k+1}) &= \begin{bmatrix} X_{2ref} \\ S_{2ref} \\ IC_{ref} \end{bmatrix} \end{aligned} \quad (13)$$

donde los vectores g_1 y g_2 representan la parte del modelo neuronal que acompañan a las entradas de control u_{k-D} y u_{k-binc} respectivamente, f representa la parte del modelo neuronal donde no parece el termino de control y f_{ref} las trayectorias de referencia deseadas. De acuerdo a (8) la ley de control óptima inversa es formulada como

$$\begin{aligned} u_{k-D}^* &= -\frac{1}{2} \left(R(\hat{x}_k) + \frac{1}{2} g_1^T(\hat{x}_k) P_k g_1(\hat{x}_k) \right)^{-1} \times \\ &\quad g_1^T(\hat{x}_k) P_k g_1(\hat{x}_k) f(\hat{x}_k, x_{\delta,k+1}) \\ u_{k-binc}^* &= -\frac{1}{2} \left(R(\hat{x}_k) + \frac{1}{2} g_2^T(\hat{x}_k) P_k g_2(\hat{x}_k) \right)^{-1} \times \\ &\quad g_2^T(\hat{x}_k) P_k g_2(\hat{x}_k) f(\hat{x}_k, x_{\delta,k+1}). \end{aligned}$$

Donde la matriz definida positiva $P_k = p_k P^1$ es calculada por el algoritmo gradiente de velocidad, $R(\hat{x}_k)$ es una matriz contante, $f(\hat{x}_k)$ y $g(\hat{x}_k)$ son vectores como en (13) y $f(\hat{x}_k, x_{\delta,k+1}) = f(\hat{x}_k) - f_{ref}(x_{\delta,k+1})$.

El seguimiento de una trayectoria deseada, definido en términos de los estados de la planta $X_{i,k}$ formulado como en (1) puede ser establecido como la siguiente desigualdad:

$$\|X_{i,\delta} - X_{i,k}\| \leq \|X_{i,k} - \hat{x}_{i,k}\| + \|X_{i,\delta} - \hat{x}_{i,k}\| \quad (14)$$

Donde $\|\cdot\|$ representa la norma euclidea, $\hat{x}_{i,k}$ es el estado observado, $X_{i,\delta}$ es la señal de trayectoria deseada suave y acotada. Esta proposición es posible basada en el principio de separación para un sistema no lineal en tiempo discreto (Lin *et al*, 1994). De (14), establecemos los siguientes requerimientos para el seguimiento de la red neuronal y la solución del control:

Requerimiento 1:

$$\lim_{t \rightarrow \infty} \|X_{i,k} - \hat{x}_{i,k}\| \leq \zeta_i \quad (15)$$

con ζ_i una constante pequeña positiva.

Requerimiento 2:

$$\lim_{t \rightarrow \infty} \|X_{i,\delta} - \hat{x}_{i,k}\| = 0. \quad (16)$$

Un observador neuronal entrenado con el FKE basado en (4) asegura (15) (Sanchez *et al*, 2006), mientras (16) es garantizado por un controlador discreto desarrollado usando control óptimo inverso.

V. CONTROL INTELIGENTE HÍBRIDO

El proceso anaeróbico es capaz de trabajar adecuadamente sin control en presencia de pequeñas perturbaciones. No obstante, para perturbaciones grandes es requerida una ley de control para mantener el proceso estable. Entonces, la supervisión de variables clave es una tarea importante. El ODL/X_2 es la cantidad de carga orgánica que una unidad de biomasa puede tratar en un día de trabajo y es importante para la estabilidad del proceso (Carlos-Hernandez *et al*, 2004). Es definido como:

$$ODL / X_2 = D_k A_2 S_{20} / \hat{X}_2 \quad (17)$$

donde D_k es la razón de dilución (1/h), A_2 la amplitud de la perturbación en el sustrato de entrada S_{2in} (mol/L), S_{20} el valor inicial del sustrato S_2 (mol/L) y \hat{X}_2 es la biomasa estimada X_2 (mol/L). En presencia de una perturbación sobre S_{2in} , ODL/X_2 puede incrementar abruptamente a un valor, que excede los límites de estabilidad (valor crítico); por lo tanto el proceso tiende al lavado o inestabilidad del sistema. Si ODL/X_2 está cerca de su valor crítico entonces una ley de control debe ser aplicada para permitir el crecimiento de la biomasa, y por lo tanto, disminuir ODL/X_2 y estabilizar el sistema. En contraste, si ODL/X_2 está debajo de su valor crítico el sistema puede trabajar en lazo abierto. Dependiendo del valor de ODL/X_2 , la conmutación entre los modos de operación (lazo abierto, lazo cerrado) es hecho por un supervisor difuso Takagi-Sugeno. Esta conmutación toma lugar progresivamente para evitar cambios abruptos. El conjunto difuso es definido en la Fig. 2.




Fig 2. Conjunto difuso ODL/X_2

El algoritmo Takagi-Sugeno es usado para definir el supervisor. De un conocimiento empírico, el conjunto difuso es asociado con una acción de control; entonces tres reglas de inferencia difusa son deducidas:

Si ODL/X_2 es BAJO entonces $u =$ lazo abierto
 Si ODL/X_2 es MEDIO entonces $u =$ Acción b_{inc}
 Si ODL/X_2 es ALTO entonces $u =$ Acción D

El supervisor Takagi-Sugeno emplea la biomasa estimada para el cálculo de la ODL/X_2 y seleccionar la acción de control más adecuada para el proceso. La estructura del control inteligente híbrido es mostrado en la Fig. 3.

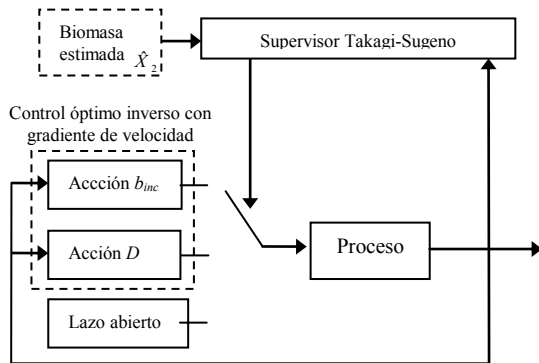


Fig. 3 Esquema de control inteligente híbrido

La principal idea de este esquema de control es combinar diferentes acciones de control para permitir al proceso seguir una referencia de producción de metano. El modo de operación en lazo abierto funciona adecuadamente en presencia de pequeñas perturbaciones, que representan ahorro de energía. Consecuentemente, la acción de control más adecuada es aplicada para evitar el lavado.

VI. RESULTADOS DE SIMULACIÓN

El modelo del proceso anaeróbico y el observador son implementados usando Matlab/M-file™. El observador fue verificado ante perturbaciones en la entrada y variación de parámetros, obteniendo una buena estimación de estados. 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), porque ellas representan el comportamiento dinámico del proceso anaeróbico para crecimiento de biomasa y producción de metano 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. El seguimiento de trayectorias para los estados es mostrado en la Fig. 4.

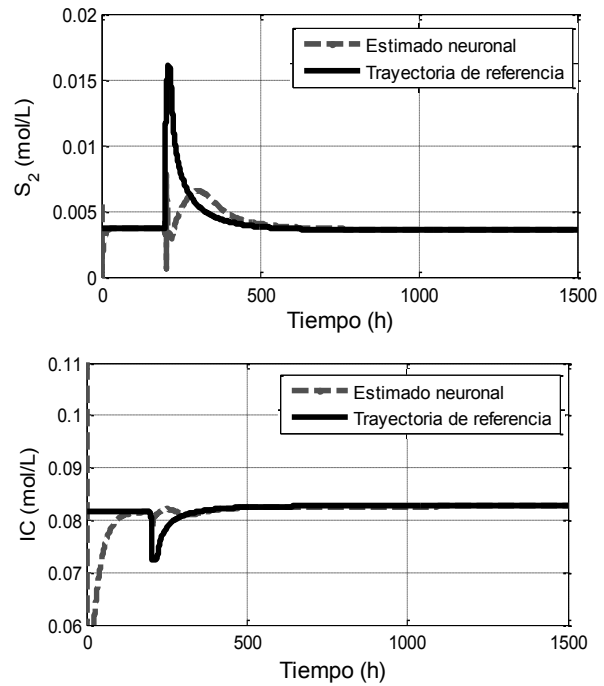
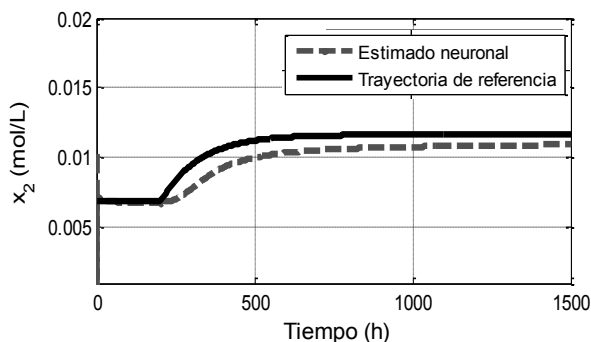


Fig. 4 Seguimiento de trayectorias de los estados

Cuando la perturbación es introducida, la ley de control debe ser aplicada para permitir el crecimiento de la biomasa y por lo tanto disminuir ODL/X_2 y estabilizar el sistema. Durante la perturbación, ODL/X_2 incrementa su valor hasta alcanzar un nivel de pertenencia al conjunto difuso ALTO. Por lo tanto el sistema opera en lazo cerrado con la acción de control D . Durante la evolución del proceso ODL/X_2 disminuye su nivel hasta pertenecer al conjunto difuso MEDIO. Así la acción de control b_{inc} es aplicada y la acción de control D es detenida. Finalmente ODL/X_2 disminuye su valor hasta pertenecer al conjunto difuso BAJO que pertenece a la operación en lazo cerrado. Esta situación implica que la perturbación ha sido rechazada completamente. Así el seguimiento de trayectorias de los estados es eficiente como es ilustrado en la Fig. 4 y el error se aproxima a cero en el estado estable. YCH_4 es ilustrada en la Fig. 5.

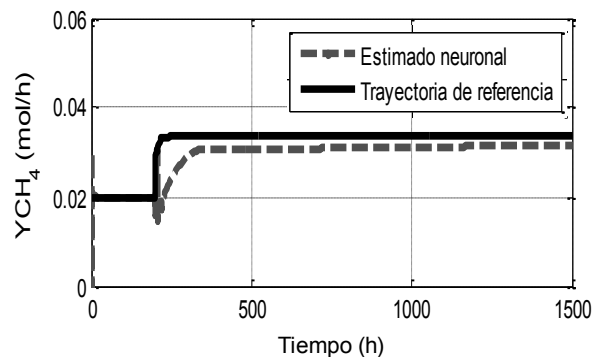


Fig. 5 Seguimiento de trayectoria para YCH_4

La YCH_4 es obtenida con la ecuación (2) que está en función de los estados estimados del sistema. Como se ilustra en la Fig. 5, la referencia YCH_4 es alcanzada. El error de

seguimiento es desplegado en la Fig. 6. Este error podría ser debido a la estructura simple del observador.




Fig. 6 Error de seguimiento para YCH_4

La Fig. 7 despliega las señales de control para las entradas b_{inc} y D_{in} .




Fig. 7 Señales de control

VII. CONCLUSIONES

En este artículo un esquema de control híbrido inteligente para un proceso anaeróbico es propuesto para producir metano y evitar la inhibición del proceso. 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. 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. El supervisor difuso detecta actividad biológica dentro del reactor empleando la estimación de la biomasa y

aplica una acción de control. La meta es forzar al sistema para seguir señales de referencia deseadas. Los resultados en simulación ilustran que el control híbrido inteligente propuesto es capaz de estabilizar la producción de metano a lo largo de la trayectoria deseada en presencia de perturbaciones, y evitando el lavado. El seguimiento de trayectorias con el esquema de control propuesto es novedoso para el modelo de digestión anaeróbica descrito en este artículo. Como trabajo futuro se implementará la estrategia de control propuesta en tiempo real.

AGRADECIMIENTOS

Este trabajo está financiado por el proyecto CONACyT 57801Y.

REFERENCIAS

- 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.
- 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., 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.
- 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.
- Liang, R. H., Liao, J.H. (2007). A fuzzy-optimization approach for generation scheduling with wind and solar energy systems, *IEEE Trans. Power Syst.*, vol. 22, no. 4, pp. 1665–1674.
- Lin, Wei and Byrnes, Christopher I. (1994). Design of discrete-time nonlinear control systems via smooth feedback. *IEEE Trans. on Automatic Control* 39(11), 2340–2346.
- 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)
- 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.
- 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.
- Takagi, T., Sugeno, M., (1985). *IEEE T. Syst. Man Cyb.* 15 (1) 116.
- Tanaka, K., Wang, W. O., (2001). *Fuzzy control systems design and analysis: a linear matrix inequality approach*, First ed., Wiley-Interscience, New York.
- Yamuna Rani, K. y Ramachandra Rao, V.S. (1999). Control of fermenters, *Bioprocess Engineering*, no. 21, pp. 77–78, Springer-Verlag, Germany.