

MODELAMIENTO MATEMÁTICO Y DISEÑO DE UN NEUROCONTROLADOR DBP PARA UN REACTOR CSTR

HENRY ANTONIO MENDIBURU DÍAZ
Ingeniero Electrónico, Magíster en Control y Automatización
henrymendiburu@yahoo.es

ABSTRACT: Esta investigación tiene por objetivo el modelamiento matemático de un reactor químico continuo CSTR en el cual se desarrolla una reacción exotérmica (saponificación de acetato de etilo con hidróxido de sodio). Así mismo se busca diseñar un sistema de control basado en un neurocontrolador dinámico DBP, el cual será simulado bajo funcionamiento de operación normal y también sometido a ruido y perturbaciones; para evaluar su rendimiento también se controló el sistema usando un PID y redes neuronales estáticas.

1. INTRODUCCION

Un reactor químico continuo CSTR (Complete Stirred Tank Reactor), es aquella unidad procesadora diseñada para que en su interior se lleve a cabo una o varias reacciones químicas. Dicha unidad procesadora esta constituida por un recipiente cerrado, el cual cuenta con líneas de entrada y salida para sustancias químicas. Este tipo de reactor consta de un tanque con una agitación permanente y casi perfecta, en el que hay un flujo continuo de material reaccionante y desde el cual sale continuamente el material que ha reaccionado (material producido).

Un neurocontrolador dinámico DBP (Dynamic Back Propagation), es aquel algoritmo matemático basado en una red neuronal multicapa, con aprendizaje supervisado, conocido como algoritmo de retropropagación de errores. Posee la capacidad de autoadaptar los pesos que conectan las neuronas de las capas intermedias. Este algoritmo es de naturaleza estocástica, es decir, que encuentra el camino hacia un mínimo local o global de manera zigzagueante, por lo cual tiene una convergencia lenta lo que implica un mayor número de iteraciones para lograr reducir el error.

2. MODELAMIENTO MATEMATICO

Se asume: que la agitación es perfecta, por tanto la concentración, presión, y temperatura son iguales en cualquier punto del tanque, así como en la corriente de salida; que el volumen del reactor es constante; que las propiedades de los compuestos no varían con la temperatura; y que no hay pérdidas de calor hacia el ambiente. No se considera como objeto de control el sistema de agitación, ni el sistema de control de nivel del tanque.

BALANCE DE MASAS

La expresión general del balance de masas para un material X es la siguiente:

$$V * \frac{dC_x}{dt} = Fi_x * Ci_A - F * C_x \pm G \tag{1}$$

Donde:

V	Volumen del tanque	[m ³]
CiX	Concentración de material X a la entrada	[mol]
CX	Concentración de material X a la salida	[mol]
FiX	Velocidad de flujo molar de X a la entrada	[lit/seg]
F	Velocidad de flujo molar a la salida	[lit/seg]
GX	Velocidad de generación o transformación	[mol/seg]

Si la temperatura, actividad catalítica, concentración, y demás parámetros asumidos son válidos y uniformes, entonces se cumplirá que: $G_x = r_x * V$ (2)

La velocidad de reacción (r_x) se define como la velocidad de formación o de desaparición de moles del material X, transformados por cada unidad de tiempo y por cada una unidad de volumen.

Para este caso, la reacción sigue la ecuación de segundo orden, por tanto: $-r_x = K * C_x$ (3)

Ecuación de Arrhenius: $K = p * z * e^{\frac{-E_x}{R*T}}$ (4)

La cual se resolverá según Henry y Simancas (1996): $K = 63380 * e^{\frac{-2407.2}{T}}$ (5)

Donde:

rx	Velocidad de reacción	[mol/(seg*m ³)]
K	Constante de velocidad	[mol ⁿ /(seg*m ³)]
p	Factor estérico	[mol ⁿ⁺¹ /m ³]
Z	Frecuencia de colisiones	[1/(seg*mol)]
Ex	Energía de activación	[°K*kJ/(Kg*mol)]
R	Constante de Botzmann	[°K*kJ/(Kg*mol)]
T	Temperatura	[°K]

Se sabe que el volumen de la masa reaccionante al interior del tanque es constante, entonces tanto el flujo de entrada como el flujo de salida serán iguales, por lo que el balance global de las masas será:

$$2 * F = Fi_A + Fi_B \quad (6)$$

Balance de masas para hidróxido de sodio (A): $V * \frac{dC_A}{dt} = Fi_A * Ci_A - F * C_A - K * C_A * C_B * V$ (7)

Balance de masas para acetato de etilo (B): $V * \frac{dC_B}{dt} = Fi_B * Ci_B - F * C_B - K * C_A * C_B * V$ (8)

Balance de masas para acetato de sodio (C): $V * \frac{dC_C}{dt} = -F * C_C + K * C_A * C_B * V$ (9)

Balance de masas para el etanol (D): $V * \frac{dC_D}{dt} = -F * C_D + K * C_A * C_B * V$ (10)

BALANCE DE ENERGÍA

Según Fogler (1992), el balance de energía en un reactor CSTR de volumen constante esta dado por la siguiente expresión:

$$Q + \sum (Fi_x * Ci_x * Hi_x) - \sum (F * C_x * H_x) = \sum (C_x * V * Cp_x) * \frac{dT}{dt} + \sum (H_x * V) * \frac{dC_x}{dt} \quad (11)$$

Subdividiendo cada término:

$$\sum (Fi_x * Ci_x * Hi_x) = Fi_A Ci_A Hi_A + Fi_B Ci_B Hi_B + Fi_A Cr Hr + Fi_B Cr Hr \quad (12)$$

$$\sum (F * C_x * H_x) = FC_A H_A + FC_B H_B + FC_C H_C + FC_D H_D + FCr Hr \quad (13)$$

$$\sum (C_x * V * Cp_x) * \frac{dT}{dt} = V (C_A Cp_A + C_B Cp_B + C_C Cp_C + C_D Cp_D + Cr Cp_r) * \frac{dT}{dt} \quad (14)$$

$$\sum (H_x * V) * \frac{dC_x}{dt} = V \left(H_A \frac{dC_A}{dt} + H_B \frac{dC_B}{dt} + H_C \frac{dC_C}{dt} + H_D \frac{dC_D}{dt} + Hr \frac{dCr}{dt} \right) \quad (15)$$

Los términos correspondientes a $\frac{dC_x}{dt}$ se obtienen de las ecuaciones (7), (8), (9), y (10)

El término Q se desarrolla de la siguiente manera: $Q = UA(Tr - T)$ (16)

Donde U es el coeficiente global de transferencia de calor, y según Hernández y Borregales (2001) se puede asumir constante: $U = 19.19 / A$ (17)

Operando algebraicamente y simplificando se obtiene que el balance de energía, que expresa el comportamiento dinámico de la temperatura dentro del reactor, queda reducido a la siguiente expresión:

$$VCp \frac{dT}{dt} = \frac{UA(Tr - T)}{V\rho_L} - Fi_A Ci_A Cp_A (T - Ti_A) - Fi_B Ci_B Cp_B (T - Ti_B) + \Delta H(KC_A C_B)V$$
 (18)

Capacidad calorífica: $Cp = C_A Cp_A + C_B Cp_B + C_C Cp_C + C_D Cp_D$ (19)

Generalizando la Capacidad Calorífica del material X se encuentra a partir de la siguiente ecuación, los coeficientes para cada material, fueron obtenidos a partir de la bibliografía Perry (1992).

$$Cp_X = \alpha_{X1}T^3 + \alpha_{X2}T^2 + \alpha_{X3}T + \alpha_{X4}$$
 (20)

Las entalpías se agrupan en un solo término:

$$\Delta H = hr(Tref) + \int_{Tref}^T (Cp_C + Cp_D - Cp_A - Cp_B) dt$$
 (21)

El coeficiente hr(Tref) representa la parte de la integral que es constante, es decir la sumatoria de las capacidades caloríficas para una temperatura de referencia (Tref).

Donde:

U	Coeficiente de transferencia de calor	[J/(°K*seg*m²)]
A	Superficie o área para la transferencia de calor	[m²]
T	Temperatura en el reactor a la salida	[°K]
TiA	Temperatura del material A en la entrada	[°K]
TiB	Temperatura del material B en la entrada	[°K]
Tr	Temperatura en el refrigerante a la salida	[°K]
Cp	Capacidad calorífica general	[kJ/(Kg*°C)]
Cpx	Capacidad calorífica del material X	[kJ/(Kg*°C)]
ρ_L	Densidad del líquido en el tanque	[Kg/m³]
Hx	Entalpías de formación del material X	[kJ/C]
ΔH	Calor desarrollado en la reacción	[kJ/C]

El comportamiento dinámico para la temperatura de la camisa de refrigeración (según referencia <http://isaw.isa.cie.uva.es/ecosimjava/reactor.htm>) esta dado por la expresión:

$$\frac{dTr}{dt} = \frac{Fr\rho_r Cp_r (Tir - Tr) + UA(T - Tr)}{Vr\rho_r Cp_r}$$
 (22)

Donde:

Tr	Temperatura del refrigerante a la salida	[°K]
Tir	Temperatura del refrigerante a la entrada	[°K]
Fr	Flujo del líquido refrigerante	[lit/seg]
Cpr	Calor específico del refrigerante	[kJ/(°K*Kg)]
Vr	Volumen de la camisa de refrigeración	[m³]
ρ_r	Densidad del refrigerante	[Kg/m³]

También es necesario conocer el valor del pH, este valor puede ser medido experimentalmente por un sensor, pero en este caso de simulación, se hará una aproximación mediante la expresión:

$$\dot{p}h = \frac{(Fi_A * pH_A + Fi_B * pH_B - 2F * Ph - K * C_A * C_B)}{V}$$
 (23)

$$pH = 11 + \log_{10}(Ph)$$
 (24)

Donde:

pH	Valor de pH dentro del reactor
pHA	Valor de pH del material A
pHB	Valor de pH del material B
Ph	Variable auxiliar para determinar el pH


Las Ecuaciones del Modelo Matemático del Reactor CSTR quedan resumidas de la siguiente manera:

$$\begin{aligned}
 \dot{C}_A &= \frac{F i_A * C_{iA} - F * C_A - K * C_A * C_B * V}{V} \\
 \dot{C}_B &= \frac{F i_B * C_{iB} - F * C_B - K * C_A * C_B * V}{V} \\
 \dot{C}_C &= \frac{-F * C_C + K * C_A * C_B * V}{V} \\
 \dot{C}_D &= \frac{-F * C_D + K * C_A * C_B * V}{V} \\
 \dot{T} &= \frac{UA(T_r - T) - F i_A C_{iA} C_{pA}(T - T_{iA}) - F i_B C_{iB} C_{pB}(T - T_{iB}) + \Delta H(K C_A C_B)V}{V \rho_L} \\
 \dot{T}_r &= \frac{F r \rho_r C_{p_r}(T_{ir} - T_r) + UA(T - T_r)}{V_r \rho_r C_{p_r}} \\
 \dot{p}h &= \frac{(F i_A * pH_A + F i_B * pH_B - 2F * Ph - K * C_A * C_B)}{V}
 \end{aligned}
 \tag{25}$$

3. DISEÑO DEL NEUROCONTROLADOR

El objetivo del sistema de control es controlar la concentración de los materiales que salen del reactor (acetato de sodio y etanol). Para realizar dicho control es necesario variar las concentraciones de entrada de los materiales reactantes (acetato de etilo e hidróxido de sodio). Otra variable a controlar es la temperatura dentro del reactor químico, esto se conseguirá variando la temperatura de la camisa de refrigeración. Por tanto también se debe controlar la temperatura en la camisa de refrigeración, para esto la acción de control recae sobre la temperatura de entrada del refrigerante que recorre la camisa de refrigeración. También se busca monitorear el nivel de pH de la reacción.

ESQUEMA DE LA PLANTA



Variables sensadas:
 $F_A, F_B, T_{iA}, T_{iB}, C_A,$
 $C_B, C_C, C_D, T, Ph,$
 Fr, T_r, Tr

Variables manipuladas (actuadores):
 C_{iA}, C_{iB}, T_r

Se pueden presentar perturbaciones en:
 $T_{iA}, T_{iB}, F_{iA}, F_{iB}, Fr$

NEUROCONTROLADOR

Para la implementación de la simulación del sistema, es necesario discretizar el modelo matemático anterior, quedando éste expresado de la siguiente manera:

$$\begin{cases} C_A(k+1) = C_A(k) + \frac{Fi_A * Ci_A(k) - F * C_A(k) - K * C_A(k) * C_B(k) * V}{V} \\ C_B(k+1) = C_B(k) + \frac{Fi_B * Ci_B(k) - F * C_B(k) - K * C_A(k) * C_B(k) * V}{V} \\ C_C(k+1) = C_C(k) + \frac{-F * C_C(k) + K * C_A(k) * C_B(k) * V}{V} \\ C_D(k+1) = C_D(k) + \frac{-F * C_D(k) + K * C_A(k) * C_B(k) * V}{V} \\ T(k+1) = T(k) + \frac{\frac{UA * (Tr(k) - T(k))}{V \rho_L} - Fi_A Ci_A Cp_A * (T(k) - Ti_A)}{VCp} \\ \quad + \frac{-Fi_B Ci_B Cp_B * (T(k) - Ti_B) + \Delta H * (KC_A(k) C_B(k)) * V}{VCp} \\ Tr(k+1) = Tr(k) + \frac{Fr \rho_r Cp_r * (Tir(k) - Tr(k)) + UA * (T(k) - Tr(k))}{Vr \rho_r Cp_r} \\ Ph(k+1) = Ph(k) + \frac{Fi_A * pH_A + Fi_B * pH_B - 2F * Ph(k) - K * C_A(k) * C_B(k)}{V} \end{cases}$$

Dado un sistema: $X_{(k+1)} = f(X_k, u_k)$, el cual es conocido, se busca controlar el sistema, para lo cual se desea minimizar una función de costo $J = \sum_{k=0}^{N-1} \frac{1}{2} (X^2_{(k+1)} + \xi \cdot u^2_{(k)})$

Donde los estados del sistema son representados por : $X_{(k+1)} = \phi(X_k, u_k)$
 Así mismo la señal de control se representa por: $u_{(k)} = \psi(X_k)$

Los pesos del neurocontrolador son representados por “V” y “W”: $w = w - \eta \frac{\partial J}{\partial w} \quad v = v - \eta \frac{\partial J}{\partial v}$

Donde, η representa el ratio de aprendizaje de los pesos.

La actualización de los pesos responde a la siguiente derivada total:


$$\frac{\partial J}{\partial w} = X_{(1)} \frac{\partial X_{(1)}}{\partial w} + \xi \cdot u_{(0)} \frac{\partial u_{(0)}}{\partial w} + X_{(2)} \frac{\partial X_{(2)}}{\partial w} + \xi \cdot u_{(1)} \frac{\partial u_{(1)}}{\partial w} + X_{(3)} \frac{\partial X_{(3)}}{\partial w} + \xi \cdot u_{(2)} \frac{\partial u_{(2)}}{\partial w} + \dots$$

Las derivadas totales de X respecto a los pesos W, se expresan de la siguiente forma:

$$\frac{\partial X_{(k+1)}}{\partial w} = \frac{\partial X_{(k+1)}}{\partial u_{(k)}} \cdot \frac{\partial u_{(k)}}{\partial w} + \left(\frac{\partial X_{(k+1)}}{\partial X_{(k)}} + \frac{\partial X_{(k+1)}}{\partial u_{(k)}} \cdot \frac{\partial u_{(k)}}{\partial X_{(k)}} \right) \cdot \frac{\partial X_{(k)}}{\partial w}$$

Las derivadas totales de u respecto a los pesos W, se expresan de la siguiente forma:

$$\frac{\partial u_{(k)}}{\partial w} = \frac{\partial u_{(k)}}{\partial w} + \frac{\partial u_{(k)}}{\partial X_{(k)}} \cdot \frac{\partial X_{(k)}}{\partial w}$$



Se puede notar que el sistema trabaja bien únicamente cuando existen muy pocas neuronas en la capa intermedia, por lo que se ha diseñado el controlador utilizando 3 neuronas.

La entrada a la red es el error entre los estados a controlar y sus respectivas referencias, estos errores han sido llevados a un escalamiento de ± 3 . Se busca que este error sea cero por lo cual también se convierte en el error del sistema

La salida de la red se convierte en la señal de control que se conecta a los actuadores, la cual también ha sido escalada a ± 0.9

El entrenamiento comenzó con pesos aleatorios con distribución gauseana, luego de aproximadamente 15 000 iteraciones se consiguió llegar a resultados aceptables, el ratio de aprendizaje fluctuó entre 0.00001 y 0.0000001.

La función utilizada en la capa intermedia fue la función sigmoidea, así mismo también se consideró la variación de centros y amplitudes de esta, para lo cual se uso un ratio de aprendizaje entre 0.0001 y 0.000001 para los centros, y entre 0.0000001 y 0.00000001 para las amplitudes.

La actualización de los pesos se consigue luego de resolver la siguiente ecuación, donde “w” representa al peso que se desea actualizar.

$$\frac{\partial \overline{X}_{(k+1)}}{\partial w} = \frac{\partial X_{(k+1)}}{\partial u_{(k)}} \cdot \frac{\partial u_{(k)}}{\partial w} + \left(\frac{\partial X_{(k+1)}}{\partial X_{(k)}} + \frac{\partial X_{(k+1)}}{\partial u_{(k)}} \cdot \frac{\partial u_{(k)}}{\partial X_{(k)}} \right) \cdot \frac{\partial \overline{X}_{(k)}}{\partial w}$$

De donde se tiene que desarrollar por partes cada término, así tenemos:

<p>La derivada del estado X en el instante siguiente con respecto al estado X en el instante actual, se resuelve de la forma:</p>	$\frac{\partial X_{(k+1)}}{\partial X_{(k)}} = \begin{bmatrix} \frac{\partial C_{C(k+1)}}{\partial C_{C(k)}} & \frac{\partial C_{C(k+1)}}{\partial C_{D(k)}} & \frac{\partial C_{C(k+1)}}{\partial T_{(k)}} \\ \frac{\partial C_{D(k+1)}}{\partial C_{C(k)}} & \frac{\partial C_{D(k+1)}}{\partial C_{D(k)}} & \frac{\partial C_{D(k+1)}}{\partial T_{(k)}} \\ \frac{\partial T_{(k+1)}}{\partial C_{C(k)}} & \frac{\partial T_{(k+1)}}{\partial C_{D(k)}} & \frac{\partial T_{(k+1)}}{\partial T_{(k)}} \end{bmatrix}$
<p>La derivada del estado X en el instante siguiente con respecto a la señal de control U en el instante actual, se resuelve de la forma:</p>	$\frac{\partial X_{(k+1)}}{\partial u_{(k)}} = \begin{bmatrix} \frac{\partial C_{C(k+1)}}{\partial CiA_{(k)}} & \frac{\partial C_{C(k+1)}}{\partial CiB_{(k)}} & \frac{\partial C_{C(k+1)}}{\partial Tir_{(k)}} \\ \frac{\partial C_{D(k+1)}}{\partial CiA_{(k)}} & \frac{\partial C_{D(k+1)}}{\partial CiB_{(k)}} & \frac{\partial C_{D(k+1)}}{\partial Tir_{(k)}} \\ \frac{\partial T_{(k+1)}}{\partial CiA_{(k)}} & \frac{\partial T_{(k+1)}}{\partial CiB_{(k)}} & \frac{\partial T_{(k+1)}}{\partial Tir_{(k)}} \end{bmatrix}$

La red neuronal hace uso de la función sigmoidea para su entrenamiento: $n = \frac{2}{1 + e^{-\frac{(m-c)}{a}}} - 1$

De esta se obtienen las siguientes derivadas (para pesos, amplitudes y centros):

$$\frac{\partial n}{\partial m} = \frac{2}{\left(1 + e^{-\frac{(m-c)}{a}}\right)^2} * e^{-\frac{(m-c)}{a}} \quad \frac{\partial n}{\partial a} = \frac{2 * (-m + c)}{\left(1 + e^{-\frac{(m-c)}{a}}\right)^2} * e^{-\frac{(m-c)}{a}} \quad \frac{\partial n}{\partial c} = \frac{-2}{\left(1 + e^{-\frac{(m-c)}{a}}\right)^2} * e^{-\frac{(m-c)}{a}}$$

La derivada de la señal de control U con respecto a los estados X, se resuelve de la forma:

$$\frac{\partial u_{(k)}}{\partial X_{(k)}} = (w) \cdot \left(\frac{\partial n}{\partial m} \right) \cdot (v)$$

Finalmente las derivadas de la señal de control U con respecto a los pesos se resuelven de la forma:

$$\frac{\partial u}{\partial w} = \begin{bmatrix} \frac{\partial C_C}{\partial w} & \frac{\partial C_D}{\partial w} & \frac{\partial T}{\partial w} \end{bmatrix} = [n \quad n \quad n] \quad \frac{\partial u_i}{\partial v} = (X - ref) * (w_i) * \left[\frac{\partial n}{\partial m} \right] \quad \frac{\partial u}{\partial c} = (w) * \left(\frac{\partial n}{\partial c} \right) \quad \frac{\partial u}{\partial a} = (w) * \left(\frac{\partial n}{\partial a} \right)$$

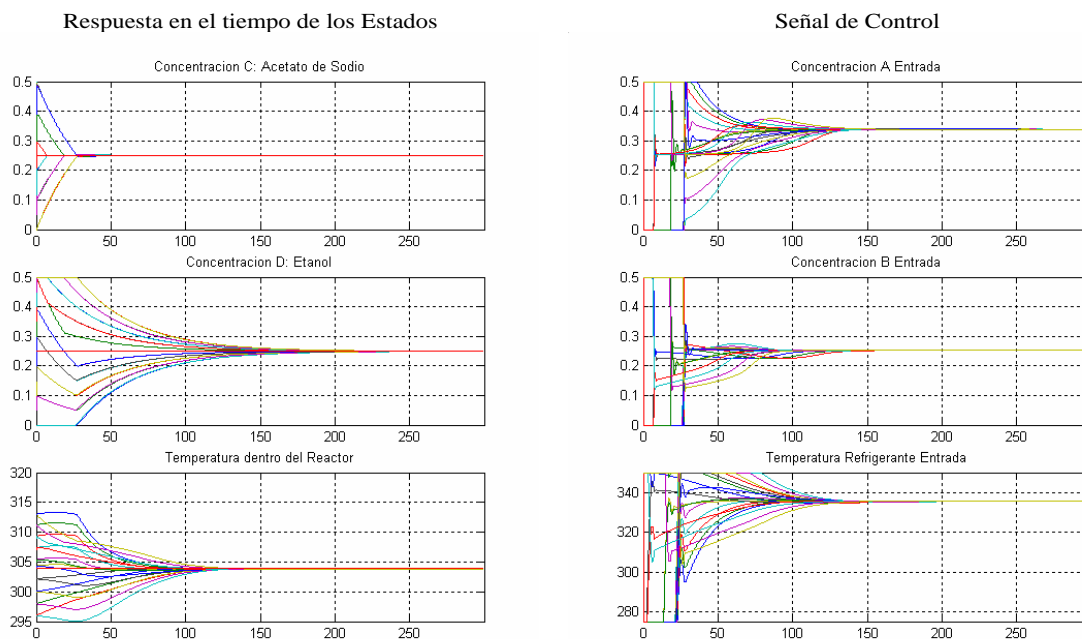
pesos “w”
pesos “v”
centro “c”
amplitud “a”

Los pesos obtenidos cuando se realizó el entrenamiento para el caso de múltiples condiciones iniciales, se muestran a continuación:

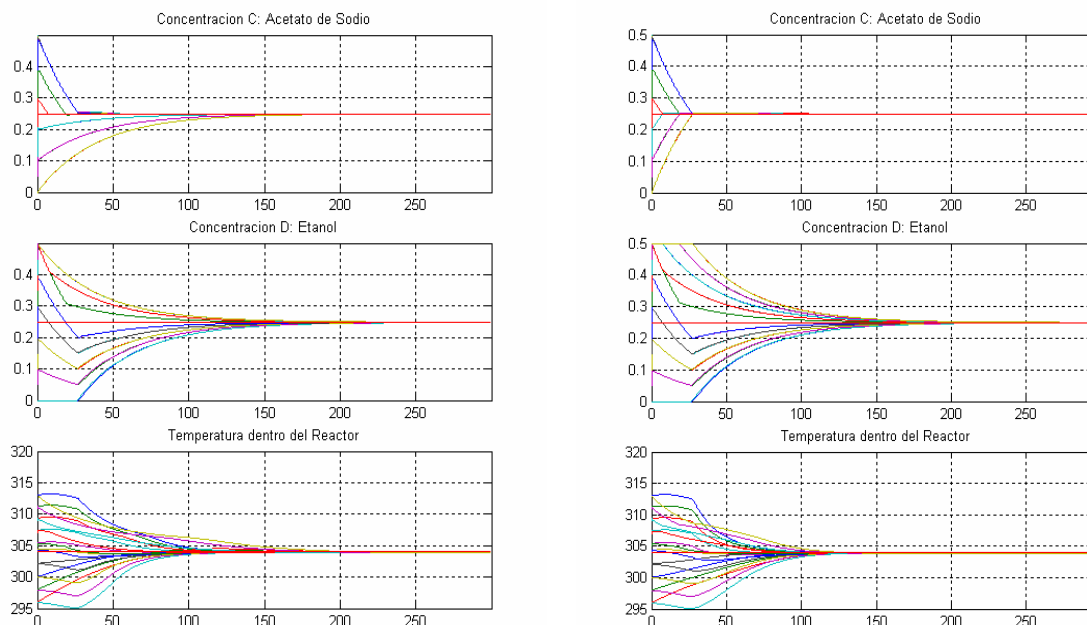
$$w = \begin{bmatrix} -7.9222 & -1.6126 & 3.6309 \\ -6.1172 & 3.6871 & 8.4769 \\ 2.8156 & 2.2750 & 2.3466 \end{bmatrix} \quad v = \begin{bmatrix} 3.0158 & -2.0010 & -3.0011 \\ 0.0020 & -0.0055 & -0.0113 \\ -0.0501 & 0.0001 & -0.4101 \end{bmatrix} \quad a = \begin{bmatrix} 0.3969 \\ 0.9991 \\ 0.9986 \end{bmatrix} \quad c = \begin{bmatrix} -0.0062 \\ 0.0532 \\ 0.0518 \end{bmatrix}$$

4. SIMULACIÓN Y VALIDACIÓN DEL SISTEMA

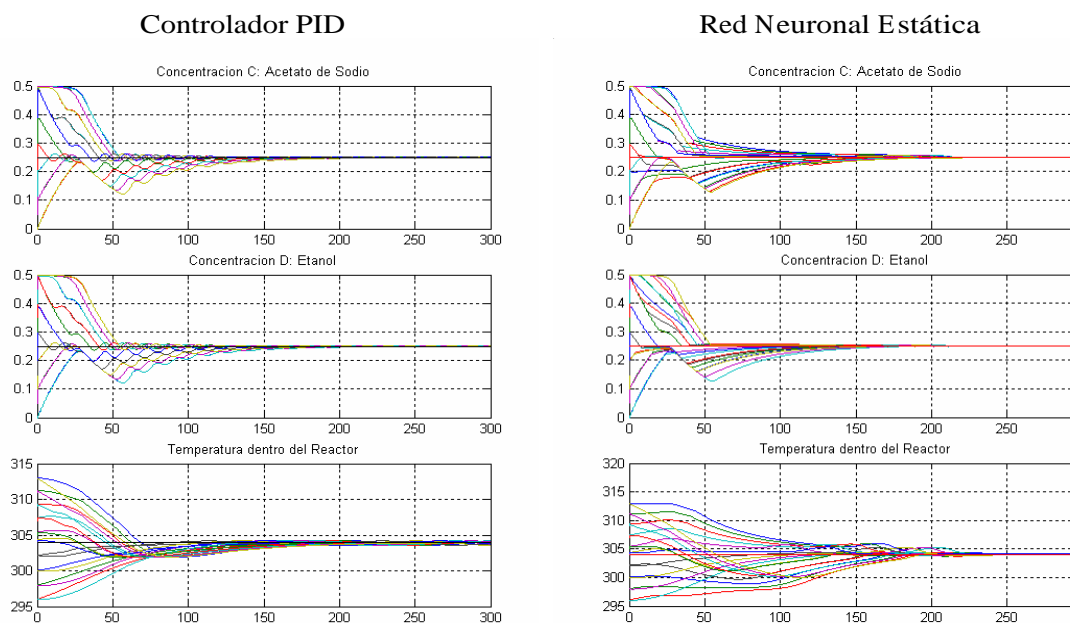
A continuación se muestra la respuesta de los estados y señal de control para el caso de múltiples condiciones iniciales que buscan alcanzar la referencia $C_C = 0.25 \text{ mol}$, $C_D = 0.25 \text{ mol}$, $T = 304 \text{ }^\circ\text{k}$.



A continuación se muestra la respuesta de los estados frente a dos casos con presencia de ruido y perturbaciones, para alcanzar la misma referencia.



Para evaluar el rendimiento del neurocontrolador, se comparó con otros dos controladores: un controlador PID, y una red neuronal estática, bajo las mismas condiciones que la primera simulación:



5. CONCLUSIONES

Mediante las técnicas de modelamiento matemático se ha realizado el balance de masas y balance de energía, cuyas ecuaciones han permitido llegar a un modelo matemático del sistema que se desea controlar.

El diseño del neurocontrolador dinámico ha resultado ser complicado, del mismo modo el entrenamiento de la red es arduo y requiere un gran número de iteraciones. Una característica importante es el hecho de que el entrenamiento requiere el conocimiento del modelo del sistema. Pese a la marcada complejidad es justificable para el eficaz control de sistemas complejos.

El neurocontrolador dinámico ha demostrado ser una buena opción, debido al pequeño error en estado estable, tiempo de establecimiento corto, la señal de control es aplicable a actuadores reales, y la respuesta del sistema no presenta alteraciones bruscas que dañen el producto final producido. Cuando se sometió al sistema a la afección de un juego completo de perturbaciones y ruido, el resultado obtenido afectó a todos los controladores, pero en una escala menor al neurocontrolador dinámico.

6. BIBLIOGRAFÍA

- Fogler, S. (1992). "Elements of chemical reaction engineering". Prentice Hall. New Jersey.
- Freeman, James A., Skapura, David M. (1993). "Redes neuronales: algoritmos, aplicaciones y técnicas de programación". Addison-Wesley Iberoamericana.
- Harvey, Robert L. (1994). "Neural network principles". Prentice-Hall. Englewood Cliffs.
- Hernández, A., Borregales, E. (2001). "Montaje, instrumentación y modelaje de un reactor de laboratorio". Universidad Simón Bolívar. Venezuela.
- Henry, C., Simancas, D. (1996) "Modelaje y simulación de un reactor químico". Proyecto de Grado. Universidad Simón Bolívar. Venezuela.
- Luyben, W.L. (1990). "Process modeling, simulation, and control for chemical engineers". McGraw-Hill. New York.
- Perry, Robert H. (1992). "Manual del ingeniero químico". Mc.Graw Hill, México.
- Srinivas Palanki, Soumitri Kolavennu, (2003). "Simulation of Control of a CSTR Process". The International Journal of Engineering Education Volume 19, Number 3, pag. 398-402.
- Vemuri, V. Rao (1992). "Artificial neural networks: concepts and control applications". IEEE Computer Society Press tutorial. California.