

CONTROL NEURO-BORROSO POR MODELO INTERNO DE UN PROCESO ELECTROMECAÁNICO COMPLEJO

¹Rodolfo E. Haber¹, J.R. Alique¹, A. Alique¹, R.H. Haber², A. Jiménez³

¹Instituto de Automática Industrial (CSIC).
Km. 22,800 N-III, La Poveda. 28500. Madrid.
ESPAÑA
Rodolfo.haber@upm.es

²Departamento de Control Automático
Universidad de Oriente, Santiago de Cuba
CUBA

³Grupo de Control Inteligente. DISAM.
ETSII. Universidad Politécnica de Madrid.

Resumen: Esta contribución muestra la viabilidad de la implementación de una estrategia basada en el paradigma del Control por Modelo Interno (CMI), con una útil sinergia de una Red Neuronal Artificial (RNA) y un Controlador Lógico Borroso (CLB): el Control Neuro-Borroso (CNB). Como caso de estudio consideramos un problema de estabilización de la fuerza de corte en un proceso electromecánico complejo: el mecanizado. Se presentan comparativamente los resultados de la simulación de cuatro estrategias diferentes, con los mejores indicadores para el CNB por su eficacia en el rechazo de perturbaciones. Copyright © 2005 CEA-IFAC

Palabras Clave: Intelligent control, stabilization, fuzzy control, neural-network models, fuzzy systems, force control.

1. INTRODUCCIÓN

Ciertos procesos electromecánicos están caracterizados por una complejidad e incertidumbre tales que hacen que la llamada tecnología de los sistemas inteligentes se convierta en una opción viable a las descripciones formales clásicas (Haber et al. 2002). La Lógica Borrosa (LB) es una de esas técnicas, que ha probado ser útil en control e ingeniería industrial como una herramienta de optimización muy práctica (Haber et al. 1996). Por medio de la LB los sistemas de control pueden ser dotados de la experiencia de un operador experto,

frecuentemente usadas en control no lineal. Varios esquemas han sido propuestos para el control neuronal de sistemas no lineales (Hagan, et al., 2000). El paradigma del Control por Modelo Interno (CMI) es un enfoque bien establecido para el diseño de controladores, que utiliza explícitamente al modelo del proceso en el diseño del sistema de control (Goodwin, et al., 2001; Kambhampati, et al., 2000). En general, la inversión de modelos no lineales no es una tarea fácil, y pueden no existir soluciones analíticas, de modo que las soluciones tienen que calcularse numéricamente. Otro problema es que la inversión del modelo del proceso puede conducir a sistema es de fase

probablemente la otra técnica de la Inteligencia Artificial (IA) más usada en la identificación de modelos y el diseño de sistemas de control (Alique et al. 2000). Las RNA resultan adecuadas para la identificación y el control de procesos no lineales (Hunt, et al., 1992; Nelles, 2000), básicamente debido a su excelente capacidad para representar cualquier función no lineal con el grado deseado de precisión. De entre todos los diferentes tipos de RNA las anticipativas o hacia delante, particularmente el perceptrón multicapa (PMC), son las más

Efectivamente, las RNA pueden usarse en un esquema eficiente de control basado en el principio del CMI. El CMI basado en RNA (RN-CMI) consiste básicamente en entrenar una red para que aprenda la dinámica del proceso. Otra RNA puede entrenarse para aprender la dinámica inversa, de modo que pueda usarse como controlador no lineal (Norgard, et al., 2000). La cuestión es cómo capitalizar la robustez de un CLB sin aumentar la complejidad del diseño.

¹ Autor a quien dirigir correspondencia.

Si podemos sintetizar un CLB con ganancia estática igual a la del modelo inverso, y si el sistema de control es estable con este controlador, obtendremos un control sin desviación estacionaria para valores de referencia y perturbación constantes (Rivals y Personnaz, 2000). El esquema de CNB que proponemos está inspirado en las RN-CMI (Haber-Guerra y Alique, 2004). La inversa de la RNA dinámica es reemplazada en el camino directo por un CLB, para con ello mejorar la capacidad de rechazo a perturbaciones del sistema.

En nuestro trabajo hemos usado en calidad de instalación experimental un proceso electromecánico complejo: el proceso de mecanizado (Haber-Guerra, et al., 2005).

El objetivo principal es implementar la optimización del proceso de mecanizado mediante el control de una única variable de salida, la fuerza de corte, usando una única variable de acción, la velocidad de avance. La eficacia del esquema CNB la demostraremos mediante simulaciones. La comparación entre un CLB, un control directo-inverso basado en RNA's (CDI-RN), un CMI-RN y un CNB se realiza usando varios índices de desempeño a partir de los resultados de las simulaciones. Como se verá, se concluye que el CNB produce un sistema de control más eficaz en el rechazo a perturbaciones.

2. NOCIONES DE MODELADO MEDIANTE RNA

Consideremos un sistema no lineal con $\mathbf{u}_k \in \mathfrak{R}^m$ entradas y $\mathbf{y}_k \in \mathfrak{R}^p$ ($m \geq p$) salidas. Supongamos que ese sistema puede ser modelado exactamente mediante la siguiente RNA anticipativa, de una capa interna

$$y_{k+l} = \mathbf{W}_o \cdot \tanh(\mathbf{W}_x \cdot \mathbf{x}_k + \mathbf{W}_u \cdot \mathbf{u}_k + \mathbf{b}_x) + \mathbf{b}_o \quad (1)$$

donde $\mathbf{x}_k \in \mathfrak{R}^n$ está dado por

$$\mathbf{x}_k = [y_k^T, y_{k-1}^T, \dots, y_{k-ny}^T, u_{k-1}^T, \dots, u_{k-nu}^T]^T \quad (2)$$

con $n = (ny + l) \cdot p + nu \cdot m$, $\mathbf{W}_o \in \mathfrak{R}^{p \times l}$, $\mathbf{W}_x \in \mathfrak{R}^{l \times n}$, $\mathbf{W}_u \in \mathfrak{R}^{l \times m}$, $\mathbf{b}_x \in \mathfrak{R}^{l \times 1}$ y $\mathbf{b}_o \in \mathfrak{R}^{p \times 1}$, donde \mathbf{b}_x y \mathbf{b}_o son los vectores de la polarización en las capas oculta y de salida respectivamente, \mathbf{W}_x , \mathbf{W}_u son matrices de pesos y \tanh representa la función tangente hiperbólica.

Por simplicidad, consideremos el sistema no lineal ($y_k \in \mathfrak{R}^1$) de simple-entrada simple-salida (SESS). La identificación puede ser vista como la determinación del mapeo del conjunto $z^N = [\mathbf{u} \ \mathbf{y}]^T$ al conjunto de pesos posibles (parámetros) $\hat{\boldsymbol{\theta}}$, de modo que la red pueda producir una predicción \hat{y}_{k+l} lo más próxima posible a la salida real y_{k+l} .

$$\hat{\boldsymbol{\theta}} = [\text{vec}(\hat{\mathbf{W}}_o) \ \text{vec}(\hat{\mathbf{W}}_x) \ \text{vec}(\hat{\mathbf{W}}_u) \ \hat{\mathbf{b}}_x \ \hat{\mathbf{b}}_o]^T \quad (3)$$

Usando un método de identificación de predicción de errores, los pesos se calculan como

$$\hat{\boldsymbol{\theta}} = \arg \min (J_l(\boldsymbol{\theta}, z^N)) \quad (4)$$

$$\text{donde } J_l(\boldsymbol{\theta}, z^N) = \frac{1}{2N} \sum_{t=1}^N (y(t) - \hat{y}(t|\boldsymbol{\theta}))^T (y(t) - \hat{y}(t|\boldsymbol{\theta}))$$

El método de entrenamiento de Levenberg-Marquardt puede usarse para determinar los pesos de la red (Haber-Guerra, et al., 2005).

De entre las dos estructuras generales de modelado disponibles, seleccionamos el modelo paralelo mostrado en la ecuación (5), que expresa la aproximación del proceso no lineal mediante la función $G_m(\cdot)$ en términos de las entradas y salidas pasadas del modelo, el modelo del promedio autoregresivo-móvil no lineal (NARMA):

$$\begin{aligned} \hat{y}(k+l|\boldsymbol{\theta}) &= G_m(\varphi(k), \hat{\boldsymbol{\theta}}) \\ &= G_m(\hat{y}_k, \hat{y}_{k-1}, \dots, \hat{y}_{k-ny+1}, u_k, \dots, u_{k-nu+1}, \hat{\boldsymbol{\theta}}) \end{aligned} \quad (5)$$

Usando (1) para formar el modelo paralelo de (5), el modelo puede expresarse como en (6) y (7)

$$\phi_{k(q)} = \tanh \left(\sum_{i=1}^{ny} a_{i(q)} \hat{y}_{k-i+1} + \sum_{j=1}^{nu} b_{j(q)} u_{k-j+1} + b_{x(q,0)} \right) \quad (6)$$

$$\hat{y}(k+l|\boldsymbol{\theta}) = \sum_{q=1}^p W_{o(k,q)} \cdot \phi_{k(q)} + b_{o(k,0)} \quad (7)$$

Nuevamente consideraremos un PMC con una sola capa interna y con funciones de activación tangente hiperbólica en la capa oculta y lineal en la salida.

3. EL PROCESO DE MECANIZADO

Las características del proceso de mecanizado, como proceso electromecánico complejo, limitan severamente el uso de herramientas matemáticas clásicas para el modelado y el control (Bukkapatnam, et al., 1995). La dinámica del proceso de fresado (respuesta de la fuerza de corte F a cambios en la velocidad de avance f) puede modelarse aproximadamente usando una ecuación diferencial de al menos segundo orden. Lauderbaugh and Ulsoy (1989) sugirieron el siguiente modelo lineal:

$$G_{LU}(z) = \frac{0.019z + 0.017}{z^2 - 1.75z + 0.77} \quad (8)$$

Otro modelo, obtenido usando ecuaciones diferenciales de segundo orden (Rober and Shin, 1996) es

$$G_{RS}(z) = \frac{0.052z + 0.04}{z^2 - 1.42z + 0.45} \quad (9)$$

Landers and Ulsoy (2000) propusieron una estructura de primer orden del proceso de fuerza de corte,

incluyendo las velocidades de corte y los efectos no lineales de la profundidad de corte, de ese modo

$$G_{LA}(z) = \frac{0.11}{z - 0.85} a^{0.65} f^{0.63} \quad (10)$$

Los modelos aproximados (8)-(10) proporcionan una caracterización de la dinámica del proceso de mecanizado que ayuda a investigar y analizar el desempeño y limitaciones de la máquina herramienta. Para obtener un mejor acabado superficial en la pieza y reducir el tiempo de mecanizado, la fuerza de corte ha de mantenerse constante durante el mecanizado (relación directa entre la fuerza de corte y la tasa de arranque de virutas). Cuando hay perturbaciones, tales como la variación de la profundidad de corte, este requisito solo puede cumplirse usando el control. De aquí que podamos usar un modelo matemático aproximado en el diseño de nuevos controladores con vistas a la optimización del proceso.

El conjunto $G_P = \{G_{LU}(z), G_{RS}(z), G_{LA}(z)\}$ representa al proceso de mecanizado desde el punto de vista clásico. Las ecuaciones (8)-(10) son solo válidas en rangos de operación estrechos, de aquí que no puedan rebasar ciertos límites a la hora de representar la complejidad e incertidumbre del proceso. No obstante, ellas sí que proporcionan una caracterización aproximada de la dinámica del proceso de mecanizado y por ello serán usadas posteriormente para las simulaciones.

En la figura 1 se muestra el diagrama completo de una tarea típica de mecanizado y un esquema de control para la optimización del proceso. El Control Numérico Computarizado (CNC) cumple importantes tareas, que incluyen los lazos de control de velocidad para el avance, f_r , y el giro del husillo, así como el interpolador (i.e., lazo de control de la posición espacial del útil de corte $O_p = [x_p \ y_p \ z_p]^T$). Las variables O_{p0} , s_o y f_o representan las referencias internas para los lazos de control del CNC, los cuales pueden diferir, en el caso de f , de los valores dinámicos generados por el controlador de fuerza de corte.

4. UNA SOLUCIÓN AL CONTROL BORROSO DE LA FUERZA DE CORTE

El proceso de fresado es ciertamente complejo, pero la tarea de su control puede solucionarse aplicando un controlador no lineal, cuyo diseño no requiere de modelo analítico exacto del proceso: un CLB. En el diseño de un CLB las variables incluidas en el vector de error e son el error y el cambio del error en la fuerza de corte (ΔF y $\Delta^2 F$, respectivamente, en Newtons). La variable de acción elegida por nosotros es el incremento de la velocidad de avance (Δf en porcentaje del valor inicial programado), mientras

que la velocidad del husillo es constante y fijada por el operador.

$$e^T = [K_E \cdot \Delta F \quad K_{CE} \cdot \Delta^2 F]; \quad u = [GC \cdot \Delta f] \quad (11)$$

donde K_E , K_{CE} y GC son factores de escala para las entradas y salidas, respectivamente.

Consideraremos un conjunto de reglas constituido por expresiones lingüísticas que vinculan a cada antecedente con su respectivo consecuente, con la siguiente sintaxis:

*IF ΔF is positive AND $\Delta^2 F$ is positive
THEN Δf is Positive Big*

La salida del controlador se infiere mediante un operador composicional. En nuestro caso elegimos el llamado operador Sup-Producto. Por ejemplo, aplicando la norma T_2 (producto) y la co-norma S_1 (máximo) se obtiene

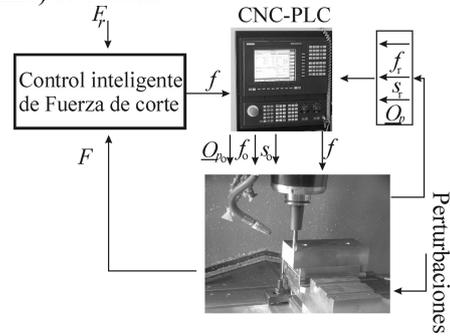


Fig. 1. Diagrama general de un esquema típico de mecanizado y control para la optimización del proceso.

$$\mu(\Delta F, \Delta^2 F, \Delta f) = \underset{i=1}{m \times n} \left[T_2 \left[\mu_{\Delta F_i}(\Delta F), \mu_{\Delta^2 F_i}(\Delta^2 F), \mu_{\Delta f_i}(\Delta f) \right] \right] \quad (12)$$

donde T_2 representa la operación de producto algébrico y S_1 la operación de unión (max), $m \times n = 49$ reglas. La salida determinista del controlador usada para cambiar el avance de la bancada se obtiene mediante la llamada concreción, empleando el método del centro del área (CDA), definido como

$$\Delta f = \frac{\sum_i \mu_R(\Delta f_i) \cdot \Delta f_i}{\sum_i \mu_R(\Delta f_i)} \quad (13)$$

La estrategia usada para calcular a f determina el tipo de CLB que resulta. En este caso se trata de un regulador PI:

$$f(k) = f(k-1) + \Delta f(k) \quad (14)$$

5. UN SISTEMA DE CMI BASADO EN RNA

Un esquema de CMI puede ser implementado usando una RNA, en lo que se conoce como RN-CMI. Primeramente se entrena una RNA para que aprenda la dinámica del proceso suministrándole datos de entrada-salida. Así, uno de los modelos desarrollados en (Haber- Guerra, et al., 2005) se elige como base para el CMI. La ecuación dinámica puede representarse, en notación reducida, por

$$\hat{F}(t) = G_M(\mathbf{F}, \mathbf{f}) \quad (15)$$

donde G_M es una función incógnita a identificar, F es la fuerza de corte ejercida durante la remoción de virutas metálicas y f es la velocidad relativa entre la bancada y el útil de corte. Puesto en forma vectorial \mathbf{f} y \mathbf{F} son la entrada y salida, respectivamente, definidas como $\mathbf{F} = [F(t-1) \dots F(t-n)]$ y $\mathbf{f} = [f(t-1), \dots, f(t-m)]$, t es el instante de tiempo discreto y $n, m \in \mathbb{Z}$. Un esquema de identificación debería asegurar valores $\hat{F}(t)$ tan cercanos como sea posible a los de $F(t)$ (salida real).

El algoritmo de entrenamiento fue desarrollado usando MATLAB. La topología se escogió inicialmente como sigue: una entrada, f , y una salida, \hat{F} , una función de activación lineal a la salida y una capa oculta que usa una función de activación de tangente hiperbólica. El tipo de modelo se seleccionó usando conocimiento *a priori* del proceso de mecanizado y los tipos de modelos considerados en trabajos previos. Se utilizaron para el entrenamiento datos obtenidos de operaciones de mecanizado reales. Elegimos una RNA con cuatro entradas, cuatro neuronas en la capa oculta y una neurona en la de salida. La ecuación dinámica puede expresarse, usando notación reducida, por

$$\hat{F}(t+1) = G_M(f(t) \ f(t-1) \ F(t) \ F(t-1)) \quad (16)$$

donde $G_M = \{\mathbf{w}_f, \mathbf{W}_f\}$, $\mathbf{w}_f = \{\mathbf{W}_u, \mathbf{W}_x, \mathbf{b}_x\}$, $\mathbf{W}_f = \{\mathbf{W}_0, \mathbf{b}_0\}$

$$\mathbf{w}_f = \begin{bmatrix} -0.0094 & 0.0019 & 0.0226 & -0.0158 & 2.2530 \\ 0.0081 & 0.0084 & -0.0075 & -0.0031 & -6.2151 \\ 0.0122 & -0.0068 & -0.0202 & 0.0245 & -2.5668 \\ -0.0056 & 0.0167 & -0.0103 & 0.0140 & -4.1976 \end{bmatrix} \quad (17)$$

$$\mathbf{W}_f = [-28.7834 \ 13.8937 \ 47.0386 \ 54.5429 \ 378.4564] \quad (18)$$

El modelo inverso se obtuvo mediante el entrenamiento generalizado (Norgard, et al., 2000). Por consiguiente, la red fue entrenada para minimizar, fuera de línea, a

$$J(\theta) = \sum_{t=1}^M (f(t) - \hat{f}(t))^2 \quad (19)$$

Otra RNA fue entrenada para aprender la dinámica inversa del proceso y funcionar como controlador no lineal. La ecuación dinámica del modelo inverso puede expresarse en notación reducida por

$$f(t) = G'_M(F(t+1) \ F(t) \ f(t-1) \ f(t-2)) \quad (20)$$

donde, $G'_M = \{\mathbf{w}_i, \mathbf{W}_i\}$, $\mathbf{w}_i = \{\mathbf{W}_u, \mathbf{W}_x, \mathbf{b}_x\}$, $\mathbf{W}_i = \{\mathbf{W}_0, \mathbf{b}_0\}$

$$\mathbf{w}_i = \begin{bmatrix} 0.0022 & -0.0004 & -0.0003 & -0.0042 & -0.3665 \\ 0.0332 & 0.0141 & -0.0076 & -0.0213 & -18.1896 \\ 0.0026 & -0.0027 & 0.0017 & 0.0070 & -1.7947 \\ 0.0029 & -0.0006 & -0.0010 & 0.0048 & -0.7328 \end{bmatrix} \quad (21)$$

$$\mathbf{W}_i = [-157.9236 \ 2.6474 \ 94.7554 \ 129.0931 \ 459.2642] \quad (22)$$

Los vectores de polarización ($\mathbf{b}_x, \mathbf{b}_0$) están representados por la última columna de (17)-(18) y (21)-(22).

6. SINTONÍA ÓPTIMA DEL CLB

El algoritmo de propagación hacia atrás del error se aplicó para la sintonía de $\hat{\theta} = [\hat{K}_E, \hat{K}_{CE}]$, correspondiente a los factores de escala de entrada del bloque borroso que reemplazará al modelo inverso (20). Los detalles se muestran en la figura 2. El objetivo es asegurar que la salida del sistema siga fielmente a la señal de referencia $F_r(t)$ mediante el ajuste óptimo de esos factores de escala de entrada.

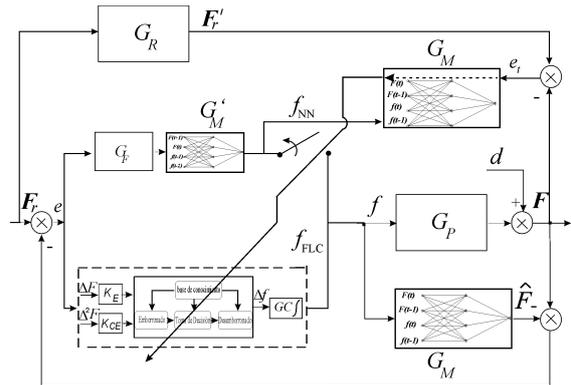


Fig. 2. Esquema para la sintonía de los factores de escala usando retro-propagación y modelo inverso.

Ciertamente, si (20) describiera la dinámica inversa real del proceso, habría una cancelación perfecta y por consiguiente podríamos intentar hallar una $\hat{\theta} = [\hat{K}_E, \hat{K}_{CE}]$ tal que $f_{NN}(t) \cong f_{FLC}(t)$. No obstante, la red entrenada (21)-(22) tendrá ciertas imprecisiones y no podremos estar seguros del comportamiento real del sistema a lazo cerrado. Sobre la base del algoritmo de entrenamiento recursivo descrito en la Sección 2 el error de salida del CLB será

$$e_n(t) = \frac{\partial F(t)}{\partial f(t-1)} \cdot e_i(t) \quad (23)$$

donde $e_i(t) = F_r'(t) - F(t)$, $F(t)$ es la salida del sistema y $F_r'(t)$ la del modelo de referencia. Usando el modelo directo (16) podemos estimar las Jacobianas y, por consiguiente,

$$\frac{\partial F(t)}{\partial f(t-1)} \cong \frac{\partial \hat{F}(t)}{\partial f(t-1)} \quad (24)$$

Más detalles acerca de este algoritmo pueden hallarse en (Norgard, et al., 2000).

Para evaluar la desviación de $\hat{\theta}$ pueden usarse los conocidos criterios integrales, e.g., el de error cuadrático (ISE), que, sin embargo, no suele ser muy sensible.

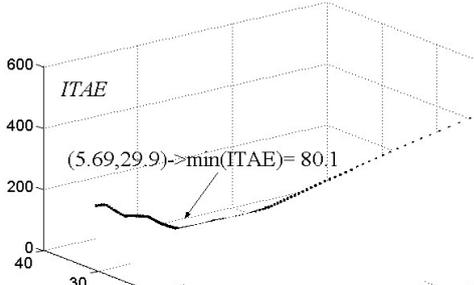


Fig. 3. Comportamiento del criterio *ITAE* respecto a $\hat{\theta} = [\hat{K}_E, \hat{K}_{CE}]$

Por tanto, para optimizar la respuesta transitoria, penalizando sobrepasos grandes y transitorios prolongados, que resultan especialmente dañinos para los útiles de corte usados en el mecanizado, un mejor camino sería, por ejemplo, usar el criterio del integral del valor absoluto del error multiplicado por el tiempo (*ITAE*)

$$J_2 = \int_0^T t \cdot |e(t)| dt \quad (25)$$

El esquema para el ajuste óptimo del bloque CLB usando el criterio *ITAE* se esboza en la figura 2.

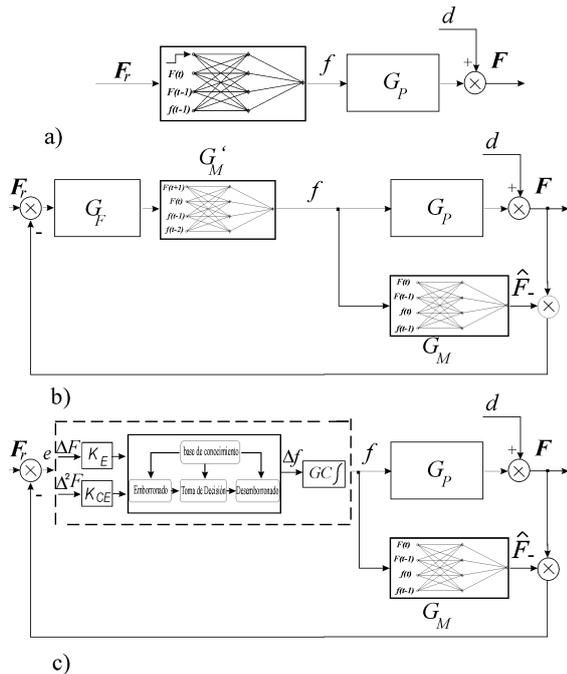


Fig. 4 a) Esquema CDI-RN, (b) Esquema CMI-RN, (c) Diagrama CNB

El modelo que usamos como referencia, en transformada Z , $G_R(z)$, está dado por

$$G_R(z) = \frac{0.11}{z - 0.89} \quad (26)$$

Los parámetros iniciales del CLB (i.e., sus factores de escala) fueron $\theta = [K_E, K_{CE}] = [10.2, 5.1]$. Por simplicidad, se consideró que (10) es G_p . Tras 150 iteraciones, obtuvimos $[\hat{K}_E, \hat{K}_{CE}] = [5.69, 29.9]$, correspondientes a un mínimo $J_2 = 80.1$ (ver figura 3).

7. SIMULACIONES Y RESULTADOS

Los modelos (8)-(10) fueron usados en la estructura de control realimentado, según los esquemas de la figura 2. La superficie de control borroso tiene la misma ganancia estática que el modelo neuronal inverso G_M' . Tal ganancia se obtuvo ajustando los factores de escala K_E, K_{CE} y GC .

Los factores de escala correspondientes al CLB eran

$$(K_E, K_{CE}, GC) = (10.0, 5.1, 0.09) \quad (27)$$

mientras que, aplicando el procedimiento de la sección 6, se obtuvieron

$$(K_E, K_{CE}, GC) = (5.69, 29.9, 0.09) \quad (28)$$

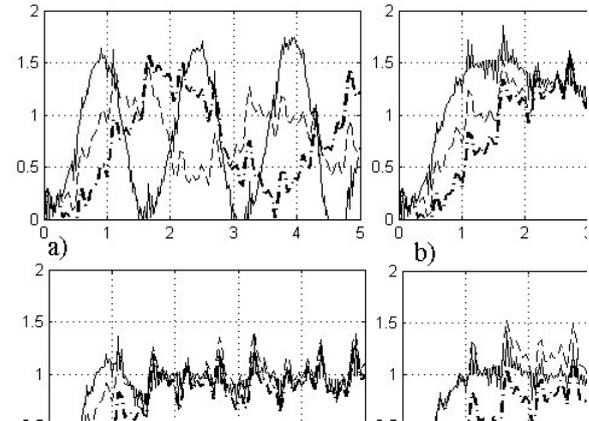


Fig. 5. Respuesta a lazo cerrado en presencia de perturbaciones a) CDI-RN, b) CLB, c) CMI-RN, d) CNB.

En lo adelante, se aplicó (28) al CLB del esquema CNB. Se realizaron simulaciones usando los modelos linealizados (aproximados) del proceso (8)-(10) con los esquemas de control borroso y los que se muestran en la figura 4. Para evaluar el comportamiento del sistema en presencia de perturbaciones, se consideró la presencia de ruido aditivo más la dinámica no modelada, como estimación de la dinámica que cabría esperar en aplicaciones reales. Se asumió que la salida estaba contaminada con el ruido aditivo

$$d(t) = 0.1 \cdot (\sin 8t + \sin 12t + \sin 23.66t + \sin 35.49t) \quad (29)$$

De este modo, un modelo más realista del proceso, incluyendo dinámica multiplicativa no modelada, más el ruido (29), estaría representado por

$$G_p(z) = G_*(z) \cdot \frac{0.095}{z - 0.904} + d(z) \quad (30)$$

donde $G_*(z)$ es un modelo ideal del proceso representado por (8)-(10).

Se calcularon varios índices de mérito, tales como el Integral del valor Absoluto del Error (*IAE*), el *ISE* y el *ITAE*, además del máximo sobrepaso *Mpt*. En la figura 5 se presenta una comparación entre el CDI-RN, CLB, CMI-RN y CNB, con la influencia de dinámica no modelada y perturbaciones. El CDI-RN muestra el peor de los desempeños. La señal de control generada CDI-RN es altamente oscilatoria y ocasiona las oscilaciones que muestra el sistema.

Esa situación cambia significativamente si tienen lugar perturbaciones. El CLB, el CMI-RN y el CNB son todos capaces de regular el proceso en presencia de ruido. A pesar de su intrínseca robustez, el CLB da un mejor transitorio, pero más error y mayor sobrepaso y, por tanto, el peor de los desempeños detrás del CDI-RN. Por otro lado, no hay gran diferencia entre el CMI-RN y el CNB en base de los criterios *IAE* e *ISE* (ligeramente mejor para el CNB). Sin embargo, el CNB se comporta muy bien según el criterio *ITAE* (ver Tabla 1).

Tabla 1. Resumen comparativo de las estrategias analizadas.

Índice ⇒	<i>ISE</i>		<i>IAE</i>		<i>ITAE</i>		<i>Mpt</i>	
	CLB	CMI	CNB	CLB	CMI	CNB	CLB	CMI
(8)	+	+	++	+	-	+	+	-
(9)	+	+	+	+	-	-	+	-
(10)	+	+	++	+	+	++	+	-
(30)-(8)	-	+	++	-	+	++	-	++
(30)-(9)	-	+	+	-	++	+	-	+
(30)-(10)	-	+	++	-	+	++	-	++

++ excelente, + bueno, - malo, -- muy malo

8. CONCLUSIONES

El esquema de Control Neuro-Borroso propuesto está inspirado en el CMI no lineal. El modelo inverso, representado por una RNA dinámica, es reemplazado por un CLB para mejorar la capacidad de rechazo a perturbaciones. Una RNA dinámica es entrenada para aprender la dinámica del proceso (directa) y otra para aprender la dinámica inversa. Un CLB, con igual ganancia estática que el modelo inverso se usa en el camino directo del lazo de control.

Este estudio muestra la viabilidad de implementar una estrategia de control, basada en el paradigma CMI, que es una útil sinergia de una RNA dinámica

entrenada con datos reales, usada para predecir la salida del proceso y un CLB que mejora el desempeño global del sistema. Para el proceso electromecánico estudiado, las pruebas de simulación demuestran que el CNB se comporta mejor que el CLB y que el CMI-RN en presencia de ruido. Perturbaciones severas y ruido aditivo hacen que las simulaciones sean más realistas y útiles para la optimización del proceso.

REFERENCIAS

- Alique A., R. E. Haber, R. H. Haber, S. Ros, and C. Gonzalez (2000). A neural network-based model for the prediction of cutting force in milling process. A progress study on a real case. IEEE International Symposium on Intelligent Control, 121-125.
- Bukkapatnam S.T.S, A. Lakhtakia and S.R.T. Kumara (1995). Analysis of sensor signals shows turning on a lathe exhibits low-dimensional chaos, *Physics Review E* **52** (3), 2375-2387.
- Carotenuto, R. (2001). An iterative system inversion technique, *International Journal of Adaptive Control and Signal Processing* **15**, 85-91.
- Goodwin, G.C., S.F. Graebe and M.E. Salgado (2001) *Control System Design*, 567-582. Prentice Hall, NJ, USA.
- Haber R., J. Alique, S. Ros, and C. R. Peres (1996), Fuzzy supervisory control of end milling process, *Information sciences* **89**(1-2), 95-106.
- Haber R. E., A. Alique, S. Ros, and R. Haber (2002) *Application of knowledge-based systems for supervision and control of machining processes*, in Handbook of Software Engineering and Knowledge Engineering: Volume II: Emerging Technologies 673-709.
- Haber, R.E. and J.R. Alique (2004). Nonlinear internal model control using neural networks: Applications to machining processes, *Neural Computing and Applications* **13**, 47-55.
- Haber R.E., J.R. Alique, A. Alique, R. Haber-Haber (2005). Controlling a complex electromechanical process on the basis of a neurofuzzy approach, *Future Generation of Computer Systems* **21**(7), 1083-1095.
- Haber, R.E., K. Cantillo, and J. E. Jiménez (2005), Networked sensing for high-speed machining processes based on CORBA, *Sensors and Actuators A: Physical*, **119**(2), 418-426.
- Hagan, M.T., H.B. Demuth and O. De Jesús (2002). An introduction to the use of neural networks in control systems, *Int. Journal of Robust and Nonlinear Control* **12**, 959-985.
- Hunt, K.J., D. Sbarbaro, R. Zbikowski and P.J. Gawthrop (1992). Neural Networks for control systems- A survey. *Automatica* **28**(6), 1083-1112.
- Kambhampati, C., R.J. Craddock, M. Tham and K. Warwick (2000). Inverse model control using recurrent networks. *Mathematics and Computers in Simulation* **51**, 181-199.
- Landers, R. and A.G. Ulsoy (2000). Model-based machining control, *ASME Journal of Dynamics*

- Systems, Measurement and Control* **122(3)**, 521-527.
- Lauderbaugh L.K. and A.G. Ulsoy (1989). Model reference adaptive force control in milling. *ASME Journal Engineering of Industry* **111**, 13-21.
- Nelles, O. (2000). *Nonlinear system identification: From classical approaches to neural networks and fuzzy logic*. Springer Verlag, London.
- Norgard, M., O. Ravn, N.K. Poulsen and L.K. Hansen (2000). *Neural networks for modelling and control of dynamics systems*, Springer Verlag, London.
- Rivals, I. and L. Personnaz (2000). Nonlinear internal model control using neural networks: Application to processes with delay and design issues, *IEEE Transactions on Neural Networks* **11(1)**, 80-90.
- Rober, S.J. and Y.C. Shin (1996). Control of cutting force for milling processes using an extended model reference adaptive control scheme. *Journal of Manufacturing Science and Engineering* **118**, 339-347.