

Control de procesos por medio de dos configuraciones de redes neuronales. Una revisión

Process Control by Means of Two Configurations of Neural Networks. One Review

JOSÉ DANILO RAIRÁN ANTOLINES

Ingeniero Electricista y Magíster en Automatización Industrial de la Universidad Nacional de Colombia. Docente de la Universidad Distrital Francisco José de Caldas, en el programa de Tecnología en Electricidad. Director del grupo de investigación en Control Electrónico, reconocido por Colciencias en categoría B
drairan@udistrital.edu.co

FRANCISCO JAVIER MILLÁN RODRÍGUEZ

Tecnólogo en Electrónica de la Universidad Distrital Francisco José de Caldas y estudiante de Ingeniería en Control Electrónico e Instrumentación de la misma Universidad. Integrante del grupo de investigación en Control Electrónico.
francisco.j.millan.r@gmail.com

JOHN ANDERSON GUZMÁN PERDOMO

Tecnólogo en Electrónica de la Universidad Distrital Francisco José de Caldas y estudiante de Ingeniería en Control Electrónico e Instrumentación de la misma Universidad. Integrante del grupo de investigación en Control Electrónico.
jagp47@hotmail.com

Clasificación del artículo: revisión

Fecha de recepción: 22 de mayo de 2006

Fecha de aceptación: 13 de octubre de 2006

Palabras clave: control predictivo, control neuronal, redes de base radial, perceptrón, identificación.

Key Words: predictive control, neural control, radial bases network, perceptron, identification.

RESUMEN

En este artículo se explican las estrategias de control de dos configuraciones usando redes neuronales. La primera es denominada control, a partir de un modelo de referencia y utiliza redes de base radial; la se-

gunda es el control predictivo con redes perceptrón multicapa. Asimismo, como introducción al uso de los controladores neuronales, en la sección dos se estudian distintos esquemas de identificación, que también utilizan redes neuronales.

ABSTRACT

Control strategies of two configurations using neural networks are explained in this paper. The first is denoted model reference control and it uses radial

basic function networks. The second is predictive control by multilayer perceptron networks. Additionally, as an introduction to the use of neural controllers, different identification schemes which use neural networks too are studied in section two,

* * *

1. Introducción

Desde que W. Mc Culloch y W. Pitts presentaron la primera publicación referente al uso de redes neuronales (1943) se ha avanzado mucho en la definición de estructuras neuronales aplicadas a la solución de problemas industriales; sin embargo, no siempre fue así. La lejana fecha de la primera conferencia organizada por IEEE, realizada en San Diego (EUA) en 1987 así lo evidencia. El interés por el control de procesos utilizando redes neuronales se ha incrementado en la última década; esto se demuestra a partir de la gran cantidad de artículos científicos, tesis doctorales y libros relacionados con el tema.

La popularidad del tratamiento del tema se ha incrementado en razón de su habilidad para emular sistemas no lineales [1,2], aún sin conocimiento previo de ellos; en consecuencia, reducen el trabajo de identificación, considerado como el primer paso en el diseño de casi cualquier controlador. Cuando el aprendizaje se efectúa “fuera de línea” (por ejemplo en [3]), es suficiente con una muestra de las señales de entrada y salida (que deben representar toda la dinámica del sistema dentro su rango de funcionamiento) para que los algoritmos de entrenamiento empiecen a adecuar los pesos de la red, en apariencia sin intervención humana [4]. Otra característica favorable de las redes neuronales es que pueden adaptarse a los cambios en los parámetros de la planta que emulan [6-8], lo que se debe al aprendizaje en tiempo real con que pueden ser implementadas. Además, su lógica interna es simple; se basa en la transformación de los datos de entrada en los de salida por medio de multipli-

caciones, sumas, y cálculos de exponenciales, en la mayoría de los casos; esto implica que la ejecución de sus algoritmos no es exigente en cuanto a recurso computacional y, por tanto, pueden ser rápidas.

A pesar de lo anterior, cuando se usan redes neuronales no todo es ventajoso; por ejemplo, es difícil demostrar la estabilidad y robustez de un sistema controlado por estas redes antes de que sean implementadas (un ejemplo de ello se presenta en [9]). Esto ha hecho que algunos investigadores desistan de su utilización y prefieran otras estrategias, como el control H_∞ o LQ¹, con las cuales el análisis de estabilidad y robustez resulta más claro, aunque no sencillo [10]. Otro aspecto negativo es que prácticamente no existen criterios para seleccionar el número de neuronas en las capas ocultas de la red; tampoco puede definirse la función de activación más apropiada en función del problema, por lo que prima el método de ensayo error, basado en la experiencia del diseñador de la red.

En este artículo se estudiarán dos configuraciones de controladores neuronales, consideradas representativas de la gran cantidad de aplicaciones existentes: el control basado en un modelo de referencia y el control predictivo generalizado. La primera corresponde a una red dinámica (por medio de redes de base radial) que efectúa todo el proceso de control de la red. La segunda se basa en una red estática (tipo *feed forward*) que sólo sirve de apoyo en el proceso de control. Además de estas dos configuraciones, también es común el control mediante el modelo inverso [11, 12], por

¹ Por su sigla en inglés, Linear Quadratic (LQ) control

la linealización mediante realimentación [13], o el basado en el modelo interno; éstas y otras no mencionadas no fueron estudiadas, porque el número de artículos consultados que las utilizan es bajo, se trata de un esquema con más aplicaciones teóricas que prácticas, o es similar a alguna de las dos aquí incluidas².

En la sección dos se hace una introducción al proceso de identificación con redes neuronales, indispensable en cualquier esquema de control neuronal. En la sección tres se explica el control mediante el modelo de referencia, en el cuarto, el control predictivo neuronal, y en la cinco se enuncian las conclusiones del trabajo. Las referencias bibliográficas mostradas al final son uno de los aportes más importantes del artículo, ya que todas ellas son recientes y, a excepción de los libros, se encuentran disponibles en Internet.

2. Identificación de sistemas dinámicos mediante redes neuronales

La mayor producción científica en el campo del control corresponde al proceso de identificación. Por ejemplo, en [14] se clasifican 1.410 referencias sobre identificación de sistemas no lineales, todos con fechas anteriores a 2001; por facilidad ellas se clasifican en veinte categorías, de las que se destaca el procesamiento de señales, las comunicaciones y la ingeniería biomédica. Un trabajo similar puede consultarse en [15].

Una de las contribuciones más importantes para la identificación fue publicada en 1990, cuando Narendra y Parthasarathy demostraron que las redes neuronales identifican sistemas no lineales, y además son útiles para su control [1], por sus características

² El artículo es uno de los productos del grupo de investigación en Control Electrónico de la Universidad Distrital Francisco José de Caldas, que desarrolla un proyecto de investigación que concluirá con la construcción de tres controladores para la regulación del entrehierro en el proceso de levitación magnética esfera-bobina. El objetivo es comparar las tres estrategias de control y recomendar la más adecuada, de acuerdo con algunos indicadores que también generará el proyecto.

de adaptabilidad, robustez y paralelismo [16], especialmente cuando el proceso a modelar es una caja negra [17]. También cuando se conoce muy poco acerca de la dinámica del sistema [18], dado que se ajustan a la información de entrada-salida con que se les entrene, la cual es asumida como ejemplos en su proceso de aprendizaje [19].

El proceso de identificación implica cuatro etapas:

- Planeación del experimento para adquirir los datos con que se alimentará la red.
- Selección de la configuración de la red.
- Estimación de los parámetros del modelo (mediante la aplicación de algoritmos de aprendizaje).
- Validación [20].

En esta sección se abordará la etapa dos, mediante el estudio de cuatro configuraciones: paralelo, serie-paralelo, con conocimiento aproximado y redes modulares. Por otra parte, debe mencionarse que la identificación hecha por estas configuraciones es local (se entrenan con una muestra del comportamiento dinámico del sistema), en lugar de global, que es lo ideal [21]; esto puede generar inconvenientes a la hora de implementar el controlador, pues es posible que el modelo presente dinámicas contrarias a las de la planta en regiones en las que no fue entrenada y puede generarse inestabilidad luego de iniciar el proceso de control [22].

2.1. Identificación en paralelo

Es la configuración más sencilla, útil cuando el sistema a modelar no tiene memoria, es decir, cuando la salida actual no depende del valor de entrada o salida en los instantes anteriores [23], como se presenta en la predicción de la temperatura de la soldadura eléctrica en [24]. Se estudia porque incluye el procedimiento básico sobre el cual se realizarán mejoras hasta alcanzar modelos más complejos, por tanto con mayores prestaciones. En este caso la identificación consiste en entrenar la red para que el error (definido en el diagrama 1)

se minimice; por ejemplo, por medio del algoritmo de retropropagación del error [4, 8, 25].

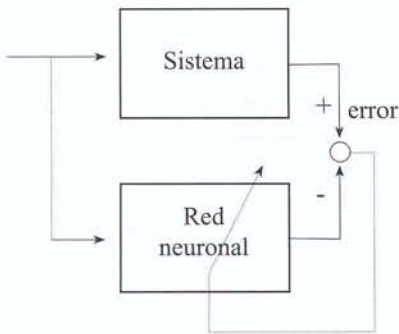


Diagrama 1. Configuración paralelo para identificación

2.2. Identificación serie-paralelo

En esta configuración la salida actual depende de la anterior (como se observa en el diagrama 2), luego es útil en el modelado de sistemas de primer orden. Una modificación de su configuración es la más popular en identificación: una red *feedforward*, alimentada por el bloque TDL (*Time Delay Line*) mostrado en diagrama 3. Este bloque se encarga de memorizar la entrada y la salida para alimentar la red, de manera que ésta se entrena con la dinámica del sistema. El resultado es que la red, estática por definición, se convierte en dinámica (DNN) [17]. Algunas redes dinámicas por naturaleza son la red Hopfield (presentada en 1984), Jordan (en 1989) y Elman (en 1990).




Diagrama 2. Configuración serie paralelo para identificación

La identificación a partir de la relación causa-efecto de la entrada-salida tiene una limitación importante: el modelo resultante no puede utilizarse para inferir la dinámica interna del sistema identificado [22]. Cuando se necesita memorizar toda la dinámica, los estados del sistema se usan como entradas de la red; sin embargo, esto no es posible en todas las aplicaciones, porque no siempre pueden medir tales estados.




Diagrama 3. Línea de retardo de tiempo (TDL) para identificación

Un ejemplo de red serie-paralelo es el modelo del sistema de levitación magnética esfera-bobina mostrado en [26], implementado en una red *feedforward*. El diagrama 4 sólo muestra la parte de la red generada a partir del modelo linealizado en la ecuación (1), dado que el resto de la dinámica se aprende en tiempo real. En (2) se muestra el resultado de escribir (1) como una serie de tiempo, teniendo en cuenta la aproximación con retenedor de orden cero (ZOH) con un tiempo de discretización de 2 ms.

$$\frac{X(S)}{I(S)} = \frac{-25,6796}{(S + 39,1546)(S - 39,1546)} \quad (1)$$

$$x(k) = b_0 i(k) + b_1 i(k-1) + b_2 i(k-2) + a_1 x(k-1) + a_2 x(k-2) \quad (2)$$

En (1), $X(S)$ denota el entrehierro e $I(S)$ la corriente de alimentación. En (2) $b_0 = 0$; $b_1 = -0,5138 \cdot 10^{-4}$; $b_2 = -0,5138 \cdot 10^{-4}$; $a_1 = 2,0061$; $a_2 = -1$.

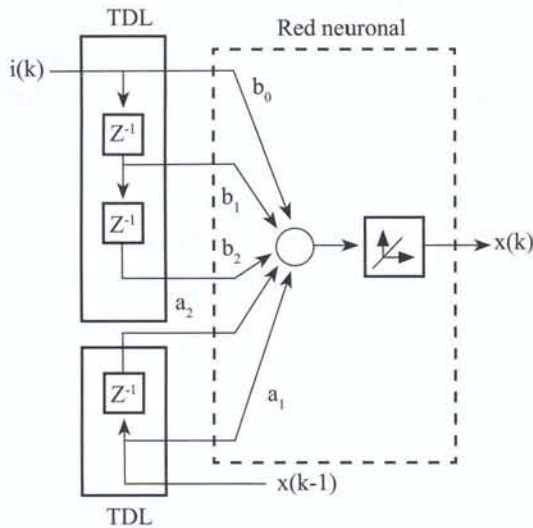


Diagrama 4. Red *feedforward* alimentada por dos líneas de retardo

Las siguientes son algunas aplicaciones de redes *feedforward*. En [17] se modela un sistema de segundo orden no lineal y un sistema caótico definido por la ecuación de Duffing; en [27] se explica el procedimiento de utilización de un perceptrón multicapa (MLP) para identificación; [28, 29] muestran la relación entre el modelo neuronal y el tipo NARX (*autoregressive with exogenous input*); [30] implementa un controlador neuronal adaptativo en modo deslizante para regular la trayectoria de un vehículo modular no holonómico, que requiere de la identificación con una red perceptrón multicapa.

2.3. Identificación a partir de un modelo aproximado

En este caso la red neuronal aprende a completar el modelo bajo la premisa de que es mejor comenzar a identificar la dinámica en un punto cercano al que se quiere llegar, en lugar de hacerlo de manera aleatoria. Por ejemplo, la identificación del sistema de levitación magnética del ítem anterior utiliza este enfoque. Se comienza con una red *feedforward* que consiste en la implementación de la ecuación en series de tiempo del modelo linealizado; luego el resto de la red (con funciones de activación sigmoide o tangente hiperbólica) completa la dinámica

no lineal. Esta configuración resulta adecuada en la implementación de un controlador neuronal en tiempo real para este sistema [26, 31].

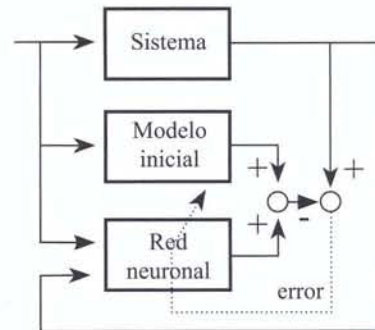


Diagrama 5. Identificación a partir de un modelo aproximado.

2.4. Identificación a partir de redes modulares

Se trata de emular el funcionamiento de la corteza cerebral, en la que grupos pequeños de neuronas constituyen un módulo y realizan operaciones independientes, que sumadas resultan más poderosas que una sola red compleja con el mismo número de neuronas [32, 33]. El trabajo consiste en ejecutar funciones más complejas que las que llevaría a cabo un solo módulo mediante la división en subproblemas más pequeños y sencillos que el original, bajo el principio “divide y vencerás” [34, 35].

Las redes modulares son muy utilizadas en la actualidad en el campo de la robótica, por ejemplo para la conducción de un camión compuesto por varios bloques; cada red se encarga de una tarea (mantener la dirección o una velocidad de un bloque independiente) para lograr que el vehículo completo pueda parquear en reversa [13]. La estructura de la red es la mostrada en el diagrama 6; en ella se muestran sólo dos módulos, a manera de ejemplo.

En este tipo de redes el trabajo más importante es la solución del problema de competencia y cooperación entre módulos [35]; esto es, en generar las reglas que definan la contribución de cada módulo al sistema total.




Diagrama 6. Identificación con redes neuronales modulares (MNN)

La clasificación de configuraciones estudiada no cubre todas las posibilidades en modelado de sistemas por medio de redes neuronales, pero sí la mayoría. Sin embargo, es importante relacionar algunos trabajos adicionales que demuestran la amplitud del tema y la cantidad de variantes identificadas. En [36] se utilizan redes neuronales basadas en el análisis de Fourier, para la identificación de sistemas no lineales; una posible aplicación es el control en lazo cerrado de sistemas BIBO (*Bounded Input Bounded Output*). En [37] se encuentran los parámetros de la red por medio de algoritmos evolutivos, sobre seis funciones objetivo que se reparten en dos clases.

En [38] se identifican sistemas con retardos de tiempo variable; [28, 60] estudian la aplicación de las redes neuronales en sistemas con pasividad, es decir, los que resultan estables con cualquier esquema de realimentación negativa; en [29, 39] se identifican sistemas lineales discretos variantes en el tiempo.

3. Control basado en un modelo de referencia

Esta sección comienza con la presentación de las redes neuronales basadas en funciones de base radial (RBF, por su sigla en inglés). Una vez definidas se explica su utilización como identificadoras de sistemas no lineales, y luego la forma de control a partir de su uso.

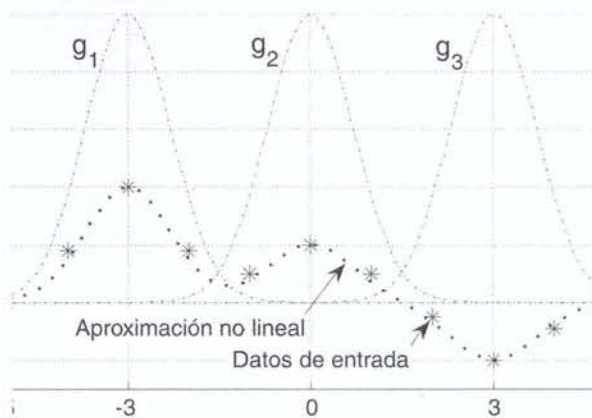
En las ecuaciones (3) y (4) se definen las funciones de base radial gaussiana y multicuadrática de Hardy inversa, respectivamente [23]. En ellas r mide la

distancia entre la entrada y el centro donde está ubicada la función ($r_i = x_i - C$); d es un parámetro que define el rango de influencia de la función, el cual se incrementa a medida que d es mayor.

$$g(r) = e^{-\frac{\|r\|^2}{d^2}} \quad (3)$$

$$g(r) = \left(1 + \frac{\|r\|^2}{d^2}\right)^{-1/2} \quad (4)$$

Con el fin de explicar el uso de las funciones de base radial, en la gráfica 1 se agregan algunos datos con coordenadas (x,y) , denotados por asterisco, los cuales deben ser aproximados mediante una función. Se selecciona $g(r)$, como en la ecuación (3), y tres de ellas se distribuyen en el rango de interés $[-5, 5]$; enseguida se ajusta d , de manera que las redes no se traslapen; luego, se establece la influencia de cada función, ponderando la participación de cada una para lograr aproximar la función no lineal $y = f(x)$.



Gráfica 1. Aproximación de una función no lineal

La gráfica 1 permite afirmar que la aproximación no lineal (línea punteada) generaliza el comportamiento de los datos en el rango de entrada, es decir, los “identificó”. La mayoría de aplicaciones de redes de base radial se encuentran precisamente en identificación; por ejemplo, la obtención de un modelo para el proceso de descomposición de óxido de nitrógeno

en plantas térmicas [40], la identificación de la relación entre parámetros para el control de temperatura de un invernadero [41] o su uso en situaciones tan disímiles como el modelado de un brazo de robot [42], la simulación del comportamiento de fluidos para efectos especiales [43], el funcionamiento de un sistema de potencia [44] o el calentamiento de una máquina [21].

La forma más común de configurar RBF se presenta en el diagrama 7; en ella X es el conjunto de entradas, G las funciones de base radial, W una matriz de pesos y Y el vector de salidas. Sin embargo, esta configuración sólo es útil cuando las salidas no dependen de estados anteriores. Para aumentar las aplicaciones de esta red se han experimentado algunas configuraciones que permiten memorizar, para poder generalizar la dinámica de un sistema. Una posibilidad es que las entradas sean alimentadas por un línea de retardo de tiempo (TDL), como se explicó en la sección 2; otra consiste en realimentar el estado anterior de cada salida como entradas adicionales a las funciones de base radial; pero la opción más común es la utilización de filtros FIR (*Finite Impulse Response*) o IIR (*Infinite Impulse Response*), en el lugar donde aparecerían los pesos de la red.




Diagrama 7. Red de base radial para R entradas y M salidas.

Un filtro FIR se utiliza cuando sólo se requiere memorizar la influencia de los estados anteriores de la entrada al mismo, y un IIR si además se necesitan memorizar los estados de la salida [5]. Al implementar un filtro ya no se calculan pesos sinápticos,

sino que se ajustan coeficientes, por ejemplo, el del filtro IIR en la ecuación (5). En la red de el diagrama 8 se utilizan N de estos filtros.




Diagrama 8. Red de base radial para identificar sistemas dinámicos

$$H_j(Z) = \frac{a_{j0} + \sum_{t=1}^T a_{jt} Z^{-t}}{1 + \sum_{s=1}^S b_{js} Z^{-s}} \quad (5)$$

El proceso de entrenamiento de la red en el diagrama 8 consiste en reducir el error ($E(k) = \frac{1}{2}(y_n(k) - y_d(k))^2 = \frac{1}{2}e(k)^2$), en el cual $y_d(k)$ es la salida deseada y $y_n(k)$ la salida de la red. En (6) se definen los ajustes de los coeficientes a y b del filtro; α_1 y α_2 regulan la velocidad de aprendizaje de la red y son motivo de estudio en el análisis de estabilidad mediante el método de Lyapunov [45-47].

$$\Delta a_{jt}(k) = -\alpha_1 \cdot e(k) \cdot \frac{\partial y_n(k)}{\partial a_{jt}(k)} \quad (6)$$

$$\Delta b_{js}(k) = -\alpha_2 \cdot e(k) \cdot \frac{\partial y_n(k)}{\partial b_{js}(k)}$$

Al extender la idea de cambiar un peso sináptico por un filtro cuya salida sea función de los valores anteriores de entrada pueden diseñarse varios esquemas; uno de ellos se conoce como red doble recurrente y es el recomendado para emular sistemas dinámicos no lineales. Su configuración se presenta en el diagrama 9.




Diagrama 9. Red doble recurrente

El superíndice W en el diagrama 9 indica que F_i es un filtro FIR sobre la conexión sináptica; el R significa que se trata de un FIR de realimentación. Las salidas de los filtros se definen en la ecuación (7). El ajuste de los coeficientes a_{ij} se logra mediante la ecuación (6), en la cual un coeficiente α ajusta el filtro sináptico y otro el de realimentación; estos deben estar en el rango $0 < \alpha_i < 1/|\partial Y_N/\partial A|$, si se quiere lograr estabilidad en el sentido Lyapunov [23], es decir, α está relacionada con la norma de la variación de la salida de cada filtro, Y_N , con respecto al cambio de los pesos, recopilado en A .

$$y_i(k) = \sum_{j=0}^{R-1} a_{ij}^W \cdot g_i(k-j) \quad (7)$$

$$x_i'(k) = \sum_{j=1}^S a_{ij}^R \cdot g_i(k-j)$$

En el control por medio de redes de base radial pueden distinguirse dos casos, en función del origen de la información para calcular el ajuste de los pesos: en uno se conoce la función matemática que representa la planta y en el otro no; además, el ajuste depende del gradiente del error con respecto al cambio de los pesos, como expresa la ecuación (8), en la que $e(k)$ es el error en la iteración k ; $\partial u(k)/\partial \omega_i(k)$ depende de la estructura de la red, y $\partial y(k)/\partial u(k)$ mide la variación de la salida de la planta en función del voltaje de control, según el esquema en el diagrama 10.

En el diagrama 10, NN2 es una red neuronal que emula la planta y NN1 la controla; ambas están compuestas por redes de base radial en configuración doble recurrente. En estas redes se generan errores que sirven para auto-ajustar los coeficientes de los filtros; el primero es $e^l(k)$, y actúa sobre NN2 en tiempo real (esto indica que la red es adaptativa, pues se actualiza durante el funcionamiento del sistema respondiendo a cambios en los parámetros de la planta); el segundo error, $e^c(k)$, mide la diferencia entre la salida de la planta y un modelo de referencia; éste último puede estar compuesto por un polinomio característico tipo ITAE o Bessel, entre otros, cuando se necesita optimizar el uso de energía o lograr una respuesta sin sobrepico, respectivamente.

$$\frac{\partial E(k)}{\partial \omega_i(k)} = e(k) \cdot \frac{\partial y(k)}{\partial u(k)} \cdot \frac{\partial u(k)}{\partial \omega_i(k)} \quad (8)$$

El esquema de control con modelo de referencia implica una filosofía distinta a la del control convencional (por ejemplo PID), dado que las correcciones no buscan que la salida siga una señal de referencia $r(k)$, sino que se reduzca la diferencia entre la salida de un sistema asumido como ideal y la planta; de esta manera el voltaje de control presenta transiciones más suaves.




Diagrama 10. Control neuronal basado en un modelo de referencia

Las aplicaciones de las redes de base radial en control son diversas, aunque son más comunes en identificación. En algunos trabajos se utilizan en el control de sistemas de primer orden no lineales, caso en que la red aprende la no linealidad y la compensa [45]; como aplicación teórica también se controla la posición de dos péndulos invertidos conectados por resorte [19, 48]; en robótica existen aplicaciones como el control de posición angular de un brazo flexible [42]. Asimismo, las redes de base radial colaboran en el control de la estabilidad y el manejo de transitorios en sistemas de potencia, cuando estos incluyen parámetros variantes en el tiempo [44]; también son útiles en el control de la frecuencia en un láser [49]. Adicionalmente, existen las aplicaciones teóricas presentadas en [50, 51], de control mediante linealización por realimentación y control adaptativo directo [25, 52].

4. Control predictivo con redes neuronales

Esta estrategia controla mediante la optimización de un índice dependiente del comportamiento futuro del sistema [53], luego la precisión del modelo de predicción es crítica. En este artículo se asume que el modelo está compuesto por redes neuronales de base radial (RBF) o perceptron multicapa (MLP).




Diagrama 11. Diagrama de bloques para el control predictivo

El proceso de control consiste en determinar el valor de control $u(n + 1)$, a partir del comportamiento futuro del sistema [54]; esto hace imposible garantizar estabilidad o robustez *a priori*, lo que puede considerarse como negativo. Mientras se realiza la predicción, los interruptores s del diagrama 11 hacen que la planta quede desconectada; aún así ésta debe ser alimentada con el valor de control actual $u(n)$, hasta que se determine $u(n + 1)$.

El primer paso en el proceso de control consiste en definir y_r , es decir, la forma como la red neuronal debe cambiar su valor inicial ($y_m(n) = y_p(n)$) hasta alcanzar el valor de consigna (ver diagrama 12). Lo que sigue es hacer que la salida de la red y_m se acerque al máximo a y_r ; esto se logra modificando el valor de control $u(n + 1)_i$, comenzando por el que alimenta la planta real en ese instante ($u(n + 1)_i = u(n)$). Cuando se encuentra un valor de control adecuado se cambia la posición de los interruptores y se alimenta con él a la planta.

Además de minimizar la diferencia entre y_r y y_m , es recomendable tener en cuenta el cambio en el

valor de control ($\Delta u = u(n+1) - u(n)$), penalizando valores elevados mediante un coeficiente de ponderación λ ; de esta manera, se define la suavidad con que y_p se presentará. Todo el proceso de control ya explicado se resume en un algoritmo de optimización [31] que se explicará a continuación.

- Selección de la ventana de predicción $[N_1 N_2]$, el horizonte de control N_U y el coeficiente λ . Estos son los parámetros que permiten sintonizar al controlador.
- Generación de la trayectoria de referencia y_r en la ventana de predicción.
- Simulación del comportamiento del sistema y_m usando la red neuronal, alimentada con el valor de control actual $u(n)$.
- Selección de $u(n+1)$, buscando que minimice la función de costo descrita en la ecuación (9).
- Repetición de los pasos 3 y 4, hasta que $u(n+1)_i - u(n+1)_{i-1}$ sea menor a una cota que depende de la precisión deseada para el cálculo. A manera de ejemplo, en el diagrama 12 fue necesario iterar el algoritmo de minimización tres veces.
- Asignación del valor de control del paso 5 como $u(n+1)$ y alimentación de la planta real con éste. En este paso debe cambiarse la posición de los interruptores s del diagrama 12.
- Repetición desde el paso 1, todo el tiempo que quiera controlarse el sistema.




Diagrama 12. Proceso de control

En forma simultánea a la alimentación de la planta y antes de correr el algoritmo de optimización pue-

de usarse un algoritmo de entrenamiento a la red neuronal en línea; de esta manera, la red se adaptará a los cambios en la planta real. Además puede emplearse la identificación a partir de un modelo aproximado, como se explicó en la sección 2.3, en la cual el modelo se perfecciona en línea a medida que el tiempo pasa.

$$J = \sum_{i=N_1}^{N_2} [y_r(n+i) - y_m(n+i)]^2 + \lambda \sum_{i=1}^{N_{ii}} [u(n+i-1) - u(n+i-2)]^2 \quad (9)$$

Algunos de los algoritmos de optimización son: Newton-Raphson, simplex y de programación cuadrática sucesiva [53]; el primero resulta costoso en cuanto a recurso computacional, pero converge en pocas iteraciones; por esto es el utilizado en la mayoría de aplicaciones.

A continuación, se enunciarán algunos trabajos que demuestran la popularidad del control predictivo mediante redes neuronales, divididos en experimentales y teóricos. Como parte del primer grupo, en [55] se resalta la importancia de la identificación de un sistema MIMO (*Multiple Input Multiple Output*) para el control experimental de un evaporador de circulación forzada de carácter no lineal; en [56] se controla un tubo generador de vapor y los resultados se comparan con un control proporcional integral convencional *PI*; el resultado es una mejora en la estabilidad del sistema; el estudio de la NASA [26] es particularmente útil para los interesados en la levitación magnética, dado que presenta los resultados de la aplicación en tiempo real de este tipo de sistema.

Continuando con la descripción, en [57] se investiga el uso de las redes neuronales para el control de una planta pasteurizadora y se comparan los resultados con los de un PID; el control del proceso de soldadura eléctrica [58] implica, además, el uso del control difuso, para observar la corriente y velocidad de soldadura. Finalmente, en [59] se aplica el control predictivo no lineal para mantener la concentración de glucosa en valores normales, especialmente con el tipo uno de diabetes.

Diversas aplicaciones teóricas o desarrolladas con plantas simuladas también fueron identificadas; [22] se centra en la calidad esperada del modelo base para el control predictivo, y demuestra los resultados en un sistema SISO (*Single Input Single Output*) no lineal; en [53] se supone que el modelo de un elevador es $d^3y(t)/dt^3 = u(t)$ y, a partir de él, se demuestra la utilidad del control predictivo; el trabajo se constituye en punto de partida para entender a cabalidad esta estrategia. [31] presenta los mayores detalles acerca de la aplicación del algoritmo de optimización Newton-Raphson, controlando algunas plantas no lineales al final. En [21] el control predictivo se implementa en un conjunto de plantas a escala de laboratorio, una de las que simula el proceso de calentamiento de agua por medio de una resistencia.

[60] es uno de los pocos trabajos que trata la estabilidad, por medio del método de Lyapunov. Por otra parte, en [61] se expone una aplicación interesante con respecto al control de sistemas caóticos; se supone un sistema desconocido y éste se identifica a partir de la relación entrada-salida. Otro trabajo referente a un sistema simulado mediante ecuaciones es [40], en que se estudia el proceso de descomposición del óxido de nitrógeno (variante en el tiempo), asumido como linealizable localmente. En [62] se trabaja con sistemas que no están descritos en espacio estado, como es usual, sino con procesos de decisión de Markov. En [63] la aplicación es aeroespacial y en él se determina el torque de entrada necesario para que un modelo simulado siga una trayectoria; resulta importante porque hace un análisis de robustez y porque compara sus resultados con un controlador PD convencional. En [54] se simula el proceso de control de pH, y en [64] se simula y controla un mezclador de flujo.

Otros artículos que deben resaltarse son [65-67], debido a que presentan aplicaciones comerciales del control predictivo, lo que demuestra la popularidad de esta estrategia. En [65, 66] se presenta el desarrollo de una biblioteca en *Simulink* de Matlab que trabaja con sistemas no lineales, identificados por redes neuronales tipo MLP. Finalmente, en [67] se

expone una aplicación al control de una columna de vacío en una refinería.

5. Conclusiones

- Antes de reemplazar los controladores convencionales por neuronales debe analizarse la posibilidad de combinación de los primeros. Por ejemplo, en [71] se conecta un PID en paralelo con un controlador neuronal, con el fin de manejar un sistema matemático no lineal. Una aproximación similar se encuentra en [73], en el que se suman las dos correcciones, pero para el control de posición del robot A460.

El algoritmo PID también puede emularse con una red neuronal [72], con tres entradas ($e(k)$, $\Sigma e(k)$, $e(k)-e(k-1)$), una capa oculta con dos neuronas y una salida; ésta fue utilizada en el control del proceso de enfriamiento de ácido sulfúrico en dos tanques. En [74] se estudia la implementación del control inteligente en la dirección de misiles, ella comenzó por el triple lazo convencional con PID, pasó por controladores difusos neuronales y, por supuesto, por la combinación de los tres. Luego de dominar los controladores neuronales puede trabajarse con neurodifusos, o con combinaciones con otras

estrategias, por ejemplo, con algoritmos genéticos. En este sentido, la contribución encontrada en [69] es importante; allí se implementa un controlador neurodifuso en una FPGA; otros ejemplos se encuentran en [70] y [74].

- La navegación aérea es una de las aplicaciones con mayor futuro para el uso de controladores neuronales, o híbridos: vehículos autónomos, manejo de fallas múltiples o vehículos espaciales reutilizables son algunos de los desarrollos posibles, como se expone en [10], [63], [74], [75].
- La mayoría de aplicaciones de control neuronal se producen en la robótica [7], [9], [12], [30], [42], [52], [70], [73] y la industria química. [3], [6], [21], [25], [39], [40], [41], [54], [55], [56], [67].
- Análisis de estabilidad y estudios de robustez son dos temas no desarrollados en profundidad; la elaboración de criterios para prever el número de capas ocultas y de neuronas por capa también puede ser importante. En general, se requieren más trabajos que aumenten el espectro sectorial en el que se aplican los controladores neuronales en tiempo real, por ejemplo como sistemas embebidos.

Referencias bibliográficas

- [1] Levin, U. A., and Narendra, S. K. (Marzo 1993). "Control of Nonlinear Dynamical Systems Using Neural Networks: Controllability and Stabilization". *IEEE Transactions on Neural Networks*, Vol. 4 (2), pp. 192-206.
- [2] Limanond, S., and Si, J. (November 1998). "Neural-Network-Based Control Design: An LMI Approach". *IEEE Transactions on Neural Networks*, Vol. 9 (6), pp. 1422-1429.
- [3] Venayagamoorthy, G. K., Wunsch, D. C., and Harley, R. G. (September 29-October 2 1999). "Neurocontrol of Turbogenerators with Adaptive Critic Designs". *Proceedings of the IEEE AFRICON Conference*, Cape Town, South Africa, pp. 489-494.
- [4] Patankar, A., and Koduru, P. (November 2001). "Modeling and Control of Circulating Fluidized Bed Using Neural Networks". *Annual Project Report University/NETL Partnership Program* (Subcontract agreement No. 001060-2 under prime DOE agreement No. DE-FC-26-98FT40143), pp. 1-38.
- [5] Oppenheim, A., Schafer R., y Buck J. (2000). *Tratamiento de señales en tiempo discreto*. Ed. Prentice Hall, 2ª ed., Madrid.
- [6] Conradie, A. V. E., Miikkulainen, R., and Aldrich, C. (2002). "Adaptive Control Utilising Neural Swarming". *Proceedings of the Genetic and Evolutionary Computation Conference*. New York, USA. pp. 1-13.
- [7] Rivals, I., Personnas, L., Dreyfus, G., and Canas, D. (1993). "Real-Time Control of an Autonomous

- Vehicle: A Neural Network Approach to the Path Following Problem". *5th International Conference on Neural Networks and their Applications*, pp. 1-11.
- [8] Hoskinson, R., Van den Doel, and Fels, S. (2003). "Realtime Adaptive Control of Modal Synthesis". *Proceedings of the International Conference on New Interfaces for Musical Expression*. Montreal, pp. 99-103.
- [9] Cox, C., Mathia, K., Edwards, J., and Akita, R. (1996). "Modern Adaptive Control with Neural Networks". *International Conference on Neural Networks Information Processing, ICONIP 96, Hong Kong*, pp. 1-5.
- [10] Battipede, M., Gili, P., Lando, M., and Massotti, L. (April 2003). "Post-Failure Analysis of an Adaptive Predictor-Corrector Neural Controller on a Flight Simulator". *ESANN'2003 Proceedings-European Symposium on Artificial Neural Networks*. Bruges (Belgium), pp. 413-418.
- [11] Rivals, I., and Personnaz, L. (June 1996). "Internal Model Control Using Neural Networks". *Proceedings of the IEEE International Symposium on Industrial Electronics*, pp. 1-6.
- [12] Maeda, Y., and Figueiredo, P. J. (September 1997). "Learning Rules for Neuro-Controller Via Simultaneous Perturbation". *IEEE Transactions on Neural Networks*, Vol. 8 (5), pp. 1119-1130.
- [13] Widrow, B., and Lamengo, M. M., (March 2002). "Neurointerfaces". *IEEE Transactions on Control Systems Technology*, Vol. 10 (2), pp 221-228.
- [14] Giannakis, G. B., and Serpedin E. (2001). "A Bibliography on Nonlinear System Identification". *Signal Processing 81 Elsevier Science B.V.*, pp. 533-580.
- [15] Zhao, V., and Viswanathan S. (2004). "Intelligent Systems for HAZOP Analysis". *School of Chemical Engineering, Purdue University*, pp. 1-83.
- [16] Olivera, J. (1997). "Identification of Dynamic System Using Neural Network". *The scientific journal FACTA UNIVERSITATIS. Series: Architecture and Civil Engineering*, Vol. 1 (4), pp. 525-532.
- [17] Poznyak, S. A., Wen Yu, Sánchez, E. N., and Pérez, P. J. (November 1999). "Nonlinear Adaptive Trajectory Tracking Using Dynamic Neural Networks". *IEEE Transactions on Neural Networks*, Vol. 10 (6), pp. 1402-1411.
- [18] Zhihong, M., Wu, H. R., and Palaniswami, M. (September 1998). "An Adaptive Tracking Controller Using Neural Networks for a Class of Nonlinear Systems". *IEEE Transactions on Neural Networks*, Vol. 9 (5), pp. 947-955.
- [19] Naira Hovakimyan, Anthony J. Calise, and Nakwan Kim. (October 2004). "Adaptive Output Feedback Control of a Class of Multi-Input Multi-Output Systems Using Neural Networks". *International Journal of Control*, Vol. 77 (15), pp. 1318-1329.
- [20] Mills, M. M., Zomaya, A. Y., and Tadé, M. O. (1996). *Neuro-Adaptive Process Control. A Practical Approach*. Ed. WILEY (John Wiley & Sons), New York.
- [21] Koivisto, H. A. (1995). "Practical Approach to Model Based Neural Network Control". *Academy of Finland, Technology Development Centre in Finland, Foundation for the Advancement of Technology in Finland and Wihuri Foundation*, pp. 1-177.
- [22] Fache, A., Dubois, O., and Billat, A. (April 1999). "On the Invertibility of the RBF Model in a Predictive Control Strategy". *ESANN'1999 Proceedings-European Symposium on Artificial Neural Networks*. Bruges (Belgium), D-Facto public, pp. 381-386.
- [23] Boquete, V. L., Barea, N. R. (1998). *Control neuronal. Servicio de publicaciones, Imprenta de la Universidad de Alcalá, Universidad de Alcalá, Departamento de Electrónica, Monografía*, pp. 1-181.
- [24] Coit, W. D., Tuner, J. B., and Smith E. A. (2002). "Neural Network Open Loop Control System for Wave Soldering". *Journal of Electronics Manufacturing*, Vol. 11(1), pp. 95-102.
- [25] Oliveira, C. D., and Moneira, H. E. (2003). "Direct Adaptive Control Using Feedforward Neural Networks". *Revista Controle & Automação*, Vol. 14 (4), pp. 348-358.
- [26] Haley, J. P., Soloway, D., and Gold B. (1999). Real-Time Adaptive Control Using Neural Generalized Predictive Control. *National Aeronautics and Space Administration (NASA) Langley Research Center Hampton, Virginia. NASA Technical*, pp. 4278-4282.
- [27] Jha, R., and He C (April 2002). "Neural Network Based Adaptive Predictive Control for Vibration Suppression". *American Institute of Aeronautics and Astronautics, 43rd AIAA/ASME/ASCE/AHS/ASC Structures, Structural Dynamics, and Materials*, pp. 1.
- [28] Reyes, R. J., YU, W., and Poznyak, S. A. (2000). "Passivation and Control of Partially Known Siso Nonlinear Systems Via Dynamic Neural Networks". *Mathematical Problems in Engineering, OPA (Overseas Publishers Association) N.V.*, Vol. 6, pp. 61-83.
- [29] Dudul, S. V., and Ghatol A. A. (January 2004). "Identification of Linear Dynamical Time-Variant Systems using Feedforward Neural Network". *IE (I) Journal-ET*, Vol. 84, pp. 66-71.
- [30] Yangmin Li and Yugang Liu. (December 2004). "Sliding Mode Adaptive Neural-Network Control for Nonholonomic Mobile Modular Manipulators". *2nd International Conference on Autonomous Robots and Agents*, Palmerston North, New Zealand, pp. 95-100.

- [31] Soloway, D., and Haley, J. P. (1997). "Neural Generalized Predictive Control: A Newton-Raphson Implementation". *NASA Technical Memorandum 110244*, pp. 1-17.
- [32] Azam, F. (2000). *Biologically Inspired Modular Neural Networks*. Dissertation submitted to the Faculty of the Virginia Polytechnic Institute and State University in partial fulfilment of the requirements for the degree of Doctor of Philosophy in Electrical and Computer Engineering, May, Blacksburg, Virginia.
- [33] Poirazi, P., Neocleous, C., Pattichis, C. S., and Schizas, C. (May 2004). "Classification Capacity of a Modular Neural Network Implementing Neurally Inspired Architecture and Training Rules". *IEEE Transactions on Neural Networks*, Vol. 15 (3), pp. 597-612.
- [34] Zwaag, V. D., and Spaanenburg, K. S. (2002). "Process Identification through Modular Neural Networks and Rule Extraction". *World Scientific*, Netherlands, pp. 1-10.
- [35] Franco, L., and Cannas, S. A. (2001). "Generalization Properties of Modular Networks: Implementing the Parity Function". *IEEE Transactions on Neural Networks*, Vol. 12, pp. 1306-1313.
- [36] Dzielinski, A. (2002). "Neural Network-Based Narx Models in Non-Linear Adaptive Control". *Int. J. Appl. Math. Comput. Sci.*, Vol. 12 (2), pp. 235-240.
- [37] Ferariu, L., and Marcu, T. (2002). "Evolutionary Design of Dynamic Neural Networks Applied to System Identification". *15th Triennial World Congress IFAC*, Barcelona, España, pp. 1-6.
- [38] Yonghong Tan. (2004). "Time-Varying Time-Delay Estimation for Nonlinear Systems Using Neural Networks". *Int. J. Appl. Math. Comput. Sci.*, Vol. 14 (1), pp. 63-68.
- [39] Yu, W., Moreno, M., Gómez, R. E. (July 2004). "Modelling of Gasoline Blending Via Discrete Time Neural Networks". *International Joint Conference on Neural Networks -IEEE*. Budapest, Hungary, pp. 1291-1296.
- [40] Peng, H., Ozaki, T., Toyoda, Y., Shioya, H., Nakano, K., Haggan-Ozaki, V., and Mori, M. (2004). "RBF-ARX Model-Based Nonlinear System Modeling and Predictive Control with Application to a NOx Decomposition Process". *Elsevier Science, Control Engineering Practice* 12, pp. 191-203.
- [41] Yu, C., Ying, Y., Wang J., Nourain J., and Yang, J. (2005). "Determining Heating Pipe Temperature in Greenhouse Using Proportional Integral Plus Feedforward Control and Radial Basic Function Neural-Networks". *Journal of Zhejiang University SCIENCE*, pp. 265-269.
- [42] Wedding, D. K. and Eltimsahy, A. H. (2000). "Flexible Link Control Using Multiple Forward Paths, Multiple RBF Neural Networks in a Direct Control Application". *SMC 2000 Conference Proceedings of the 2000 IEEE International Conference on Systems, Man & Cybernetics*, Vol. 4, pp. 2619-2624.
- [43] Pighin, F., Cohen, J., and Shah, M. (2004). "Modeling and Editing Flows Using Advected Radial Basis Functions". *Eurographics/ACM SIGGRAPH Symposium on Computer Animation*, R. Boulic, D. K. Pai (Editors), pp. 1-10.
- [44] Atanasova, T., and Zaprianov, J. (1999). "Performance of the RBF Neural Controller for Transient Stability Enhancement of the Power System". *International Conference on Accelerator and Large Experimental Physics Control Systems*, Trieste, Italy, pp. 281-283.
- [45] Patiño, H. D., and Liu, D. (February 2000). "Neural Network-Based Model Reference Adaptive Control System". *IEEE Transactions on Systems, Man, And Cybernetics-Part b: Cybernetics*, Vol. 30 (1), pp. 198-204.
- [46] Liu, G., Kadiramanathan V., and Billings S. (February 1999). "Variable Neural Networks for Adaptive Control of Nonlinear Systems". *IEEE Transactions on Systems, Man, and Cybernetics-Part c: Applications and Reviews*, Vol. 29 (1), pp. 34-43.
- [47] Yu, W., Poznyak, S. A., and Álvarez, J. (1999). "Neuro Control for Multicomponent Distillation Column". *14th World Congreso of IFAC*, paper (7a-12-6), pp. 378-384.
- [48] Spooner, T. J., and Passino, M. K. (November 1999). "Decentralized Adaptive Control of Nonlinear Systems Using Radial Basis Neural Networks". *IEEE Transactions on Automatic Control*, Vol. 44 (11), pp. 2050-2057.
- [49] Ricci L., and Tecchiolli G. (May 1997). "A Neural System for Frequency Control of Tunable Laser Sources". *IEEE Instrumentation and Measurement Technology Conference*, Ottawa, Canada, pp. 1-7.
- [50] Shuzhi, S., and Cong, W. (January 2002). "Direct Adaptive NN Control of a Class of Nonlinear Systems". *IEEE Transactions on Neural Networks*, Vol. 13 (1), pp. 214-221.
- [51] Nam, K. (May 1999). "Stabilization of Feedback Linearizable Systems Using a Radial Basis Function Network". *IEEE Transactions on Automatic Control*, Vol. 44 (5), pp 1026-1031.
- [52] Yut, W., Poznyakt, S. A., and Sánchez, N. E. (June 1999). "Adaptive Control of Two-Link Manipulator Via Dynamic Neural Network". *Proceedings of the American Control Conference*, San Diego, California, pp. 2516-2520.

- [53] Van den Boom, T. J. J. (1996). "Model Based Predictive Control". *Revised and extended version of survey paper on the CESA'96 IMA Multiconference on Computational Engineering in Systems Applications*, pp. 1-34.
- [54] Kocijan, J., Smith, M. R., Rasmussen, E. C., and Girard, A. (June-July 2004). "Gaussian Process Model Based Predictive Control". *Proceeding of the 2004 American Control Conference*, Boston, Massachusetts, pp. 2214-2219.
- [55] Constantin, N. (December 2003). "Adaptive Neural Predictive Techniques for Nonlinear Control". *Studies in Informatics and Control*, Vol. 12 (4), pp. 285-291.
- [56] Parlos, G. A., and Atiya F. A. (September 2001). "Neuro-Predictive Process Control Using On-Line Controller Adaptation". *IEEE Transactions on Control Systems Technology*, Vol. 9 (5), pp. 741-755.
- [57] Khadir, T. M., and Sellami, M. (2005). "Artificial Neural Networks for Model Predictive Control: Application to a Milk Pasteurisation Plant". *7th ISPS'Algiers-Artificial Neural Networks for Model Predictive Control*, pp. 105-116.
- [58] Yu M. Zhang, and Kovacevic, R. (August 1998). "Neurofuzzy Model-Based Predictive Control of Weld Fusion Zone Geometry". *IEEE Transactions on Fuzzy Systems*, Vol. 6 (3), pp. 389-401.
- [59] Hovorka, R. et al. (2004). "Nonlinear Model Predictive Control of Glucose Concentration in Subjects with Type 1 Diabetes". *Institute of Physics Publishing Physiological Measurement*, pp. 905-920.
- [60] Li, X., Chen, Z., and Yuan, Z. (June 2002). "Simple Recurrent Neural Network-Based Adaptive Predictive Control for Nonlinear Systems". *Asian Journal of Control*, Vol. 4 (2), pp. 231-239.
- [61] Boukabou, A., and Mansouri, N. (2005). "Neural Predictive Control of Unknown Chaotic Systems". *Nonlinear Analysis: Modelling and Control*, Vol. 10 (2), pp. 95-106.
- [62] Negenborn, R. R., Schutter, B., Wiering, A. M., and Hellendoorn, H. (July 2005). "Learning-Based Model Predictive Control for Markov Decision Processes". *Proceedings of the 16th IFAC World Congress*, Prague, Czech Republic, pp. 1-7.
- [63] Crassidis, L. J., Markley, L. F., Anthony, C. T., and Andrews, F. S. (1997). Nonlinear Predictive Control of Spacecraft. *Published by the American Institute of Aeronautics and Astronautics*, pp. 1-10.
- [64] Ou, J., and Russell, R. R. (2002). Grouped-Neural Network Modeling for Model Predictive Control. *ISA Transactions the Instrumentation, Systems, and Automation Society*, pp. 1-8.
- [65] Kloetzer, M., and Pastravanu, O. (2004). "Simulink Blockset for Neural Predictive Control". *Seria Automatica si Calculatoare Periodica Politehnica, Transactions on Automatic Control and Computer Science*, Vol. 49 (63), pp. 1-4.
- [66] Norgaard, M., Ravn, O., Poulsen N. K., and Hansen L. K. (2004). "Neural Networks for Modelling and Control of Dynamic Systems". *Springer-Verlag, London, in the series Advanced Textbooks in Control and Signal Processing*, pp. 1-240.
- [67] Sharpe, P., and Kominar, C. (2004). "Embedded APC Tools Dramatically Lower Implementation Costs: A Refinery Case Study". *Presentation at the AIChE 2004 Spring National Conference New Orleans, LA Session TA012*, pp. 1-12.
- [68] Rivals, I., and Personnaz, L. (2000). "Nonlinear Internal Model Control Using Neural Networks: Application to Processes with Delay and Design Issues". *IEEE Transactions on Neural Networks*, pp. 1-26.
- [69] Acosta, N., and Tosini, M. (October 2002). "Custom Architectures for Fuzzy and Neural Networks Controllers". *Journal of Computer Science and Technology*, Vol. 2 (7), pp. 9-15.
- [70] Sun, W., and Wang Y. (October 2004). "A Recurrent Fuzzy Neural Network Based Adaptive Control and Its Application on Robotic Tracking Control". *Neural Information Processing-Letters and Reviews*, Vol. 5 (1), pp. 19-26.
- [71] Xiao, D. J., and Babajide O. F. (July 1999). "A Diagonal Recurrent Neural Network-Based Hybrid Direct Adaptive SPSA Control System". *IEEE Transactions on Automatic Control*, Vol. 44 (7), pp. 1469-1470.
- [72] Ronotte, C., Vande Wouwer, A., Remy, M., and Dolez, B. (June 2000). *Neural modeling and control of a heat exchanger based on SPSA techniques. Proceedings of the American Control Conference*. Chicago, Illinois, pp. 3299-3302.
- [73] Clark, M. C., and Mills, K. J. (October 2000). "Robotic System Sensitivity to Neural Network Learning Rate: Theory, Simulation, and Experiments". *The International Journal of Robotics Research*, Vol. 19 (10), pp. 955-968.
- [74] Lin, Ch., and Su, H. (2000). "Intelligent Control Theory in Guidance and Control System Design: an Overview, Taiwan Proceeding of National Science Council". *Invited Review Paper*, Vol. 24 (1), pp. 15-30.
- [75] Jonson, N. E., Calise, J. A., and Corban, E. J. (2001). *Reusable Launch Vehicle Adaptive Guidance and Control Using Neural Networks. Published by the American Institute of Aeronautics and Astronautics, Inc., with permission AIAA 2001-4381*, pp. 1-11.