

CONTROL DEL PENDULO INVERTIDO UTILIZANDO UNA RED NEURONAL CMAC

Enrique D. Ferreira - Eduardo R. Planchon - Carlos D. Trochon

Instituto de Ingeniería Eléctrica - Facultad de Ingeniería

Universidad de la República - Casilla de Correo 30

Montevideo 11100 - Uruguay

e-mail: electro@iie.edu.uy

RESUMEN

Se realizó una investigación sobre la aplicación de las Redes Neuronales en problemas de control. Se eligió como sistema a controlar el Péndulo Invertido por su inestabilidad inherente y alinealidades en el rozamiento difíciles de modelar que lo hacen un sistema atractivo para la aplicación de un control por Redes Neuronales. Se utilizó una Red Neuronal CMAC, simulada en un computador del tipo PC AT, aplicada a dos estructuras de control en tiempo real. La primera consistía de una red CMAC que aprendía a controlar al sistema simulando un Control por Realimentación de Estados (CRE) diseñado previamente. En la segunda estructura, la red CMAC aprendía la transferencia inversa del sistema a controlar. Basado en ésto y en un planeador de trayectorias se generaba la acción de control. Con ambas estructuras los resultados obtenidos fueron muy satisfactorios como se describe en las comparaciones.

ABSTRACT

A research on the application of Neural Networks in Control was done. The plant proposed was the Inverted Pendulum as an unstable system with non-linearities mainly due to friction force. A CMAC neural network, simulated in a PC AT compatible computer, was used in two different structures. In the first structure the CMAC learned to control the plant copying an existing linear controller (CRE). In the second one the CMAC learned the inverted transference of the plant to be controlled. Then control actions were generated based on a trajectory planner. Both structures gave very good results as described herein.

1. INTRODUCCION

El presente trabajo está motivado por el creciente interés que ha cobrado el estudio de las Redes Neuronales como una herramienta alternativa y factible para resolver una enorme cantidad de problemas de Ingeniería, en especial aquellos en los que los procedimientos convencionales presentan marcadas limitaciones. Tal es el caso, por ejemplo, cuando se requiere de la toma de decisiones frente a situaciones difíciles de cuantifi-

car y por lo tanto no muy bien definidas analíticamente. Este hecho es debido fundamentalmente a la capacidad que las redes neuronales poseen de procesar, en forma simultánea, un conjunto de hipótesis representativo del problema a resolver, emitiendo una respuesta acorde a la experiencia previa adquirida aún cuando tales hipótesis no fueran anteriormente presentadas, debido a la generalización que la red realiza.

Inspiradas muchas veces en las estructuras y procesos llevados a cabo por estructuras nerviosas biológicas, la red neuronal estudiada en el presente trabajo es un modelo muy simplificado de un tipo de ellas.

La red neuronal CMAC (Cerebellar Model Arithmetic Computer) fue estudiada inicialmente por Albus [1], [2], más tarde por Miller [12], Kraft y Campagna [11], y Handelman, Lane y Gelfand [10] entre otros. Esta red ha sido utilizada ampliamente en distintas aplicaciones en particular en el control de sistemas en tiempo real. Básicamente se aprovecha la capacidad de esta red neuronal para aprender una amplia gama de funciones no lineales, en un número pequeño de iteraciones.

Por su estructura básica, se puede decir que la red CMAC es una red neuronal asociativa en el sentido de que un pequeño subconjunto de la red influye su salida y a su vez este subconjunto está determinado por la entrada a la misma. Además el mapeo construido en la red CMAC asegura una generalización local, es decir a entradas similares corresponden salidas similares aunque no haya habido entrenamiento específico. Por ello la red requiere, para el aprendizaje de los patrones de entrenamiento, menos tiempo respecto de otras estructuras.

Para el control del Péndulo Invertido se han diseñado varios tipos de controladores. Belzarena, Bonino y Chavarri [5], implementaron un Control por Realimentación de Estados (CRE) cuyo diseño está basado en un análisis de la función descriptiva de la alinealidad involucrada en el sistema. El mismo fue construido físicamente en el Instituto de Ingeniería Eléctrica de la Facultad de Ingeniería de Montevideo, donde la presente investigación tuvo lugar.

En cuanto a las aplicaciones de las redes neuronales al control del Péndulo

Digitized by srujanika@gmail.com

contiene la siguiente información:
- Motor.
- Especificaciones del motor.
- Componentes del motor.
- Montaje y desmontaje.
- Operación y funcionamiento.
- Mantenimiento y reparación.
- Solución de problemas.

•Modelo.
Ej modelo matemático que se basa:
en una función de:

$$((x, x) - (\theta, \theta)) \vec{v} + v \vec{v}, \vec{v}) \frac{\vec{v}}{v} = \vec{x}$$

$$(\sin \theta - p \cos \theta) \frac{\epsilon}{J^4} = 0$$

$$\frac{d}{dt} \left(\frac{m}{S} \dot{x}_1 + m + \omega M \right) + \omega L = T$$

$$\frac{d}{Im} = \dot{p}$$

$$((\theta - \phi) \frac{E}{\mu} - \theta \cos^2(\theta)) \sin(\theta) = (\theta, \phi)$$

$$x_m d + (x, x) \sqrt{q}^{-\frac{m}{2}} = (x, x) \bar{d}$$

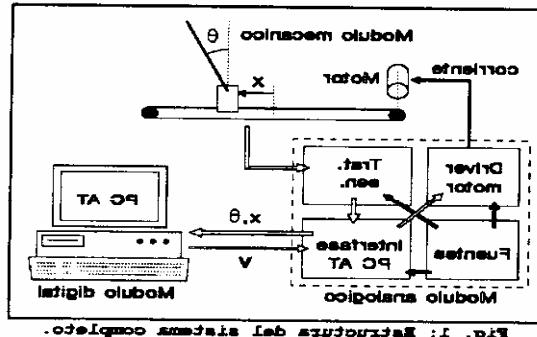
series de rocambole y cascabelas. La serie de espigas es la más numerosa y más grande.

se sifit uu mabom olobot eb si foim:

$$(\mathbf{x})_{\xi^{-1}} (\mathbf{x})_I^{-1} = (\mathbf{x}, \mathbf{x})_I^{-1}$$

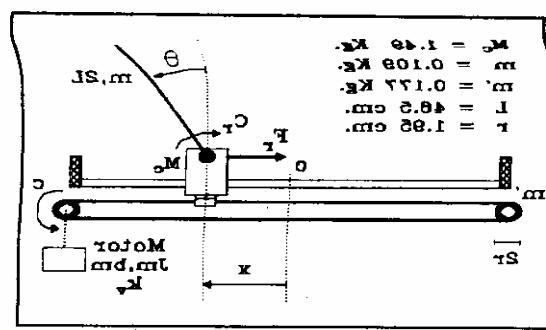
EL PENDULO INTERIOR.

A los efectos de sanción si presenta
copia(s) se desistirá una sanción
por parte de las autoridades formales:

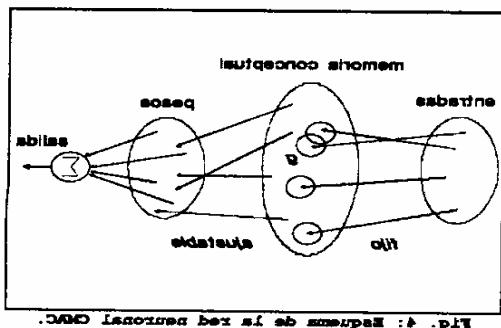


...otlegmo smetia lab smutovat : i .pid

Digitized by srujanika@gmail.com



Mid. S: Crodite key model to measure.



Während die Schenker die Schenkduldung ablehnen, ist es den Befürwortern der Schenkungsfreiheit nicht so sehr die Schenkungsfreiheit als die Schenkungsschutzmaßnahmen, die sie ablehnen.

La *bisitacion* es la visita que se hace en las fiestas religiosas, *festivales* o *festividades*, que se realizan en honor de un santo o de una virgen. La *bisitacion* es la visita que se hace en las fiestas religiosas, *festivales* o *festividades*, que se realizan en honor de un santo o de una virgen.

• 3400 • 2011-02-01

seguiría de bioclimáticos tipo basculante en su diseño para que el sistema sea software multifuncional y de fácil manejo.

(n) de casi formas que las autoridades tienen
preferencias combinatorias entre 0 y q - 1 y de
maneras que casi todas las autoridades tienen
preferencias casi iguales entre 0 y q - 1. La
función de utilidad es la siguiente:

$$(x^b + x^{-b}) \text{ near } f^b + f = (x) f^b$$

3 simple is too easy (x)

Mediation techniques differ from mediation in that mediation is a process where a third party facilitates communication between two parties. Mediation is a process where a third party facilitates communication between two parties.

$$\begin{aligned}
 q_1 &= 0.250 \\
 p_1 &= 0.00026 \\
 q_2 &= 0.355 \\
 p_2 &= 0.00026 \\
 q_3 &= 0.628 \\
 p_3 &= 0.00026 \\
 q_4 &= 0.628 \\
 p_4 &= 0.00026 \\
 q_5 &= 0.628 \\
 p_5 &= 0.00026 \\
 q_6 &= 0.628 \\
 p_6 &= 0.00026 \\
 q_7 &= 0.628 \\
 p_7 &= 0.00026 \\
 q_8 &= 0.628 \\
 p_8 &= 0.00026 \\
 q_9 &= 0.628 \\
 p_9 &= 0.00026 \\
 q_{10} &= 0.628 \\
 p_{10} &= 0.00026
 \end{aligned}$$

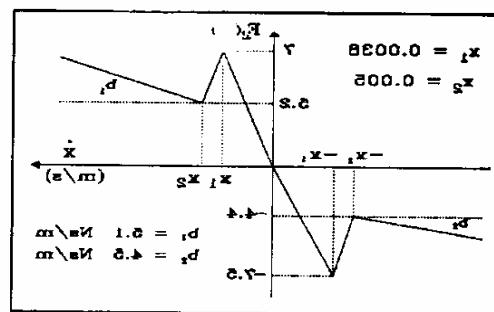


Fig. 3: Dendrogram of the 200 samples.

LA RED NEUROLOGÍA CLÍNICA

processo de transformações superficiais. Elas como zonas de desprendimento que se expandem e se espalham ao longo do leito.

$w_i(k+1) = w_i(k) + \gamma(x) - n(x)p_i$

cada vector de entrada direccione g pesos del vector tal como se muestra en la figura 5.

Albus [1], [2] y Handelman, Lane y Gel-fand [10], propusieron un método para determinar las g direcciones sobre el que se inspiran los algoritmos empleados. Se asocia a cada valor de x_i , discreto un vector de g componentes que cumple que la modificación en una unidad del valor de x_i , discreto produce la alteración de uno solo de sus componentes. Tales vectores fueron

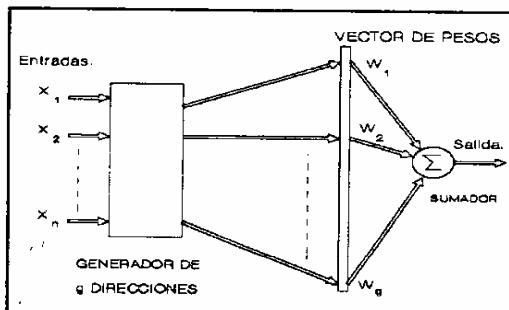


Fig. 5: Estructura básica de la red CMAC.

generados empleando la fórmula :

$$V_i[j] = j - 1 + g * E[1 + (q_i - j)/g]$$

$$0 \leq q_i \leq q_m - 1, 1 \leq j \leq g$$

donde q_i es el valor discreto de x_i , j es el índice del componente del vector asociado y $E[.]$ es el valor de la parte entera del argumento.

Para cada vector de entrada existen entonces n vectores V . Los primeros componentes de este conjunto de vectores son empleados para generar una dirección del vector donde se almacenan los pesos de la red, análogamente con los segundos, etc. hasta completar las g direcciones. Esto se hizo concatenando los valores de estos componentes.

Como el sistema a controlar recorre una zona reducida del espacio de estados considerado, se realizó una compresión de los direccionamientos sobre el vector de pesos. En tal sentido se implementó una codificación del tipo hash (Gonnet [8], Albus [2]) para las direcciones obtenidas por el método descrito, que reduce sensiblemente la dimensión del vector de pesos requerido.

Sin embargo, el agregado de esta forma de 'compresión' del direccionamiento puede producir un nuevo fenómeno indeseable que recibe el nombre de colisión el cual se maneja cuando es asignada una misma dirección final (de las g definidas) a dos vectores de entrada totalmente diferentes. No obstante Albus [1] señaló que la probabilidad de obtener tales colisiones se mantiene por debajo de 0.2 cuando $g = 100$ y mientras que se reduce a 0.02 si $g = 1000$.

En las aplicaciones experimentales de la presente investigación resultaron suficientes $q_m = 32$, g entre 6 y 24 y b alrededor de 0.05 para permitir 'mapear' transferencias físicas del sistema considerado, comprobando que los errores entre

las sucesivas predicciones de la red y las señales de supervisión disminuían con el tiempo.

5. PRIMERA ESTRUCTURA DE CONTROL

Consistió en intentar que una red neuronal controlara al péndulo invertido "imitando" las acciones de control provenientes del CRE durante el funcionamiento del sistema real.

Para ello se dispuso una red neuronal CMAC de 4 entradas reales, una para cada variable de estado del sistema y una salida real, la cual provee el valor de la acción de control para el sistema. Se tomó $W = 2311$, $q_m = 32$; $g=6$; $b=0.05$ y un intervalo de muestreo $t_s = 0.01s$. Como señal de supervisión se empleó el valor de la corriente provista por el CRE. La figura 6 muestra la

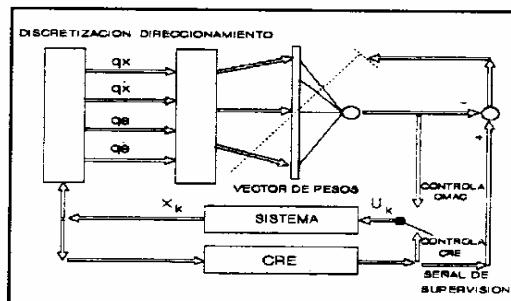


Fig. 6: Estructura utilizada en el primer objetivo.

estructura empleada.

Fueron suficientes algunos minutos de adiestramiento de la red 'on-line' para transferirle el control del sistema obteniendo un comportamiento similar al del sistema controlado por la señal proveniente de la referencia. En la figura 7 pueden apreciarse las comparaciones efectuadas por medio de las trayectorias seguidas por el sistema con uno u otro método cuando se utilizó una partición uniforme del espacio de estados.

Fue posible obtener mayores similitudes cuando se dispuso una partición alineal con mayor 'fineza' en las proximidades del origen del espacio de estados.

Debido a la capacidad de aprendizaje de funciones no lineales de la red, cabe la posibilidad de emplear otros métodos no lineales de control para su adiestramiento.

La performance obtenida es a lo sumo tan buena como el control que se está imitando. A través de la segunda estructura se intentó mejorar la performance obtenida con el CRE.

6. SEGUNDA ESTRUCTURA DE CONTROL

Consistió en adiestrar una red neuronal del tipo CMAC con la transferencia inversa del sistema a controlar, de modo que ofrezca la acción de control necesaria que desplace al sistema hacia un estado deseado X_{k+1} cuando su estado actual es X_k . Un planeador de trayectorias proporciona el estado deseado X_{k+1} en el instante de mues-

treo siguiente a partir del estado actual X_k .

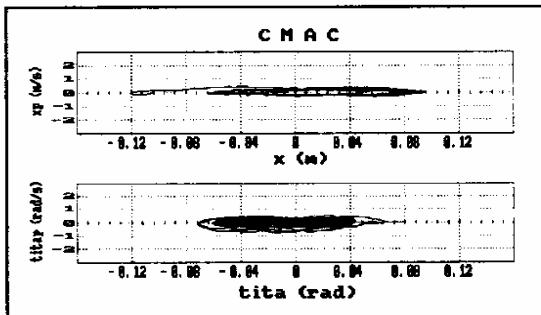
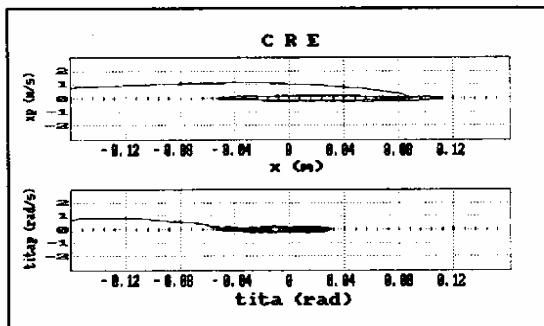


Fig. 7: Trayectorias seguidas por el mismo sistema sometido al control CRE y al del CMAC.

Se diseñó entonces una red neuronal CMAC de 8 entradas reales, 4 para las variables de estado actuales y 4 para las variables de estado deseadas en el instante de muestreo posterior, y una salida analógica, correspondiente a la acción de control necesaria. Esta red fue implementada con $q_m = 32$, $g = 16$, $W = 2573$ y $t_s = 0.02$ s. La estructura se muestra en la figura 8.

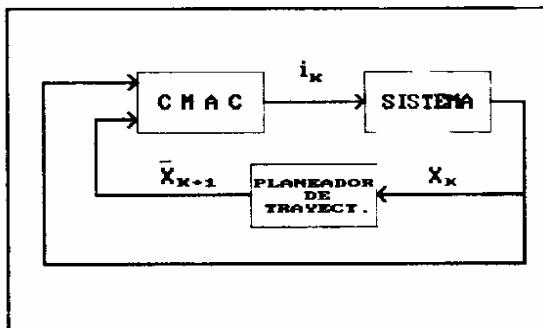


Fig. 8: Estructura del control por redes neuronales.

El adiestramiento de la red se produjo en dos etapas. En la primera el sistema es controlado por el CRE y en segundo lugar el sistema es controlado por la red CMAC. En la primera etapa el CMAC sólo aprende y no controla el sistema. En la segunda aprende y controla a la vez. Las dos etapas se muestran en la figura 9.

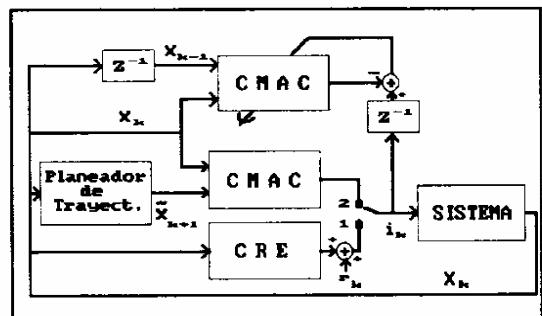


Fig. 9: Estructura del sistema de aprendizaje.

Para asegurar un buen aprendizaje, la primera etapa, es deseable que las trayectorias en el espacio de estados sea muy variadas sin perder la estabilidad. Para ello se sumó una señal de ruido η . Se observa que en esta fase, no se conoce X_{k+1} en el instante de muestreo t_k , por tanto la red aprende la transferencia inversa un instante después de la aplicación de la corriente hacia el sistema.

Se emplearon trayectorias provenientes de un modelo linealizado del sistema real al cual se le aplicaba la acción de control del CRE. También se experimentaron trayectorias ideales y posibles de seguir por el CMAC, que redujese el ciclo límite del sistema.

Comparación.

La propuesta de control presentada basada en la identificación de la transferencia inversa del sistema a través de redes neuronales, es muy diferente al CR por las siguientes razones:

1) Su adaptabilidad. La idea de un control por redes neuronales se basa en que la red es una estructura flexible, capaz de modelando el sistema a lo largo del tiempo, para lograr un objetivo deseado. En este caso la red CMAC va adaptando su vector de pesos de manera de mapear la transferencia inversa del sistema y por tanto proponer una acción de control cada vez más adecuada para seguir una determinada trayectoria dada por un planeador de trayectorias.

2) Es un control no lineal por la estructura no lineal del direccionamiento del vector de pesos.

3) Se utilizó un generador de trayectoria. De su estructura se desprende que se planteó un objetivo lineal, a un paso, en las observaciones.

Las siguientes figuras muestran los ciclos límites para ambos tipos de control.

Se observa una mejora sustancial en la proyección de las trayectorias sobre el plano x , dx/dt . En tanto en el plano $d\theta/dt$ la variación es menor para θ , pero en $d\theta/dt$ se mantiene similar al CRE.

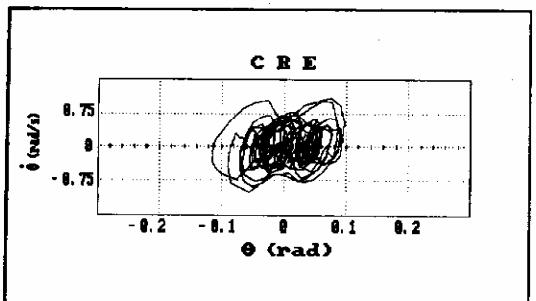
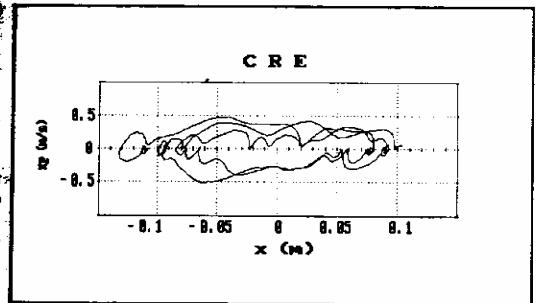


Fig. 10: Ciclo límite para el CRE.

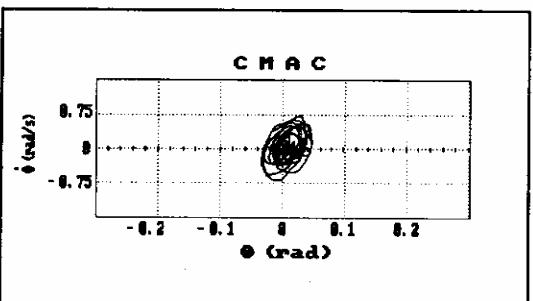
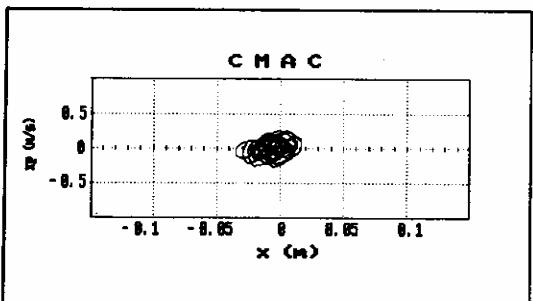


Fig. 11: Ciclo límite para el CMAC.

7. CONCLUSIONES

En el presente trabajo, se han mostrado las características de una red neuronal artificial particular, la red CMAC y su aplicación a la resolución de problemas de Ingeniería, tal como el control del péndulo invertido el cual se acondicionó convenientemente.

Se han mostrado las comparaciones respecto del tradicional método de la Realimentación de Estados exitosamente aplicado por Belzarena, Bonino y Chavarria [5] encontrando una nueva herramienta capaz tanto de imitar satisfactoriamente las acciones de control provenientes de otros métodos, como de proponer un control alternativo mejor. La implementación del control del péndulo invertido por medio de redes neuronales es un ejemplo particular del vasto conjunto de posibles aplicaciones dentro del campo de la Ingeniería, sin embargo, consiste en un problema de control en que la planta es inestable y no lineal, de allí su complejidad y la razón de su elección.

De los resultados obtenidos para el control de éste sistema en particular surge un panorama tentador para su aplicación al control de otros sistemas, en especial aquellos en que las ecuaciones de la transferencia resulten de difícil obtención y los métodos computacionales convencionales requieran excesiva memoria y/o capacidades de procesamiento.

En el presente trabajo la implementación de las redes neuronales se efectuó empleando programas secuenciales que 'emulan' paso a paso los procesos en paralelo que se llevarían a cabo en una red neuronal real.

Un mejor aprovechamiento de esta nueva herramienta surgirá en la medida de la implementación en Hardware de sus estructuras, lo cual será motivo de futuras investigaciones.

8. AGRADECIMIENTOS.

Los autores desean agradecer al personal del Instituto de Ingeniería Eléctrica de la Facultad de Ingeniería de Montevideo, y a la fundación Sigma XI por el apoyo prestado durante la realización de esta investigación.

REFERENCIAS

- [1] J.S. Albus, "A New Approach to Manipulator Control: The Cerebellar Model Articulation Controller," *IEEE Trans. ASME*, Serie G, Vol. 97, pp. 220-227, 1975.
- [2] J.S. Albus, "Data Storage in the Cerebellar Model Articulation Controller," *IEEE Trans. ASME*, Serie G, Vol. 97, pp. 228-233, 1975.
- [3] C.W. Anderson, "Learning to Control an Inverted Pendulum Using Neural Networks," *IEEE Control Systems Magazine*, Vol. 9, no. 3, pp. 31-37 1989.
- [4] A.B. Barto, R.S. Sutton, and C.W. Anderson "Neuronlike Adaptive Elements that can Solve Difficult Learning Control Problems," *IEEE Trans. SMC*, Vol. 13, no. 5, pp. 835-846 1983.
- [5] P. Belzarena, E. Bonino y P. Chavarria, "Control del Péndulo Invertido," *INGELECTRA, VII Seminario Estudiantil*, Universidad de Tarapaca, Arica, Ago. 28-30, 1991, Chile.
- [6] F.H. Glanz, W.T. Miller, "Shape recognition using a CMAC based learning system," *Proc. SPIE Conf. on Robotics and Intelligent Systems*, Vol. 848, pp. 294-298, 1987.

- [7] F.H. Glanz, W.T. Miller, "Deconvolution and nonlinear inverse filtering using a neural network," *Int'l. Conf. on Acoustics and Signal Processing*, Vol. 4, pp.2349-2352, 1989.
- [8] G.H. Gonnet, *Handbook of Algorithms & Data Structures*, Addison-Wesley Inc., cap. 3, 1984.
- [9] A. Guez, J. Selinsky, "A Trainable Neuromorphic Controller," *J. Robotic Syst.*, Vol. 5, no.4, pp. 363-388, 1988.
- [10] D.A. Handelman, S.H. Lane and J.J. Gelfand, "Integrating Neural Networks and Knowledge-Based Systems for Intelligent Robotic Control," *IEEE Contr. Syst. Mag.*, Vol.10, no. 3, pp.77-87, 1990.
- [11] L.G. Kraft, D.P. Campagne, "A Comparison Between CMAC Neural Network Control and Two Traditional Adaptive Control Systems," *IEEE Contr. Syst. Mag.*, Vol. 10, no.3, pp. 36-43, 1990.
- [12] W.T. Miller III, "Real-Time Application of Neural Networks for Sensor-Based Control of Robots with Vision," *IEEE SMC*, Vol.19, pp.825-831, 1989.
- [13] W.T. Miller III, F.H. Glanz, L.G. Kraft III, "CMAC: An Associative Neural Network Alternative to Backpropagation," *Proc. IEEE*, vol. 78, no. 10, pp. 1561-1567, 1990.
- [14] V.V. Tolat, B. Widrow, "An Adaptive Broom Balancer with Visual Inputs," *Proc. IEEE Int. Conf. on Neural Networks*, II641-II647, 1988 .
- [15] B. Widrow, "The Original Adaptive Neural Net Broom-Balancer," *Int. Symp. Circuits and Syst.*, pp. 351-357, 1987.
- [16] Chun-Shin Lin and Hyongsuk Kim, "CMAC-Based Adaptive Critic Self-Learning Control," *IEEE Trans. on Neural Networks*. Vol. 2, No. 5, pp. 530-533. Sept. 1991.

BIOGRAFIA TECNICA



Enrique D. Ferreira está actualmente culminando los estudios de grado en Ingeniería Eléctrica en la Facultad de Ingeniería Montevideo, Uruguay. Se desempeña además como profesor asistente en el Instituto de Ingeniería Eléctrica de dicha Facultad. Sus áreas de interés actual incluyen control adaptivo, identificación de sistemas, redes neuronales y lógica difusa. Es miembro del IEEE.



Eduardo R. Planchon es Ingeniero Electricista egresado de la Universidad de la República en 1992, Montevideo, Uruguay. Desde 1990 es profesor ayudante del Instituto de Ingeniería Eléctrica de la Facultad de Ingeniería de dicha Universidad. Desde entonces ha venido desarrollando trabajos de investigación en Energía Solar. Durante 1991 a 1992 fue co-autor del trabajo de investigación titulado "Redes Neuronales Artificiales: Una Aplicación al Control". Su área de interés incluye Energía Solar, Control de Procesos, Redes Neuronales, Sistemas Difusos y Sistemas Expertos. Es miembro del IEEE.



Carlos D. Trochón es Ingeniero Electricista egresado de la Universidad de la República en 1992, Montevideo, Uruguay. Durante 1991 a 1992 fue co-autor del trabajo de investigación titulado "Redes Neuronales Artificiales: Una Aplicación al Control". Su área de interés incluye Control de Procesos, Redes Neuronales, Tratamiento de Señales y Comunicaciones. Es miembro del IEEE.