

# LOS MODELOS CONEXIONISTAS Y SUS POTENCIALIDADES EN EL ANÁLISIS DE DATOS

Julián Tejada-Herrera, Colombia  
Fundación Universitaria Konrad Lorenz

## ***Resumen***

Los modelos conexionistas que conforman lo que actualmente se denomina la nueva metáfora computacional no sólo son pertinentes en el modelado de los procesos cognitivos sino que se presentan como modelos alternativos en análisis de datos. Dichos modelos son capaces de realizar tareas de clasificación y de regresión estadística con un desempeño comparable a los de cualquier método convencional, ofreciendo al usuario una variedad de modelos capaces de adaptarse a cualquier tipo de datos. El presente artículo tiene la intención de familiarizar a los psicólogos con la mecánica de estos modelos enfatizando en sus potencialidades como herramientas de análisis de datos.

**Palabras claves:** *conexionismo, clasificación, regresión, support vector machine.*

## ***Abstract***

The models today are denominated the “new computational metaphor” are not only pertinent in the modeled of the cognitive processes but they appear like as alternative models in analysis of data. These models are able to make tasks of classification and statistical regression with a performance comparable to any conventional method, offering to the user a variety of models able of adapt to any type of information. The aim of the present article is to familiarize the psychologists with the mechanics of these models emphasizing his potentialities as tools of analysis of information.

**Key words:** *the new computational metaphor, classification, regression, support vector machine.*

Desde la aparición de los computadores, estos se han convertido en una herramienta fundamental en el quehacer científico y la psicología no ha sido la excepción, inclusive ha llegado a estar tan influida por estos artefactos, que se ha construido toda una teoría que compara su procesamiento con el comportamiento mental, lo que ha sido denominado la metáfora computacional y fue la base de la revolución cognitiva (Rivière, 1998).

Aunque en la actualidad el rol del computador como protagonista de dicha metáfora está completamente revaluado (Arnau & Balluerka, 1998), su uso intensivo ha permitido la generación de nuevas metáforas en las que hay involucradas una carga muy grande de operaciones matemáticas que no podrían resolverse sin su apoyo.

Dichas metáforas tienen como objetivo explicar los fenómenos intencionales a partir de un sistema estrictamente extensional como es el cerebro, la metáfora evolucionó del computador al cerebro (Rivière, 1998), en lo que algunos denominan conexionismo (Rivière, 1998; Arnau et al., 1998). Todos estos modelos son emergencistas (Sperry, 1993),

es decir, se basan en el supuesto de que los estados mentales, como la conciencia, son estados que emergen cuando se conectan de manera suficientemente compleja, una cantidad considerable de unidades neuronales (Chalmers, 1995). Al respecto algunos teóricos como Penrose (1989) han pronunciado su escepticismo, llegando a considerar que incluso reuniendo en paralelo a todos los computadores de la tierra no podríamos alcanzar ese “nivel crítico” en el que se esperaría la emergencia de la conciencia, ya que el problema está en la manera como se concibe que procesa la información el cerebro, argumentando que el procesamiento de tal está más allá de lo binario y que debemos considerarlo como un fenómeno cuántico con toda la “incertidumbre” que esto involucre (Hameroff, 1999).

La polémica está planteada. Para algunos, los modelos conexionistas no deberían considerarse como modelos para estudiar lo “psicológico” (Penrose, 1992; Gold & Stoljar, 1999); otros siguen intentando lograr una simulación lo suficientemente fiel del comportamiento cerebral de la que emerjan los procesos psicológicos superiores (O’Reilly & Munakata, 2000). Sin embargo e independiente de su posición como modelos de lo psicológico, se siguen desarrollando algunos que desbordan la metáfora cerebral y que involucran nuevas metáforas basadas en el comportamiento de sistemas complejos de procedencia natural, como el comportamiento que ocurre en una colonia de hormigas (Merkle & Middeendorf, 2002). Estos modelos están dando mucho de que hablar por su efectividad (Garb, 2000; Goolkasian, 1997) y es debido a esto que muchos profesionales—principalmente no psicólogos—se han puesto a la tarea de crear nuevos modelos.

En este contexto es importante que el psicólogo se tome su tiempo para contemplar los alcances de la aplicación de estos modelos, no sólo en el ámbito epistemológico como un modelo que ayude a entender el comportamiento humano, sino también a nivel meramente metodológico, ya que son modelos que tienen una utilidad práctica que muchas veces supera su pertinencia teórica.

El presente artículo es una aproximación a estos modelos desde un punto de vista puramente metodológico para intentar resaltar sus bondades técnicas en el análisis de datos. Me distancio de la discusión sobre su pertinencia como modelos de lo psicológico, para exaltar su potencialidad como métodos de procesamiento de información.

Actualmente los modelos conexionistas son utilizados en tres áreas: (Price, Spitznagel, Downey, Risk, & El-Ghazzawy, 2000) (a) modelando el sistema nervioso. Éste es un enfoque que tiene por objetivo la construcción de los modelos que ayuden a entender un fenómeno específico, por ejemplo, simular una lesión cerebral; (b) como procedimientos de señales adaptativas en tiempo-real que controlan hardware. Es la típica aplicación industrial en donde algoritmos basados en los modelos conexionistas, responden ante situaciones en que los algoritmos tradicionales no podían dar una respuesta adecuada debido a la naturaleza dinámica del problema, un ejemplo de este enfoque es la utilización de modelos conexionistas para controlar la temperatura y presión de un tanque; y (c) como métodos de análisis de información. En este apartado están todas aquellas aplicaciones que utilizan los modelos conexionistas como algoritmos de búsqueda y clasificación, como la aplicación en

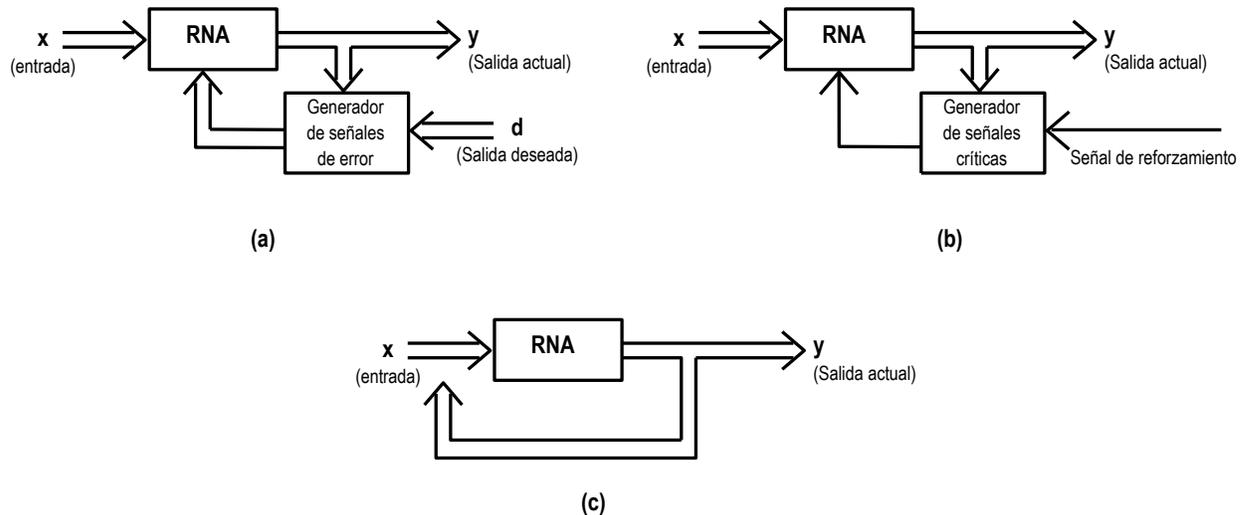
diagnóstico clínico. Estos tres campos de acción hacen referencia a tres o más modelos al interior del conexionismo y cada uno de ellos puede ser utilizado en una diversidad de problemas (Price et al., 2000).

En general, los sistemas conexionistas hacen uso de varios modelos. Algunos de ellos están basados en los procesos de aprendizaje, donde se encuentran tres diferentes modelos, a) el aprendizaje supervisado, b) el aprendizaje no supervisado y c) el aprendizaje por reforzamiento (Lin & Lee, 1996; Haykin, 1999; Regueiro, Barro, Sánchez, & Fernandez-Delgado, 1995; Bello, 1993). Todos ellos trabajan bajo un esquema en que el sistema conexionista (generalmente en el esquema de una Red Neuronal Artificial) aprende algunas regularidades del ambiente que lo rodea. Ésta es tan solo una descripción somera del comportamiento de este tipo de sistemas y es necesario intentar desglosarla un poco más para entender su pertinencia en el análisis de datos. Primero, cuando nos referimos al sistema conexionista, hacemos referencia a una serie de elementos sencillos organizados de una manera específica; se denominan elementos sencillos puesto que realizan operaciones básicas previamente estipuladas, como por ejemplo el comportamiento individual de una célula neuronal, el cual es un proceso estándar que involucra una serie de operaciones relativamente sencillas (O'Reilly et al., 2000) que se suelen simular a través de operaciones matemáticas. Estos elementos o unidades están organizados de una manera específica que determina la forma como se relacionan. En los modelos de Redes Neuronales Artificiales (RNA) se suele denominar regla de aprendizaje (Lin et al., 1996).

Existen tres reglas de aprendizaje diferentes (ver figura 1), cada una de ellas obedece a una configuración específica de organización de las unidades de procesamiento y a la forma como interpretan la información que proviene de su entorno, para responder adecuadamente a las diferentes contingencias, mostrando una curva de aprendizaje.

Las dos primeras de las reglas se caracterizan por un aprendizaje controlado por la retroalimentación que obtiene el sistema de su entorno. Son procesos en que los sistemas a través de varios intentos van aprendiendo a responder a las contingencias del ambiente en un proceso de ensayo y error. Se denominan aprendizaje supervisado y aprendizaje por reforzamiento (Lin et al., 1996); en la primera de ellas, la señal que proviene del ambiente proporciona al sistema información clara y suficiente de su desempeño, generalmente se utiliza en situaciones en que se espera del sistema una respuesta correcta.

En el segundo tipo o aprendizaje por reforzamiento, el sistema también cuenta con información del medio que lo rodea, pero en este caso la información de retroalimentación



es difusa, incompleta, que no le dice cuál es la respuesta correcta. El sistema sólo recibe información de si se está acercando o no a su objetivo. Generalmente se utiliza en situaciones en que no hay una única respuesta correcta, aunque sí una meta que alcanzar.

**Figura 1** Tres reglas de aprendizaje. (a) aprendizaje supervisado, (b) aprendizaje por reforzamiento y (c) aprendizaje no-supervisado. Tomado de (Lin et al., 1996) (p. 213)

El último tipo de aprendizaje es muy diferente a los anteriores por cuanto no requiere información acerca de su desempeño. Se denomina aprendizaje no supervisado y está basado en un principio de autoorganización (Lin et al., 1996; Bello, 1993) en que la respuesta del sistema está apoyada en las regularidades o correlaciones presentes en la información. Generalmente se utilizan en procesos de clasificación en los que no se tenga información acerca de las clases que se deben conformar (Lin et al., 1996).

Cada una de las reglas de aprendizaje responde a un tipo de problema determinado y dotan a los sistemas conexionistas de la capacidad necesaria para aprender a responder a las exigencias del ambiente. A continuación describiré las potencialidades de dos de los tres modelos anteriormente mencionados: el aprendizaje supervisado y el no supervisado, dejando de lado el aprendizaje por reforzamiento, puesto que obedece a una lógica no relacionada con el comportamiento neuronal y es utilizado más como procedimiento de simulación del comportamiento que como procedimiento de análisis de datos (Tejada, Perilla, Serrato & Reyes, 2004).

Dentro de la regla de aprendizaje supervisado se destaca un procedimiento que se denomina retropropagación del error, éste es uno de los más importantes desarrollos en la historia de las RNA (Lin et al., 1996; O'Reilly et al., 2000; Haykin, 1999; Russel &

Norving, 1995), es un “...algoritmo verdaderamente poderoso para tareas basadas en aprendizaje...” (O’Reilly et al., 2000; pp. 158). Aunque es un modelo biológicamente imposible, es uno de los más utilizados dentro de las RNA. Este procedimiento se basa en la regla de aprendizaje hebbiano que determina el principio de relación entre las unidades de procesamiento neuronales: “...cada vez que dos unidades de una red neuronal, A y B, están simultáneamente excitadas, se incrementa la fuerza de conexión entre ellas...” (Hebb, 1949 citado por Rivière, 1998, pp. 62). Las redes de retropropagación del error son, necesariamente, redes multi-capa y según Haykin (1999) se caracterizan por (a) la función de salida de cada unidad de procesamiento es una función no-lineal, (b) la RNA posee una o más capas ocultas, que aumentan dramáticamente sus capacidades de cálculo, y (c) las unidades están masivamente interconectadas.

Una RNA multi-capa de retropropagación consta de una capa de unidades de entrada, una o varias capas de procesamiento ‘ocultas’ y una capa de unidades de salida, con un valor de umbral para cada capa y sólo están conectadas con las unidades de la siguiente capa.

La idea que subyace al procedimiento de retropropagación parte del supuesto de que existe una función “suave” que relaciona varias variables  $x_i$  en una única función  $Y$ . Se busca determinar cuáles son los cambios que deben hacerse a los valores iniciales de cada  $x_i$  para que la función se aproxime al valor deseado (Patrick, 1994).

El proceso de retropropagación del error básicamente consiste en dos fases. Una fase en que las señales dentro de la red van hacia adelante, es decir de la capa de entrada hacia la capa de salida, conocida como fase de propagación (forward pass) y otra fase en que las señales van hacia atrás, fase de retropropagación (backward pass). En la fase de propagación (forward pass) un patrón de activación estimula las neuronas de entrada propagándose a través de cada una de las capas de RNA, hasta que finalmente en la capa de salida se produce la salida actual de la RNA. En esta fase, el valor de los pesos de las conexiones se mantiene fijo. En la fase de retropropagación (backward pass) los pesos de conexión son ajustados siguiendo la regla de corrección del error (Haykin, 1999).

Una red multi-capa en su fase de propagación funciona de manera equivalente a una red monocapa, como la diseñada inicialmente por McCulloch y Pitts, donde cada unidad de procesamiento genera una señal de activación que depende de las unidades que están conectadas a éstas, y que se propaga capa a capa hasta que alcanza la capa de salida.

El meollo de la fase de retropropagación se encuentra en la función que modifica los valores de los pesos de conexión, porque sólo se tiene un valor de error  $\delta_k$  – la discrepancia que hay entre el valor deseado y la salida de la red – y dependiendo de ésta, se deben modificar proporcionalmente los pesos de conexión de cada una de las capas. Para esto se suelen usar la sumatoria del error cuadrático o la función de entropía del error. Ésta

última generalmente se expresa como:  $CE = -\sum_t \sum_k t_k \log o_k + (1-t_k) \log(1-o_k)$  (O'Reilly et al., 2000), donde  $t_k$  es la salida deseada de la red y  $o_k$  es la salida actual de la red. El objetivo de la retropropagación es minimizar éste error.

En otros términos, dicho objetivo de la regla de retropropagación podría expresarse como un procedimiento a través del cual se realiza la modificación de los pesos de las conexiones, cuando la RNA responde ante una situación específica durante la etapa de entrenamiento.

Una de las características de las soluciones que alcanzan las funciones de aprendizaje en general, es que deben dar una solución óptima, incluso, en situaciones en las que la información inicial este degradada. Esta característica la resume muy bien Riviere (1998) cuando describe a las RNA como “...*sistemas conexionistas (que) alcanzan automáticamente estados de «solución óptima» a problemas de reconocimiento de patrones... a partir de estímulos degradados. Su funcionamiento... puede entenderse como resultante de las propiedades estadísticas de sistemas cooperativos que tienden, de forma intrínseca, a alcanzar estados de «relajación» máxima...*” (pp. 106).

Específicamente la regla de retropropagación, y en general el aprendizaje supervisado, permite enfrentar problemas de clasificación de patrones en los que se desee un sistema capaz de aprender una forma determinada de clasificación, por ejemplo, cuando se toman decisiones en un contexto clínico (Price et al., 2000) es deseable realizar una adecuada clasificación para lo cual se realiza un entrenamiento en habilidades clínicas que le permita al terapeuta tomar la mejor decisión posible. Una RNA regida por la regla de retropropagación podría aprender a tomar decisiones en situaciones en las que no se cuenta con toda la información necesaria, como en el contexto clínico o laboral (Willians, Carson, & Sherald, 1999).

El segundo modelo de aprendizaje que abordaré en el presente artículo es el aprendizaje no supervisado. Es un modelo que también se utiliza en tareas de clasificación pero de una manera diferente a la del aprendizaje supervisado, ya que estos modelos no aprenden una clasificación previamente establecida, sino que ellos mismos construyen dicha clasificación.

La lógica detrás de este segundo tipo de modelos es que en cualquier grupo de datos que se relacionan, es posible identificar algunas características en común y a partir de ellas construir categorías. A través de una función matemática se pueden identificar dichas características, ésta función debe, necesariamente, converger hacia estados de equilibrio dinámicamente estables (Martínez, 2000) y ser una función de ascenso de gradiente. Este es uno de los aspectos más interesantes y a la vez más difícil de comprender. Imaginar que existe una función capaz de abordar cualquier problema, y, además, con la capacidad de identificar los “puntos interesantes” del mismo, no es una tarea fácil. Sin embargo, es un

menester necesario dentro del presente artículo el intentar mostrar, de manera intuitiva, la belleza que hay dentro de estos mecanismos de aprendizaje.

Imaginemos un espacio de decisión que represente algún problema, por ejemplo, aprender a reconocer un círculo. En general, los espacios de decisión son multidimensionales, pocos son los casos en los que encontramos espacios de decisión sencillos; como no es posible representar gráficamente espacios multidimensionales, se acude a una representación reducida que asemeja una sábana extendida. Dicha sábana, para que sea ‘interesante’, debe tener algún tipo de perturbación en su superficie que genere formas como valles o montañas. Si nosotros dejáramos deslizarse una pequeña bolita de cristal en la superficie de la sábana, ésta tendería a irse dentro de algún valle. La función que rige el comportamiento de dicha bolita es un buen ejemplo de una función de aprendizaje, teniendo algunas salvedades, que obedece a un descenso de gradiente.

Supongamos que la bolita no está regida por las leyes físicas, como la gravedad o el rozamiento, sino que la controla una función de aprendizaje, esto le permitiría a la bolita no solo caer en los valles, sino en un determinado momento subir alguna colina. Nuevamente soltamos la bolita, que no buscará necesariamente un valle, sino que tiene como objetivo encontrar un sitio en la sábana, dentro del cual estén las claves que le permitan identificar un círculo, recordemos el ejemplo anteriormente planteado. Dicha bolita se moverá sobre su espacio de decisión con un objetivo claro y explorará algunos valles y montañas. En este proceso es posible que a la bolita le ocurran varias cosas, por ejemplo, que se interne en un valle donde se encuentran las características para identificar un cuadrado, o que se encuentre en la colina del triángulo; en ambos casos la bolita deberá salirse del valle o bajar la montaña, para seguir su camino. También es posible que la bolita ingrese en el valle de un óvalo, ésta es una de las situaciones más interesantes. En dicho valle la bolita encuentra una figura geométrica muy similar a un círculo y dependiendo del nivel de exactitud que se quiera alcanzar, la bolita se quedará aquí o seguirá buscando el valle del círculo, que necesariamente se encuentra muy cerca.

El ‘valle del óvalo’ hace las veces de lo que técnicamente se denominan *mínimos locales*, que son puntos, en el espacio de decisión, en los que puede caer una red y, aunque son parecidos a lo que se pretende buscar, hace que las redes den respuestas inadecuadas. Es posible evitar estos mínimos locales a través de estrategias de precisión, siendo más rigurosos en el entrenamiento. Pero tal vez la mejor manera de evitarlos es entrenar la red partiendo de diferentes puntos, algo así como dejar caer la bolita de diferentes posiciones para ver si al final termina en el mismo valle. Matemáticamente esto se logra definiendo aleatoriamente el valor inicial de todos los pesos de conexión, es un artificio simple, pero del cual dependen las RNA para un correcto funcionamiento.

La figura 2 muestra una superficie hipotética del espacio de decisión al que se debe enfrentar una RNA, lo que anteriormente denominábamos como una sábana.  $\nabla E_p$  representa el gradiente de las conexiones en un momento determinado. Dicho gradiente determina la dirección que tomará la bolita dentro del espacio de decisión. Los cambios en

los valores de las conexiones deberían producirse en la dirección del gradiente negativo, de manera iterativa hasta que la ‘bolita’ alcance el punto mínimo  $z_{min}$ .

Este segundo modelo está basado en las células neuronales de la corteza visual (Lin et al., 1996), por lo que han sido utilizadas en procesos de reconocimiento de patrones (Haykin, 1999; Lin et al., 1996), sin embargo sus posibilidades de aplicación superan este campo de acción. Son modelos que se pueden utilizar para emular procedimientos de clasificación como el análisis de componentes principales, a través de, por ejemplo, el modelo denominado la regla de *kohonen* (Lin et al., 1996).

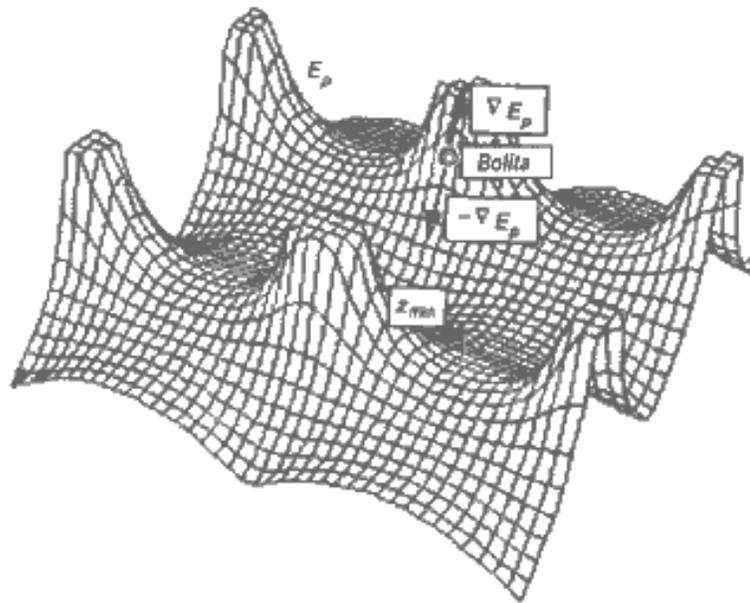


Figura 2. Superficie hipotética del espacio de pesos. Adaptado de (Freeman & Skapura, 1993).

Los dos modelos anteriormente descritos hacen parte de una gran variedad de modelos que actualmente se utilizan para tareas de clasificación y regresión estadística, sin embargo, no son los únicos modelos que actualmente se utilizan para realizar dichas tareas, existe un programa de computadora llamado Support Vector Machine desarrollado en Cornell University por Thorsten Joachims que implementa modelos similares a los de las RNA en tareas de regresión (Bi & Bennett, 2003) y de clasificación de múltiples categorías (Angulo, Parra, & Català, 2003), alcanzando un desempeño comparable con cualquier otro procedimiento de regresión o clasificación (Meyer, Leisch, & Hornit, 2003).

Support Vector Machine trabaja con una lógica similar a los modelos de aprendizaje supervisado pero a diferencia de estos, no trabaja minimizando el error empírico sino el error esperado. Adicionalmente, dicho programa posee criterios de interpretación similares

a los utilizados en los diferentes métodos de análisis multivariado, y ofreciéndole al usuario final salidas gráficas que facilitan la identificación de las diferentes clases que se construyeron a partir de los datos.

Los modelos Conexionistas se han venido posicionando como métodos alternativos para el análisis multivariado, por sus características de ser modelos no lineales que pueden procesar cualquier tipo de información ya sea paramétrica o no paramétrica. Estas potencialidades representan características importantes para los psicólogos que necesitan métodos robustos y prácticos capaces de explotar al máximo los datos, por lo que el análisis de datos a través de modelos conexionistas se presenta como una alternativa interesante y posible de usar a través de aplicaciones como Support Vector Machine.

## Referencias

- Angulo, C., Parra, X., & Català, A. (2003). *K-SVCR. A support vector machine for multi-class classification. Neurocomputing, 55*(1-2), 57-77.
- Arnau J., & Balluerka, N. (1998). *La psicología como ciencia. Principales cambios paradigmáticos y metodológicos*. Barcelona: Erein.
- Bello Pérez, R. (1993). *Curso Introductorio a las redes neuronales artificiales*. Manuscrito no publicado, Univesidad Central "MartaAbreu" de LasVillas, Cuba.
- Bi, J., & Bennett, K. (2003). A geometric approach to support vector regression. *Neurocomputing, 55*(1-2), 79-108.
- Chalmers, D. J. (1995). Facing Up to the Problem of Consciousness. *Journal of Consciousness Studies, 2*(3), 200-219.
- Freeman, J. A., & Skapura, D. M. (1993). *Redes neuronales. Algoritmos, aplicaciones y técnicas de programación*. Wilmington, Delaware: Addison-Wesley/Díaz de Santos.
- Garb, H. (2000). Introduction to the Special Section on the Use of Computers for Making Judgment and Decisions. *Psychological Assesment, 12*(1), 3-5.
- Gold, I., & Stoljar, D. (1999). A neuron doctrine in the philosophy of neuroscience. *Journal of Behavioral and Brain Sciences, 22*(5), 809-830.
- Golkasian, P. (1997). AI and statistical applications. *Behavior Research Methods, Instruments & Computers, 29*(2), 194-199.
- Hameroff, S. (1999). The neuron doctrine is an insult to neurons. *Journal of Behavioral and Brain Sciences, 22*(5), 838-839.
- Haykin, S. (1999). *Neural Networks; A Comprehensive Foundation*. New Jersey:
- Hebb, D. O. (1949). *The organization of behavior: A Neuropsychological Theory*. New York: Wiley.
- Lin, C. T., & Lee, C. S. (1996). *Neural Fuzzy Systems. A Neuro-Fuzzy Synergism to Intelligent Systems*. New Jersey: Prentice Hall.
- Martínez, F. (2000). Convergencia y estabilidad neurodinámica de las funciones de aprendizaje, presentadas a la luz del nuevo conexionismo. Tesis para optar el título de Psicólogo. Universidad Nacional de Colombia.
- Merkle, D., & Middeendorf, M. (2002). Modeling the Dynamics of Ant Colony Optimization. *Evolutionary Computation, 10*(3), 235-262.

- Meyer, D., Leisch, F., & Hornik, K. (2003). The support vector machine under test. *Neurocomputing*, 55(1-2), 169-186.
- O'Reilly, R., & Munakata, Y. (2000). *Computational Explorations in Cognitive Neuroscience. Understanding the Mind by Simulating the Brain*. Cambridge: Bradford Book The MIT Press.
- Patrick W., H. (1994). *Inteligencia Artificial*. (3a ed.). Buenos Aires: Addison - Wesley Iberoamérica.
- Penrose, R. (1989). *The Emperor's New Mind. Concerning Computers, Minds, and the Laws of Physics*. New York: Penguin Books.
- Penrose, R. (1992). *Shadows of the mind*. New York: Oxford University Press.
- Price, R. K., Spitznagel, E. L., Downey, T. J., Risk, N. K., & El-Ghazzawy, O. G. (2000). Applying Artificial Neural Network Models to Clinical Decision Making. *Psychological Assessment*, 12(1), 40-51.
- Regueiro, C., Barro, S., Sánchez, E., & Fernandez-Delgado, M. (1995). Modelos básicos de redes neuronales. In S. Barro & J. Mira (Eds.), *Computación neuronal*. (pp. 181-218). Universidad de Santiago de Compostela.
- Rivière, A. (1998). *Objetos con mente*. Madrid: Alianza - Psicología minor.
- Russel, S., & Norving, P. (1995). *Artificial Intelligence. A Morden Approach*. New Jersey: Prentice Hall.
- Sperry, R. W. (1993). The Impact and Promise of the Cognitive Revolution. *American Psychologist*, 48(8), 878-885.
- Tejada, J., Perilla, L., Serrato, S. & Reyes, A. (2004) Simulación del dilema del prisionero a partir del modelos conexionistas de aprendizaje por reforzamiento. *Summa Psicológica* 11(1). 29-51.
- Willians, W., Carson, N., & Sherald, M. (1999). Neural Networks assist in job performance: Hiring the best candidates at lower cost. *PC AI*, 13, 33-36.

### **Autor**

**Julián Tejada Herrera**. Profesor de la Facultad de Psicología de la Fundación Universitaria Konrad Lorenz. Bogotá, Colombia. E-mail: [julian\\_tejada@hotmail.com](mailto:julian_tejada@hotmail.com)