



Una mirada a la neurocomputación artificial

Jorge Eduardo Ortiz Triviño, Instructor Asociado, Departamento Ingeniería de Sistemas, Universidad Nacional de Colombia.
e-mail: jorgeo@ingenieria.ingsala.unal.edu.co

RESUMEN

Las Redes Neuronales Artificiales son modelos matemáticos conformadas por dispositivos simples de cómputo, densamente interconectados, en forma similar al modo en que se configuran las neuronas naturales en el cerebro humano. Son capaces de resolver problemas que, en muchos casos, no tienen solución mediante las técnicas computacionales tradicionales, tales como el reconocimiento de patrones. En medicina existen problemas que, potencialmente, pueden solucionarse mediante neurocomputación, por ejemplo la segmentación de Imágenes de Resonancia Magnética.

INTRODUCCIÓN

Las Redes Neuronales Artificiales (RNA) son sistemas sintéticos que pueden emular una de las características propias de los seres humanos: la *capacidad de memorizar y asociar hechos*. Si se examina con atención algunos problemas que no pueden expresarse a través de un algoritmo, tales como identificar en fracciones de segundo a una persona determinada en una multitud, es fácil, desde la óptica de la ingeniería, concluir que todos ellos tienen una característica en común: la *experiencia*. El hombre es capaz de resolver estas situaciones acudiendo a la experiencia acumulada. Así, parece razonable pensar que una forma de aproximarse a la solución de este tipo de problemas con-

siste en la construcción de sistemas que sean capaces de simular esta característica humana.

La observación anterior ha sido adoptada por científicos de las ciencias del computador en lo que se ha denominado *Neurocomputación* área cuyo objeto de estudio se denominan las Redes Neuronales Artificiales, que, en lenguaje sencillo son un modelo artificial y simplificado del cerebro humano (el cerebro humano es, sin duda alguna, el computador más perfecto del cual tengamos noticia), o dicho de otra manera, una red neuronal es un sistema para el procesamiento de información y cuya unidad básica de procesamiento está inspirada en la célula fundamental del sistema nervioso humano: *la neurona*.

En este artículo se examina un modelo simplificado de neurona artificial, se presentan algunas configuraciones básicas de RNA, se introducen las características más importantes de éstas como son el aprendizaje y la capacidad de adaptación y se culmina con la exploración de una de las aplicaciones más difundidas como es la clasificación, orientado esta vez, a la segmentación de IRM.

RED NEURONAL NATURAL

Una red neuronal natural está conformada por un gran número de células ner-

viosas, denominadas neuronas, las cuales se encuentran interconectadas masivamente. Una neurona consta esencialmente, como se ilustra esquemáticamente en la figura 1, de un cuerpo, denominado soma, al cual están conectadas unas fibras nerviosas, llamadas dendritas, y un axón, una fibra delgada y larga, dividida en su extremo en una serie de fibra terminales.




Figura 1. Esquema simplificado de Una Neurona Natural.

La neurona recibe señales de entrada provenientes de otras neuronas, a través de las dendritas, que se conectan con las dendritas de las células emisoras en un proceso durante el cual se lleva a cabo un intercambio electroquímico entre las partes. Las uniones de una neurona con otra pueden ser excitatorias o inhibitorias. Cuando la suma de las intensidades de todas las entradas supera un umbral determinado, la neurona

transmite una señal a través de su axón a las demás neuronas conectadas a ella.

De acuerdo con algunos resultados de la neurofisiología, la buena capacidad de cómputo de las redes neuronales radica en su estructura masivamente paralela pues, aunque la velocidad de conmutación de una neurona biológica es mucho menor que la de ciertos componentes electrónicos actuales, mediante los métodos de computación tradicionales es prácticamente imposible resolver ciertos problemas de la vida cotidiana que sí son fácilmente solubles por el cerebro humano.

RED NEURONAL ARTIFICIAL

Una neurona artificial es un modelo matemático, en ocasiones denominado autómata, que recibe una señal (valor) de entrada, asume un estado (valor) y produce una señal respuesta en un determinado momento.

De esta manera, una Red Neuronal Artificial, como la mostrada en la figura 2, consiste en una colección de neuronas artificiales, las cuales están interconectadas mediante relaciones con ponderaciones asociadas, es decir, valores vinculados a cada conexión. Cada unidad tiene un estado que es un valor real continuo entre cero y uno y retorna este estado a las unidades con las cuales está conectada. El estado de una neurona artificial se actualiza continuamente de la siguiente manera: el nuevo estado es una función de la suma de ponderaciones de sus entradas y usualmente esta función es una sigmoide. Gráficamente una Red Neuronal Artificial se observa en la figura 2. Allí cada neurona artificial se representa por un círculo y las relaciones mediante líneas; a cada línea, en la práctica, se la etiqueta con su valor de ponderación usando la letra ω .

Como se observa, algunas de las neuronas son designadas como neuronas de entrada, es decir, su estado es puesto

por el ambiente y otras son designadas como neuronas de salida, es decir, su estado es enviado al ambiente. El aprendizaje se da por cambio de las ponderaciones de las conexiones y este cambio depende del error, es decir, la diferencia entre la salida actual y la salida deseada de la red, dada la entrada. Éste es un ejemplo de aprendizaje supervisado puesto que se requiere un profesor quien provee la salida deseada.




Figura 2. Esquema de una Red Neuronal Artificial.

En contraste, existe el aprendizaje por refuerzo que es un ejemplo de aprendizaje no supervisado. La salida de la red se evalúa como favorable o desfavorable por el ambiente y esta evaluación es realimentada como una señal de refuerzo positiva o negativa a la red. No hay necesidad de un profesor quien provea la salida deseada. Adicionalmente, esta realimentación puede ser retardada, es decir, la señal de salida puede usarse como refuerzo en un tiempo futuro. De esta manera, la aplicabilidad del aprendizaje por refuerzo es mucho más amplio que el aprendizaje supervisado.

De otro lado, el modelo de neurocomputación más simple es el que relaciona la salida de una neurona con las entradas ponderadas a través de una función de activación (Figura 3), este modelo, denominado perceptrón simple, permite resolver problemas de diferenciación entre patrones sólo si estos son linealmente separables, esto es si puede construirse una función lineal que divida el espacio de ocurrencia de

los patrones en regiones mutuamente excluyentes, de tal forma que patrones diferentes se encuentren localizados en regiones diferentes.




Figura 3. Estructura general de un perceptrón simple.

Este modelo, propuesto por McCulloch y Pitts en 1943, relaciona las entradas x_i y las salidas y_i de la neurona mediante una función de activación $\sigma(x)$. En consecuencia, la relación entre las entradas y las salidas de la neurona está dada por:

$$\sigma\left(\sum_{i=1}^n \omega_i x_i - \theta\right) \quad (1)$$

donde $\sigma(x)$ es la función escalón unitario:

$$\sigma(x) = \begin{cases} 0 & \text{Si } x < 0 \\ 1 & \text{Si } x \geq 0 \end{cases} \quad (2)$$

Ejemplo. La figura 4 (a) ilustra la configuración de un perceptrón simple, que se muestra en la figura 3, realiza la función lógica AND de sus entradas:




Figura 4. Perceptrón simple como compuerta AND.

L es la línea recta $\omega_1 x_1 + \omega_2 x_2 - \theta = 0$. Para $\theta = 1.2$, los valores $\omega_1 = 0.5$ y ω_2

$= 1$ hacen que L separe el espacio de patrones en dos clases, cada una de ellas correspondiendo a cada tipo de salida de la función AND. De las ecuaciones (1) y (2) se tiene que la salida de la red será 1 si $0.5x_1 + x_2 - 1.2 = 0$ es mayor que 0, y 0 en caso contrario; así, para $(x_1, x_2) = (0,0)$, $(x_1, x_2) = (0,1)$, $(x_1, x_2) = (1,0)$, será igual a 0 y para $(x_1, x_2) = (1,1)$ la salida será 1.

Los valores para los pesos no son únicos: existe un infinito número de valores para las ponderaciones con las cuales se satisface la función (en general, cualquier recta L que separe en forma adecuada el espacio de patrones).

Un trabajo, catalogado como desafortunado por algunos científicos de la Neurocomputación, desarrollado por Minsky y Papert demostró que el perceptrón era incapaz de realizar tareas de procesamiento simples tales como el cálculo de la función lógica "o exclusivo" (XOR). Trabajos posteriores, sin embargo, mostraron que con otras arquitecturas de red pueden solucionarse éste y otros problemas más complejos.

SEGMENTACIÓN DE IMÁGENES DE RESONANCIA MAGNÉTICA

Los campos de aplicación de las Redes Neuronales Artificiales solo están limitados por la imaginación de los investigadores en las diversas disciplinas científicas. En el caso de medicina, para poner sólo un ejemplo, se han aplicado con éxito en la segmentación de Imágenes de Resonancia Magnética (IRM) del cerebro, mostrando resultados mejores que los obtenidos con otras técnicas como las del histograma.

En esta dirección, algunos profesores del Grupo de BioInformática, del Departamento de Ingeniería de Sistemas de la Universidad Nacional de Colombia ha venido trabajando desde hace ya algunos años en Neurocomputación y han incursionado recientemente en aplicaciones en áreas de las Ciencias de la Salud. Específicamente, para la segmentación de imágenes uno de los modelos de redes neuronales artificiales que se ha empleado es la red de *Hopfield* discreto.

El modelo de *Hopfield* discreto consiste en una red monocapa con N neuronas artificiales cuyos valores de salida son binarios: 0 / 1 ó -1 / 1. Donde cada neurona de la red se encuentra conectada a todas las demás pero no consigo misma. Las ponderaciones asociadas a las conexiones entre pares de neuronas son simétricos y su Función de activación de tipo escalón.

DISCUSIONES Y CONCLUSIONES

Además de permitir la resolución de una gran variedad de problemas, las Redes Neuronales Artificiales poseen también desventajas. Una de las desventajas está en que requieren la definición de muchos parámetros antes de poder aplicar la metodología. Por ejemplo, hay que decidir la topología de la red más apropiada, el número de capas de neuronas ocultas, el número de neuronas por capa, las interconexiones, la función de transformación, etc.

Otra desventaja de las Redes Neuronales es que no ofrecen una interpretación fácil como si lo hace, por ejemplo, un algoritmo que calcule una regresión lineal.

Con todo, a pesar de estas desventajas, las redes neuronales han resultado una excelente y única alternativa en la resolución de problemas que por métodos algorítmicos y secuenciales, eran difícil, si no imposible, de modelar y solucionar.

AGRADECIMIENTOS

El autor desea expresar sus agradecimientos al Dr. Alvaro Rodríguez Gama, Editor de esta Revista, al Profesor J.J. Martínez, del Departamento de Ingeniería de Sistemas de la Universidad Nacional, y a John Jairo López por sus valiosos comentarios y apoyo en la realización de este artículo.

REFERENCIAS BIBLIOGRÁFICAS

1. **Goles E.** Automata Networks, Birkhauser. 1990.
2. **Holland JH.** Adaptation in Natural and Artificial Systems: An Introductory Analysis with Applications to Biology, Control and Artificial Intelligence, MIT Press. 1992.
3. **Kosko B.** Neural Networks and Fuzzy Systems: A Dynamical Systems Approach. Prentice-Hall. 1992.
4. **Narendra K, Thathachar MAL.** Learning Automata : An Introduction. Prentice-Hall. 1989.
5. **Saba FJ.** Clarise'96. Congreso Latinoamericano Regional de Informática en Salud. Argentina. 1996
6. **Hilera JR, Martínez VJ.** Redes neuronales artificiales: Fundamentos, modelos y aplicaciones. De la edición RAMA. 1995.
7. **Windrow A, Lehr M.** 30 Years of Adaptive Neural Networks: Perceptron, Madaline and Backpropagation. Proc. IEEE. 1990: 78.