

Redes neuronales, procesos cognoscitivos y análisis de la conducta. ¹

Rogelio Escobar²

Universidad Nacional Autónoma de México

Resumen

Se analiza la importancia de los modelos de redes neuronales para el entendimiento de los procesos cognoscitivos en psicología y especialmente en el análisis de la conducta. En el trabajo se describen las diferencias entre los modelos simbólicos y los modelos conexionistas o de redes para la descripción de los procesos cognoscitivos. Posteriormente se describen los modelos de redes y se detallan los cálculos relacionados con la función de activación y el entrenamiento de la red a partir de las reglas de aprendizaje y la estimación del error. En la última sección se analiza la importancia de integrar los modelos de redes al análisis de la conducta. Se concluye que los modelos de redes pueden servir como un puente para que las explicaciones surgidas del análisis de la conducta se extiendan a la explicación de fenómenos típicos de la psicología cognoscitiva como la representación y la memoria. Un propósito adicional es que este trabajo sirva como una introducción que permita a los psicólogos y analistas de la conducta entender el funcionamiento de las redes neuronales artificiales a partir de ejemplos relativamente simples.

Palabras clave: *redes neuronales, modelos de redes, modelos simbólicos, procesamiento de la información, análisis de la conducta*

Abstract

This article analyzed the importance of artificial neural network models for understanding cognitive processes in psychology and especially in behavior analysis. Differences between symbolic and connectionist or network models in the description of cognitive processes are described. Subsequently, network models are described and the calculations related to the activation function and network training using rules of learning and error estimation are detailed. The final section discusses the importance of integrating network models in behavior analysis. It is concluded that network models can serve as a bridge to extend the explanations that emerged from behavior analysis into phenomenon like memory and representation that are typically studied in cognitive psychology. An additional purpose is that this paper could serve as an introduction allowing psychologists and behavior analysts to understand how artificial neural networks work using relatively simple examples.

Key words: artificial neural networks, network models, symbolic models, information processing, behavior analysis.

Dentro del campo de la inteligencia artificial y el aprendizaje de máquinas, se han generado diversos algoritmos que permiten que un programa pueda modificar su funcionamiento a partir de la experiencia (Mitchell, 1997). Algunos de estos algoritmos pueden considerarse como simulaciones por computadora de procesos cognoscitivos en humanos, tales como el aprendizaje y la memoria.

¹ La referencia de este artículo en la Web es: <http://conductual.com/content/redes-neuronales-procesos-cognoscitivos-y-analisis-de-la-conducta>

² Correspondencia: Rogelio Escobar. Laboratorio de Condicionamiento Operante. Facultad de Psicología, UNAM. Av. Universidad 3004, Colonia Copilco-Universidad. C.P. 04510. México, D.F. México. Tel. 56222303. Email: rescobar@unam.mx

El aprendizaje de máquinas es importante debido a que permite el diseño de programas que pueden adaptarse a ambientes cambiantes o en los que no pueden predecirse con precisión las condiciones en las cuales deberá ejecutarse el programa. Algunas aplicaciones del aprendizaje de máquinas son el reconocimiento de escritura y voz, y la clasificación de datos. A pesar de que a partir del auge de las teorías del aprendizaje en psicología y específicamente del desarrollo del análisis de la conducta, y de que durante décadas se han estudiado las variables que controlan el aprendizaje de patrones conductuales tanto en humanos como en animales no humanos, la interacción entre el análisis de la conducta y el aprendizaje de máquinas ha sido mínima (Hutchison, 2012).

Una de las razones para la falta de esta interacción es que dentro del análisis de la conducta la creación de modelos o simulaciones por computadora son reminiscentes del problema que advirtió Skinner (1950) de estudiar un sistema nervioso conceptual que, por su carácter especulativo, aportara poco a nuestro entendimiento del comportamiento. Una crítica similar puede aplicarse al estudio de procesos hipotéticos que sirvan como mediadores de las relaciones entre el medio ambiente y la conducta (Skinner, 1977). Para algunos autores (e.g., Epstein, 1984), las simulaciones por computadora del aprendizaje pueden ser incorrectas si parten del supuesto de que los humanos son procesadores de información a partir de la cual forman reglas para generar conducta compleja.

Existen al menos dos preguntas que habrían de contestarse para determinar la importancia de la interacción entre el análisis de la conducta y los modelos del aprendizaje de máquinas: 1) ¿qué pueden ganar los analistas de la conducta al estudiar simulaciones por computadora de procesos tradicionalmente estudiados en campos como las neurociencias y la psicología cognoscitiva? y 2) ¿los avances en el análisis de la conducta podrían ser de utilidad para el desarrollo del aprendizaje de máquinas y la inteligencia artificial?

El presente trabajo trata de dar respuesta a estas preguntas con el ejemplo específico de las redes neuronales que no sólo han permitido simular procesos de aprendizaje sino que podrían convertirse en sustitutos de las metáforas del procesamiento de la información o modelos simbólicos tradicionalmente utilizados en la psicología cognoscitiva. Para poder contestar las preguntas, primero se describen brevemente las diferencias entre los modelos simbólicos y conexionistas o de redes para el entendimiento de los procesos cognoscitivos. Posteriormente se describirá el desarrollo de los modelos de redes y se mostrarán ejemplos del funcionamiento de las redes neuronales que se espera faciliten el entendimiento de éstas. En la última sección se analizará la importancia de integrar los modelos de redes al análisis de la conducta y algunos aspectos en los cuales el análisis de la conducta podría contribuir al desarrollo del aprendizaje de máquinas.

El avance en el desarrollo de las computadoras en las décadas de 1950 y 1960 guiada, al menos parcialmente, por el modelo conceptual de la máquina de Turing (1936) que permitía que la computadora leyera símbolos de una tira y ejecutara diferentes acciones, tuvo impacto en la conceptualización de los procesos cognoscitivos en humanos. La teoría computacional de la mente (e.g., Putnam, 1961/1980) sirvió para conceptualizar el funcionamiento de los procesos cognoscitivos en términos similares al funcionamiento de las máquinas de Turing y de las computadoras en general; esto es, en términos del procesamiento de la información. De acuerdo con Pinker (1997), esta metáfora incluso resolvió el problema relacionado con el dualismo de usar fenómenos no físicos como las “intenciones” y los “deseos” como explicación de la conducta observable. Para Pinker la teoría computacional de la mente permite conceptualizar cómo el mundo se representa por medio de símbolos. En estos términos, las intenciones y los deseos son representaciones simbólicas del mundo y los símbolos, que surgieron a partir del contacto de los órganos de los sentidos con el mundo, pueden dar origen a nuevos símbolos que estén incluso asociados con conducta observable.

Una vez que se utiliza la metáfora del procesamiento de la información hay algunas preguntas que se vuelven importantes. Por ejemplo, en la psicología cognoscitiva un problema importante ha sido determinar cómo se “representa” el conocimiento. Una pregunta relacionada es ¿dónde y cómo se almacenan las representaciones del conocimiento? Si bien estas preguntas son importantes en términos de la metáfora del procesamiento de la información, desde el punto de vista del análisis de la conducta son irrelevantes debido a que parten de varios supuestos que podrían ser incorrectos (véase Skinner, 1974). Por mencionar solamente un ejemplo, una representación es un constructo que se utiliza para identificar una imagen o un “símbolo” que ocurre de manera “interna” o privada y “sustituye” a la ocurrencia de eventos observables. Cuando se asume que la representación se utiliza para llevar el “mundo exterior” al “mundo interior”, se hace una distinción entre dos aspectos del mundo: el privado, hecho de representaciones, y el observable hecho de aspectos “reales”. Una vez que se hace esta distinción, se cae en el error conceptual de asumir que el mundo interior no es más que una copia del mundo “real” y se abren preguntas acerca de si la copia es perfecta o imperfecta. Si se acepta el segundo caso, se tendría que concluir que nunca podremos saber cómo es el mundo “real” a partir de representaciones imperfectas. En cambio para el análisis de la conducta, la conducta privada que podría consistir, al menos en parte, de imaginar eventos, es una parte de la conducta que puede explicarse a partir de la interacción del organismo con el medio ambiente y, en este sentido, no es diferente de la conducta observable.

Aunque algunos autores han descrito que usar la metáfora del procesamiento de la información no significa decir que el funcionamiento cognoscitivo pueda equipararse con el de una computadora ni que el funcionamiento de las computadoras pueda darnos información sobre el funcionamiento cognoscitivo de las personas, la metáfora significa que, al menos parcialmente, el funcionamiento cognoscitivo sigue la lógica del procesamiento de la información (Lewis, 1999). Por ejemplo, puede pensarse que las personas poseen una unidad o un sistema en la cual se almacena la información con un código particular. Siguiendo con esta lógica, se podría incluso sugerir que la manera como se organiza el código es la representación y tanto el almacenamiento como la recuperación del código es la memoria. Estas metáforas han dado como resultado la creación de modelos simbólicos del funcionamiento cognoscitivo en los que se asume que las personas representan el conocimiento usando un proceso de manipulación de símbolos.

En los modelos simbólicos, la representación del conocimiento ocurre a partir del uso de símbolos. Un ejemplo puede ser el siguiente, si un operador introduce un 5 a una computadora (input) y pide que se añada 5 a ese número, la computadora presentará un 10. Este 10 es una representación simbólica de un concepto que tiene sentido para el operador humano pero no para la computadora. En la misma tradición, si alguien menciona que quiere a su perro, una persona entendería que ‘perro’ es una representación simbólica de un perro, que ‘quiere’ es una representación simbólica de la relación que una persona puede tener con su perro y que ‘perro’ es también el receptor del “afecto” de esta persona (véase Kelley, 2003). La representación simbólica del conocimiento ha abierto, entre otros, un debate que consiste en determinar si los símbolos codifican el conocimiento proposicionalmente (de manera abstracta) o por medio de imágenes o representaciones pictóricas analógicas (e.g., véase Kosslyn, 1980; Paivio, 1979; Pylyshyn, 1973).

De acuerdo con algunos psicólogos cognoscitivos y neuropsicólogos la actividad cognoscitiva o mental es el resultado de la actividad neuronal (Kalat, 2009). En este sentido, si representar y almacenar el conocimiento son actividades cognoscitivas, éstas deben estar asociadas con cierta activación del sistema nervioso central. A pesar de la importancia de la relación que existe entre los procesos cognoscitivos y la actividad neuronal, en la mayoría de los casos, la investigación en las neurociencias cognoscitivas se ha centrado en mostrar cómo es que áreas específicas del sistema nervioso central correlacionan con ciertas

actividades cognoscitivas (Gazzaniga, 2008). De esta forma, en algunos casos ha tratado de materializarse la metáfora de la representación y el almacenamiento de la información. Aunque este tipo de investigación provee información valiosa sobre la organización global del sistema nervioso, en ocasiones parece sugerir que hay partes específicas del cerebro en las cuales parece “almacenarse” información o “son centros” en los cuales se originan ciertas actividades cognoscitivas. Un problema con estas metáforas de localización es que tienden a crear homúnculos (Wegner, 2005) y otro es que debido a su carácter esencialista no ilustran adecuadamente el funcionamiento conocido de las neuronas y sus conexiones (Palmer & Donahoe, 1992).

Como una alternativa a los modelos simbólicos y a las metáforas de la localización, los modelos de redes neuronales o conexionistas se alejan de la metáfora de la computadora y describen cómo la activación neuronal y su interconexión con otras neuronas pueden realizar diferentes funciones tanto en organismos vivos (redes neuronales biológicas) como en simulaciones por computadora (redes neuronales artificiales, véase Kehoe, 1989). Las redes neuronales se organizan a partir de la idea, tomada de nuestro entendimiento de las neuronas reales, de que una neurona es una célula que se especializa en la recepción de estímulos y en la transmisión de un impulso electroquímico en forma de un potencial de acción. Una neurona se conecta con otras neuronas a través de sinapsis. Cuando en una neurona se dispara un potencial de acción éste se extiende por el axón y por medio de la sinapsis el potencial de acción puede transmitirse o inhibirse en otras neuronas (e.g., Burgos, 2002).

Una red neuronal artificial (en adelante red neuronal) es un modelo por computadora que simula la interconexión y la actividad de las células neuronales. La tarea básica de una simulación por computadora de una red neuronal es definir un conjunto de unidades neuronales artificiales o nodos así como sus potenciales interconexiones y el peso de cada conexión. Después, a partir de una función de activación se determina si la activación de una neurona pre sináptica produce la activación de la neurona post sináptica. Posteriormente se añaden reglas bajo las cuales ocurren cambios en los pesos de las interconexiones bajo las cuales la red “aprende”. Finalmente, la red se entrena y se observa cómo la red cambia a partir de la experiencia o se adapta al ambiente (Olson & Hergenhahn, 2009).

Las redes neuronales tienen una serie de características generales. Una de las más importantes es que realizan procesamiento en paralelo. Esto es, que varias unidades neuronales pueden funcionar al mismo tiempo (véase Rumelhart & McClelland, 1986). Otra característica importante es que la “representación del conocimiento” e incluso la “memoria” del sistema se encuentran distribuidas entre sus partes (Hinton, McClelland & Rumelhart 1986). En contraste con los sistemas de representación local, en una red neuronal no se puede entender una actividad a partir de la activación de cada unidad neuronal sino sólo a partir de los patrones de funcionamiento de la red (Spratling & Johnson, 2004).

En este sentido, cuando se tratan de entender fenómenos como la memoria, en lugar de pensar en términos de almacenamiento y recuperación de la información, las redes neuronales nos llevan a conceptualizar el fenómeno como un cambio en la organización de la red como producto de la experiencia. Una vez que la red cambia, realiza una función diferente y este cambio es lo que conocemos como memoria. Cabe señalar que esta conceptualización es congruente con el análisis que Skinner (1974, véase también 1988) hizo de los procesos de “memoria” al decir que:

Una persona cambia por las contingencias de reforzamiento bajo las cuales se comporta; no almacena las contingencias. En particular, no almacena copias de los estímulos que han jugado una parte en las contingencias. No hay “representaciones icónicas” en su mente; no hay “estructuras de datos almacenadas en su memoria”; no tiene un “mapa cognoscitivo” del mundo en el que vive. Solamente ha cambiado de tal forma que los estímulos ahora controlan tipos particulares de conducta perceptual (p. 93, traducción del autor).

Desarrollo histórico

Los modelos de redes neuronales se originaron con el trabajo de McCulloch y Pitts (1943). Estos autores describieron un modelo que consistió en usar unidades que compartieran características con las neuronas biológicas. Por ejemplo, una neurona puede recibir una cierta cantidad de entradas excitatorias y una cierta cantidad de entradas inhibitorias. La actividad de la neurona, que debe mantener un estado binario (dispara o no dispara), está determinada por la suma de estas entradas. Si la suma de las entradas excitatorias excede un umbral, Φ , la unidad dispara. Esta función de activación se conoce como función de transferencia de escalón o de umbral y se describirá en la siguiente sección. En el modelo de McCulloch y Pitts (MMP), si al menos una entrada inhibitoria tiene un valor de activación de 1, la unidad no dispara. Otra característica importante de las redes neuronales conforme al MMP fue que la estructura de la red no cambiaba con el tiempo. En un ejemplo sencillo de este tipo de red, podría suponerse que se requiere que la red resuelva la función lógica AND. Para realizar esta función se necesitan al menos dos unidades de entrada y una unidad de salida. Con este ejemplo, únicamente cuando cambie el estado de ambas entradas, la neurona emite un disparo. Esta función podría ser útil para reconocer y clasificar objetos con base en dos características. Para realizar esta función se establece el valor de los pesos de la conexiones (w_1 y w_2) en un valor arbitrario de 0.5. El valor de activación se calcula al sumar el producto de las entradas x_1 y x_2 (que puede ser activo +1 o no activo 0) y los pesos de la conexión ($x_1 w_1$) + ($x_2 w_2$) y este valor de activación se compara con el valor del umbral (en este ejemplo tendría que ser 1). Si ambas entradas están activas, el resultado de la suma de los pesos multiplicados por el valor de la entrada es de 1. En este caso se produce un disparo dado que el valor es igual al valor del umbral. Si sólo una de las entradas estuviera activa, el valor de la activación sería de 0.5 que es menor que el valor del umbral y no ocurriría el disparo. Con esta red puede evaluarse fácilmente la función lógica OR si se reduce el valor del umbral, por ejemplo a 0.5. De esta forma, la activación de una o ambas entradas generaría un disparo.

McCulloch y Pitts (1943) partieron del conocimiento de la época de que las neuronas debían mantener un estado binario e integraron esta lógica en su modelo. Este concepto ha cambiado y actualmente no sólo se considera el potencial de acción que puede o no ocurrir sino también la frecuencia del potencial. Estos cambios se han integrado a los modelos de redes neuronales que, en lugar de considerar a las neuronas como operadores binarios, actualmente las consideran como análogas a los convertidores de voltaje a frecuencia o un convertidor analógico a digital (Anderson, 1988).

Un paso importante en el entendimiento del funcionamiento neuronal que eventualmente se integró en las redes neuronales, consistió en que Hebb (1949) describió el principio que se conoce como la ley de Hebb y que dice, en términos generales, que cuando una neurona excita a otra neurona, la conexión entre las dos se vuelve más fuerte. Esta ley se ha parafraseado como "las neuronas que disparan simultáneamente se conectan". La ley de Hebb se ha integrado a la literatura sobre redes neuronales y permite ver que el funcionamiento de la red cambia con la experiencia. En una red neuronal, la conexión entre dos neuronas se vuelve más fuerte o, en otras palabras, aumenta la probabilidad de que la activación de una neurona active a la segunda conforme a una regla que se conoce como regla de aprendizaje. Esta regla de aprendizaje es una característica esencial en las redes neuronales posteriores a la de McCulloch y Pitts (1943) (e.g., Rosenblatt, 1958).

Durante las décadas de 1950 y 1960 ocurrieron avances importantes en los modelos de redes neuronales; por ejemplo, el perceptron de Rosenblatt (1958) que permitía discriminar entre dos patrones y ajustar los pesos de las conexiones a partir del funcionamiento de la red. Otro ejemplo es ADALINE de Widrow y Hoff (1960) que se aplicó a la reducción del eco en las líneas telefónicas. Sin embargo, para algunos autores las redes neuronales estuvieron cerca de desaparecer después de que Minsky y Papert (1969) hicieron evidente que el perceptron, igual que las redes basadas en el MMP, no podía resolver

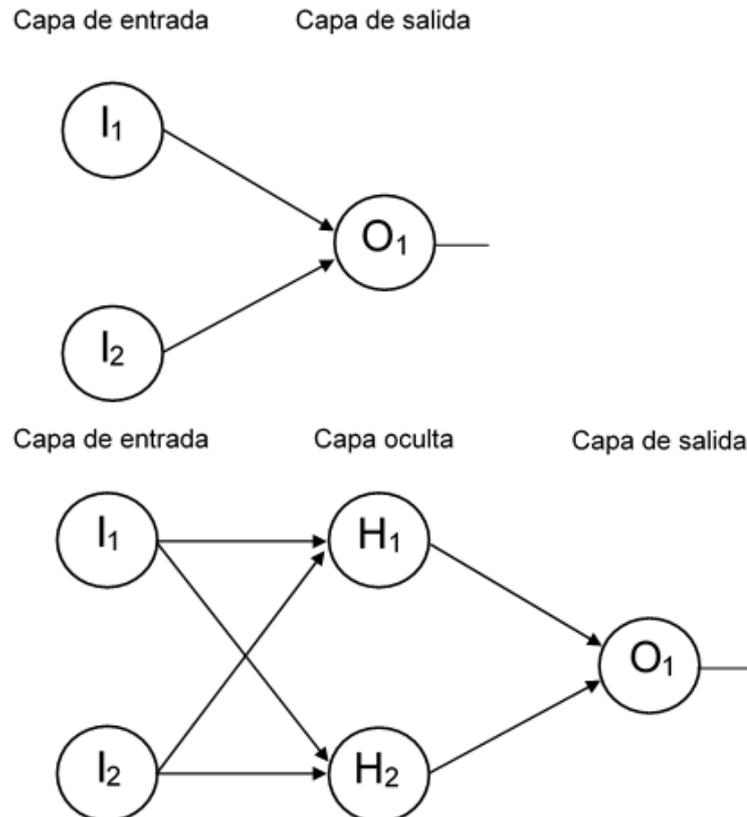
problemas relativamente simples como evaluar la función lógica de *OR exclusivo* (XOR) (véase la siguiente sección para una descripción detallada de este problema). Durante los siguientes años se realizaron relativamente pocos avances en el estudio de las redes neuronales.

Rumelhart, Hinton, y Williams (1986) sentaron las bases para el desarrollo de las redes neuronales como se conocen actualmente cuando añadieron una capa de neuronas (oculta) entre las neuronas de entrada y las neuronas de salida, lo cual permitió solucionar el problema de la función lógica XOR. Otro aspecto importante fue que definieron claramente el concepto de retro propagación que fue incorporado en las redes neuronales y que permiten usar reglas de aprendizaje a partir de las derivadas de las funciones de activación.

Redes neuronales artificiales

Hay algunos conceptos importantes para entender el funcionamiento de una red neuronal. Uno es el concepto de unidad neuronal de procesamiento que también se conoce como nodo o simplemente como unidad y simula el funcionamiento de una neurona (aunque incluso una unidad puede estar compuesta de un conjunto de neuronas). Cada unidad recibe un valor de entrada y genera un valor de salida. En la Figura 1 se muestran dos redes. En la parte superior de la figura, una unidad de salida está conectada a dos unidades de entrada. Cada columna en la figura se describe como una capa. En este ejemplo solamente existe una capa de entrada y una capa de salida. En la parte inferior de la figura se muestra una red con una capa intermedia u oculta. Estas capas, como se mostrará, son importantes en la solución de tareas complejas. Las unidades de la capa de entrada no se consideran formalmente como unidades neuronales de procesamiento debido a que su valor de salida es generado por el programa y no requieren un valor de entrada.

Figura 1. Redes neuronales artificiales con dos capas (parte superior) y tres capas (parte inferior).

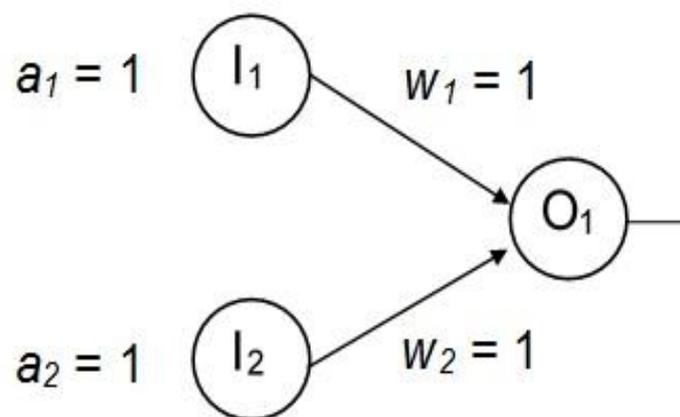


El valor de salida de cada unidad se conoce como valor de activación y simula el disparo de la neurona. En el modelo de McCulloch y Pitts (1943) la activación podía tener un valor de 0 ó 1. En la mayoría de las redes posteriores, la activación puede tener diferentes valores pero generalmente los valores se normalizan. Una característica importante en las redes de pre alimentación (*feed forward*) como las que se muestran en los ejemplos es que la estimulación se mueve en una sola dirección; esto es, hacia la capa siguiente. Una unidad no puede conectarse con otras unidades de la misma capa ni con unidades de la capa anterior.

Otro concepto importante en las redes neuronales es el peso de las conexiones. El peso simula la sinapsis y determina junto con la activación de la neurona en la capa anterior el valor de activación de la neurona receptora. Un supuesto importante de las redes neuronales es que el valor de la activación de la unidad inicial y el peso se multiplican para generar el valor de activación de la neurona de salida.

En la Figura 2, se muestra un ejemplo simple de una red neuronal con dos neuronas de entrada y una de salida. El valor de la activación de las unidades de entrada puede ser una combinación de 1 y 0 (a la manera del modelo de MacCulloch y Pitts, 1943). En este ejemplo el valor de ambas unidades de entrada se establecerá en 1 ($I_1 = 1$, $I_2 = 1$). El peso de las conexiones se determina inicialmente de manera arbitraria y posteriormente cambia a partir de una función de aprendizaje que se describirá más adelante. Para mantener este ejemplo, tan simple como es posible, los pesos de las conexiones entre las neuronas de entrada y la neurona de salida se establecerán también en 1 ($w_1 = 1$, $w_2 = 1$).

Figura 2. Red neuronal con dos valores de activación y dos pesos en las conexiones.



Por lo tanto, en el ejemplo, el valor de activación de la neurona de salida está determinado por:

$$a \cdot w = \sum_{i=1}^2 a_i w_i$$

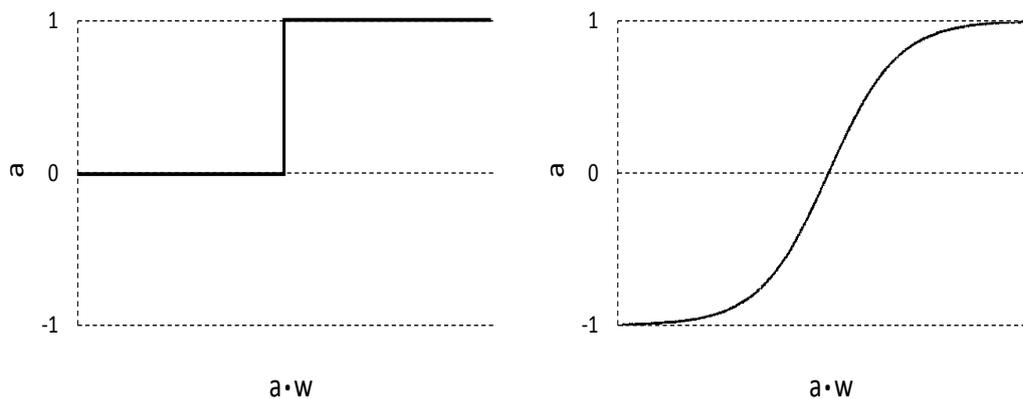
En este ejemplo $aw = a_1w_1 + a_2w_2 = 2$. Una vez que se calcula la sumatoria del producto del valor de activación de entrada y el peso, es necesario usar la función de activación para generar el valor de activación de salida. Existen diferentes funciones de activación. Por ejemplo, en el modelo de McCulloch

y Pitts (1943) y en el perceptron de Rosenblatt (1958) la función de activación fue de umbral o de transferencia de escalón y se representa de la siguiente manera:

$$f(a) = \begin{cases} 1 & \text{si}(a \cdot w \geq \Phi) \\ 0 & \text{si}(a \cdot w < \Phi) \end{cases}$$

Donde Φ es el valor del umbral. Si en el ejemplo anterior el umbral se establece en 1, entonces el valor de activación de entrada de 2 resultaría en un valor de activación de salida de 1. Cabe señalar que el valor de umbral y los valores de activación son arbitrarios y pueden cambiar en los diferentes ejemplos. Los valores que se utilizan están determinados por el funcionamiento deseado de la red. En el panel izquierdo de la Figura 3 se muestra la representación gráfica de la función de activación de escalón.

Figura 3. Representación gráfica de las funciones de activación de escalón (izquierda) y sigmoïdal (derecha). En ambos paneles a representa el valor de la activación de salida y aw representa el producto de la activación de entrada y el peso de la conexión.



En la mayoría de la redes neuronales multicapa, se utiliza la función sigmoïdal o logística que permite que el valor de activación adquiera diferentes valores entre 0 y 1. Esta función de activación se representa de la siguiente manera:

$$a = \frac{1}{1 + e^{-aw}}$$

Una ventaja de la función sigmoïdal es que su derivada puede usarse para ajustar los pesos en la regla de aprendizaje de retro propagación (*backpropagation*). Las reglas de aprendizaje se describen en la siguiente sección. En el panel derecho de la Figura 3 se muestra la representación gráfica de la función de activación sigmoïdal. Aunque existen otras funciones de activación (e.g., lineal) estas no se describirán en el presente trabajo.

Si se usa la función de activación sigmoïdal con la red del ejemplo anterior en la que se calculó que el valor de activación de la entrada fue 2, el valor de activación de salida sería de 0.88. Esto es

$$a = \frac{1}{1 + e^{-aw}} = \frac{1}{1 + 2.71^{-2}} = \frac{1}{1 + 0.13} = 0.88$$

Puede establecerse un umbral Φ para transformar este valor en una salida binaria en caso de que sea necesario. Por ejemplo, si Φ se establece 0.5, un valor de activación de 0.88 cambia el estado de 0 a 1.

La red descrita en el ejemplo con un valor de umbral de 0.5 puede usarse para evaluar la función lógica OR. La sección izquierda de la Tabla 1 muestra la tabla de verdad de la función lógica OR. Para evaluar la función lógica OR quisiéramos que la entrada de las dos unidades (I_1 , I_2) produjera en una unidad de salida el valor descrito en la columna salida en la tabla. En el cálculo anterior la red recibió entradas con valor de 1 en I_1 y 1 en I_2 . El resultado de la red fue 0.88, que al ser mayor que el umbral de 0.5, se transformó en 1. Ahora si la red recibe 1 en I_1 y 0 en I_2 o si recibe 0 en I_1 y 1 en I_2 , el valor de activación con la función sigmoideal resulta en un valor de activación de 0.73, que al ser mayor que el umbral se transforma en 1. En comparación, si la red recibe 0 en I_1 y 0 en I_2 , el valor de activación con la función sigmoideal resulta en un valor de activación de 0.5, que al ser igual que el umbral se transforma en 0. De esta forma pueden tomarse decisiones usando los valores de salida de la red conforme a la función lógica OR. Es decir, que si se recibe un input de cualquiera de las dos unidades se emite una respuesta.

Una forma de cambiar la función lógica a verificar de OR a AND es cambiando el valor del umbral, por ejemplo, a 0.75. La sección central de la Tabla 1 muestra la tabla de verdad de la función lógica AND. Al cambiar el valor del umbral únicamente cuando se recibe un valor de activación en las dos unidades de entrada se produce un cambio de estado de 0 a 1 en la unidad de salida.

Tabla 1: Tablas de verdad de las funciones lógicas OR, AND y XOR.

| OR | | | AND | | | XOR | | |
|-------|-------|--------|-------|-------|--------|-------|-------|--------|
| I_1 | I_2 | Salida | I_1 | I_2 | Salida | I_1 | I_2 | Salida |
| 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 |
| 0 | 1 | 1 | 0 | 1 | 0 | 0 | 1 | 1 |
| 1 | 0 | 1 | 1 | 0 | 0 | 1 | 0 | 1 |
| 1 | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 0 |

Nota. La sección izquierda muestra la tabla de verdad de la función lógica OR, la sección central de la función lógica AND y la sección derecha de la función lógica XOR. I_1 se refiere al valor una de las entradas e I_2 se refiere al valor de la segunda entrada.

Como se describió en la sección anterior, una crítica que se hizo a las redes neuronales con dos capas y con unidades binarias como el perceptron de Rosenblatt (1958) es que no podían realizar tareas simples como verificar la función lógica XOR (Minsky & Papert, 1969). La tabla de verdad de la función lógica XOR se muestra en la sección derecha de la Tabla 1. Como puede verificar el lector, los cambios en el valor del umbral no son suficientes para verificar esta función lógica que solamente cambia de estado de 0 a 1 cuando se activa una de las unidades de entrada pero no las dos. Es otras palabras, la red no debe responder cuando ambas unidades de entradas están en 0 ó cuando ambas unidades de entrada están en 1.

Una forma de solucionar el problema consistió en añadir una capa intermedia u oculta entre las unidades de entrada y las unidades de salida como se muestra en la Figura 4. En las redes más completas se añaden también unidades de sesgo en las capas intermedia y de salida, que permiten mantener una constante en la interacción de las unidades de entrada y de salida.

Con fines didácticos en la Figura 4 los pesos se numeraron del 1 al 9. El valor de activación de las unidades de entrada I_1 e I_2 , en este primer ejemplo, es 0 y 1, respectivamente. El valor de activación del sesgo siempre es 1. Los pesos tendrán los valores iniciales descritos en la Tabla 2 con el propósito de probar la función lógica XOR. El valor inicial de los pesos cambia una vez que se integran las reglas de aprendizaje. Por el momento, estos pesos se mantendrán constantes en este paso.

Figura 4. Red neuronal con una capa de entrada con dos unidades I₁ e I₂, una capa oculta con dos unidades H₁ y H₂ y una capa de salida con una unidad O₁. Las unidades de sesgo se muestran como B₁ y B₂. Los pesos entre las conexiones (w) están marcados con flechas y están numerados del 1 al 9. Los valores de activación inicial se muestran en la parte izquierda del diagrama.

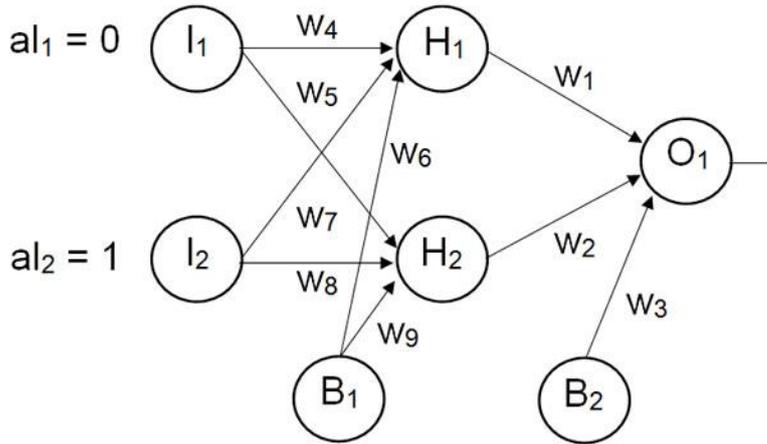


Tabla 2: Valores de los pesos.

| w | valor | conexión |
|---|-------|---------------------------------|
| 1 | 10 | H ₁ - O ₁ |
| 2 | 10 | H ₂ - O ₁ |
| 3 | -5 | B ₂ - O ₁ |
| 4 | 5 | I ₁ - H ₁ |
| 5 | -6 | I ₂ - H ₁ |
| 6 | -3 | B ₁ - H ₁ |
| 7 | -6 | I ₁ - H ₂ |
| 8 | 6 | I ₂ - H ₂ |
| 9 | -3 | B ₁ - H ₂ |

Nota. Los pesos corresponden a las conexiones descritas en la Figura 4 y están ajustados para probar la función lógica XOR (los valores fueron tomados de Heaton [2011]).

El primer paso es calcular el valor de activación de la unidad H₁.

$$H_1 = a((I_1 \cdot w_4) + (I_2 \cdot w_5) + w_6) = a((0) + (-6) + (-3)) = a(-9) = 0.00012$$

Dado que:

$$a(-9) = \frac{1}{1 + e^{-(-9)}}$$

El paso se repite para calcular el valor de activación de la unidad H₂.

$$H_2 = a((I_1 \cdot w_7) + (I_2 \cdot w_8) + w_9) = a((0) + (6) + (-3)) = a(3) = 0.95$$

Para calcular el valor de activación del output se toman ahora los valores de activación de H₁, H₂ y B₂.

$$O_1 = a((H_1 \cdot w_1) + (H_2 \cdot w_2) + w_3) = a((0.00012 \cdot 10) + (0.95 \cdot 10) + (-5)) = a(4.5) \\ = 0.98$$

El valor de activación de la unidad de salida es cercano a 1 y se considera como un cambio de estado de 0 a 1. Es posible repetir los pasos para calcular el valor de activación de la unidad de salida cuando el valor de activación de las unidades de entrada varía. En estos casos únicamente se debe reemplazar el valor de activación de I_1 y de I_2 . Los pesos y el valor de activación del sesgo (1) se mantienen constantes como se mencionó anteriormente. Con las diferentes combinaciones se producen los resultados que se muestran en la Tabla 3. Nótese cómo esta tabla muestra que la salida de la red cumple con los criterios de verificación de la función lógica XOR que no podía verificarse con las redes binarias de dos capas.

Regla de aprendizaje

Las redes neuronales comúnmente se clasifican en términos de sus algoritmos de entrenamiento y éstas pueden ser supervisadas o no supervisadas. Las redes supervisadas son las redes más comunes para resolver problemas. El entrenamiento consiste en generar diferentes pesos asociados con diferentes valores de activación de las unidades de salida y compararlos con una ejecución ideal (estimación del error). Conforme a una regla de aprendizaje los pesos se ajustan y se determina nuevamente el error que trata de disminuirse.

Las redes neuronales no supervisadas consisten en presentar diferentes patrones de entrenamiento y observar cómo la red cambia a partir de la experiencia pero la ejecución no se compara con una ejecución ideal. Las aplicaciones de las redes neuronales al modelamiento de procesos de aprendizaje ejemplifican este tipo de redes a pesar de que estas redes se usan infrecuentemente en otros campos. En esta sección se mostrará la diferencia entre estos dos tipos de redes.

Una forma común de tratar de disminuir el error en las redes neuronales es usar la técnica conocida como descenso de gradiente que usa la regla de retro propagación. Aunque existen otras técnicas (e.g., gradiente conjugado, Levenberg-Marquardt, algoritmos genéticos) éstas no se explicarán en el presente trabajo.

Para calcular el error deben compararse los valores de activación ideales (i) con los valores obtenidos (o) que genera la red. Por ejemplo, usando la tabla de verdad de la función lógica XOR se tienen cuatro resultados ideales ($i_1 - i_4$) que resultan de combinar los valores de activación de las dos unidades de entrada. A partir de las diferencias entre este resultado ideal y el valor de activación obtenido en la neurona de salida ($o_1 - o_4$) se calcula el error (E). Pueden usarse diferentes procedimientos, pero el procedimiento más común es el cálculo del error cuadrado medio (MSE) que está dado por la fórmula:

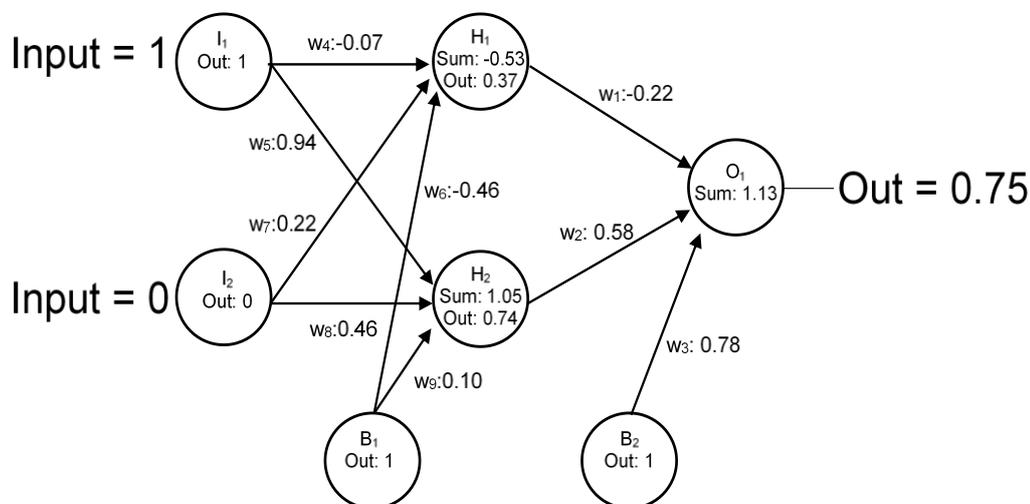
$$E = \frac{(o_1 - i_1)^2 + (o_2 - i_2)^2 \dots + (o_n - i_n)^2}{n}$$

El siguiente paso es calcular el gradiente que se refiere al error individual para cada uno de los pesos en la red neuronal. Este gradiente se calcula con la derivada de la función sigmoideal descrita en la sección anterior. En la Figura 5 se muestra una red neuronal con la misma estructura que se usó en el ejemplo anterior pero con diferentes pesos y valores de activación.

En la Figura 5, *out* significa el valor de activación, *sum* significa la sumatoria del producto de los pesos y el valor de activación. Los pesos (w) al inicio del entrenamiento de la red se establecen arbitrariamente y pueden tener cualquier valor. El gradiente se calcula para cada unidad de manera

individual. En el ejemplo, dada una combinación de inputs de 1 y 0, quisiéramos tener en la neurona de salida un valor de 1 pero el valor es de 0.75. Es decir, es necesario ajustar el valor de los pesos y para esto se utiliza la regla delta.

Figura 5. Red neuronal descrita en la Figura 4 con pesos establecidos arbitrariamente (los valores fueron tomados de Heaton [2011])



El primer paso consiste en calcular el gradiente en la neurona de salida. Primero se calcula el error por medio de la diferencia entre la salida obtenida y la salida ideal, $E = (o_1 - i_1) = -0.25$, el valor de delta de la capa se calcula con:

$$\delta_i = -E f'(a \cdot w)$$

Donde $a \cdot w$ = sumatoria del producto de los valores de activación y el peso en cada una de las conexiones con la unidad. E es igual al error en la salida. La primera derivada de la función sigmoideal de $a \cdot w$ resulta en delta. La primera derivada de la función sigmoideal es igual a:

$$f'(x) = x(1 - x)$$

Donde x es el valor de activación con la función sigmoideal. Siguiendo con el ejemplo, el valor delta de la capa estaría dado por:

$$\delta_i = -(-.25)(0.75(1 - 0.75)) = 0.046$$

Si el error alcanza un valor de 0, el valor de delta también sería de 0. En la siguiente capa (oculta) el valor delta se calcula con:

$$\delta_{k1} = f'(a \cdot w) \cdot \sum w_{k1i} \cdot \delta_i$$

Donde w_{k1i} se refiere a la sumatoria de los pesos que van de la unidad en la capa oculta a la capa de salida. δ_i se refiere al valor delta de la capa anterior. Con este ejemplo puede notarse cómo se realiza la retro propagación. En el ejemplo sólo hay un peso (w_1).

$$\delta_{k1} = (0.23)(-0.22)(0.046) = -0.0023$$

De la misma forma se calcula el valor delta de la siguiente unidad en la capa oculta.

$$\delta_{k2} = (0.19)(0.58)(0.046) = 0.0053$$

Con los valores de delta puede calcularse fácilmente el gradiente entre pares de unidades con la derivada parcial del error (e.g., entre H_1 y O_1).

$$\frac{\partial E}{\partial w_{ik}} = \delta_i O_k$$

Donde δ_i es el valor delta calculado para la capa de salida, O_K se refiere al valor de output en H_1 en el diagrama. En este caso el gradiente entre H_1 y $O_1 = (0.046)(0.37) = 0.017$. El gradiente entre H_2 y $O_1 = (0.046)(0.74) = 0.034$. El gradiente entre I_1 y $H_1 = -0.023$ y entre I_2 y $H_2 = 0$. El número de gradientes es igual al número de pesos en la red.

La regla de aprendizaje de retro propagación es:

$$\Delta w_t = \epsilon \left(\frac{\partial E}{\partial w_t} + \alpha \Delta w_{t-1} \right)$$

Donde Δw_t se refiere al cambio en el peso t y se utiliza para representar las repeticiones o iteraciones (t es la iteración actual, $t-1$ es la iteración anterior). ϵ es una constante que se conoce como tasa de aprendizaje que cumple con $0 < \epsilon < 1$ y determina la magnitud del cambio en los pesos. α es otra constante que se conoce como *momentum* y produce un valor mínimo de cambio constante.

Si $\epsilon = 0.7$ y $\alpha = 0.3$, de acuerdo con el gradiente H_1-O_1 .

$$\Delta w_t = 0.7(0.017 + (0.3 \cdot 0)) = 0.0119$$

Este valor se suma al peso anterior para producir un nuevo peso

$$w_{t+1} = -0.227 + 0.0119 = 0.215$$

Realizar los cálculos para cambiar cada uno de los pesos es una tarea repetitiva para la cual se utilizan programas de computadora. Estos programas realizan las tareas descritas en este trabajo en un número determinado de iteraciones. Una vez que el error es = 0, los pesos dejan de ajustarse.

Modelos de redes y aprendizaje

Una vez que se entiende el funcionamiento de las redes neuronales, puede entenderse con relativa facilidad como algunos modelos de redes han tratado de simular procesos de aprendizaje. En los modelos de redes de aprendizaje se han utilizado generalmente redes con entrenamiento no supervisado. En este caso los pesos de la red se ajustan a partir de una regla de aprendizaje pero no se comparan con una ejecución ideal. Una regla de aprendizaje usada comúnmente se conoce como regla de Hebb y consiste en:

$$w_{t+1} = w_t + \epsilon (o_{it} \cdot o_{kt})$$

Donde w_{t+1} se refiere al peso de la conexión en la siguiente iteración, w_t se refiere al peso en la iteración actual y O se refiere al valor de activación. Como puede observarse en la regla de Hebb, el peso cambia únicamente cuando el valor de activación de dos unidades (i y k) es mayor que 0. Congruente con la ley de Hebb, cuando dos neuronas disparan juntas se fortalece su conexión (cf. Hebb, 1949).

Caudill y Butler (1992) aplicaron la regla de Hebb en un modelo simple de aprendizaje respondiente. Por ejemplo, en una red con dos unidades de entrada y una de salida. El peso de una de las unidades de entrada (I_1) puede ser suficiente para que, al combinarse con un valor de activación positivo resulte en que el valor de activación de la neurona de salida (O) sobrepase el umbral. En cambio el peso de la otra unidad de entrada (I_2) puede especificarse de tal forma que al combinarse con la activación positiva de esta unidad, el resultado sea insuficiente para que el valor de activación de la neurona de salida alcance el umbral. Ahora, en un momento dado, debido a que la unidad de entrada I_1 produce un valor de activación alto en O. Este valor de activación de O puede cambiar el peso de su conexión con I_1 siempre y cuando el valor de activación de I_1 sea positivo. En términos psicológicos, la unidad de entrada I_1 es análoga a un estímulo condicional (EC), la unidad I_2 es análoga a un estímulo incondicional (EI), y la unidad O es análoga a la respuesta que originalmente sólo ocurre cuando se presenta (se activa) el EI y posteriormente puede ocurrir sólo cuando se presenta el EC.

Una modificación al modelo descrito de Caudill y Butler (1992) permite no sólo simular que la asociación entre el EC y el EI produce condicionamiento sino también algunos fenómenos del condicionamiento respondiente como el bloqueo y ensombrecimiento que no pueden modelarse con la regla de Hebb. Sutton y Barto (1981) describieron una regla de aprendizaje basada en el modelo de Rescorla y Wagner (1972). De acuerdo con esta regla:

$$\Delta w_t = \epsilon (y_t - \sum w x_{t-1}) x_{t-1}$$

Donde y_t es igual al máximo valor de activación de la unidad que simula el EI. $\sum w x_{t-1}$ es igual a la suma de todos los pesos de las conexiones para todas las unidades de entrada x y pesos w en la iteración previa ($t-1$). x_{t-1} permite que se cumpla la regla de Hebb. De acuerdo con el modelo de Sutton y Barto, los pesos de las unidades que simulan el EC incrementan si la diferencia entre el valor de activación máximo de la unidad que simula al EI es mayor que 0. Siguiendo con la lógica del modelo de Rescorla y Wagner, el peso, que tiene un límite superior, se distribuye entre las unidades de entrada que simulan los ECs.

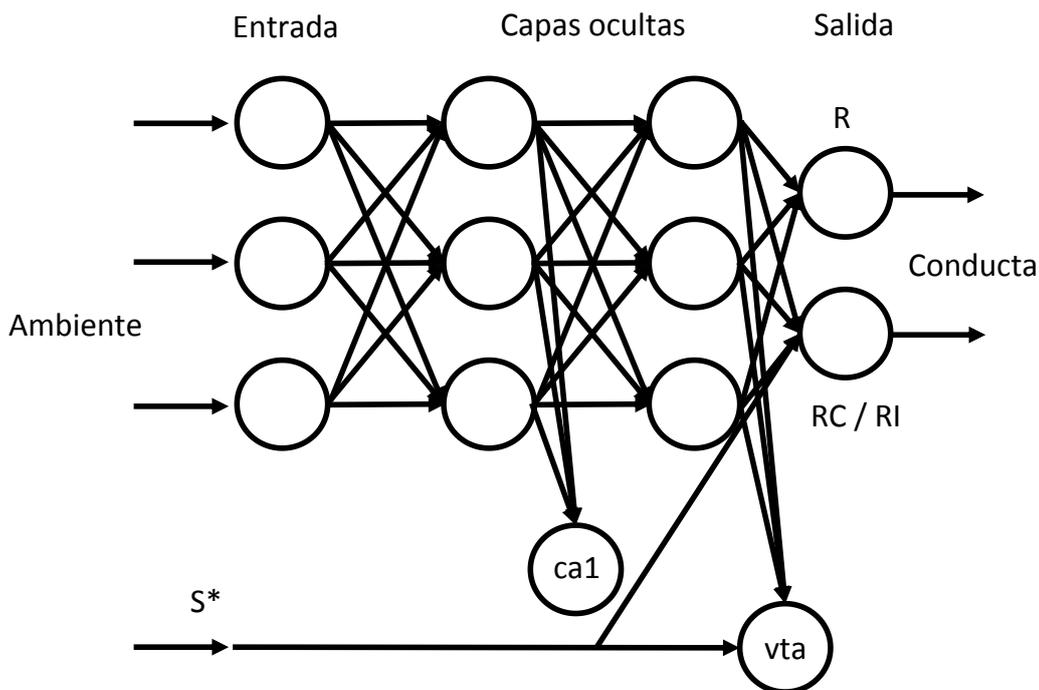
Hutchison (1984), y Hutchison y Stephens (1992) usaron una variación del modelo de Sutton y Barto (1981) que permite simular algunos elementos del condicionamiento operante. En este modelo la regla de aprendizaje es:

$$w_{t+1} = w_t + \epsilon (C_v - w_t)$$

En este modelo w representa el peso de la conexión entre un estímulo y una respuesta. C_v representa el valor de la consecuencia de una respuesta. Este modelo es reminiscente de la ley del efecto tal y como la enunciara Thorndike debido a que simula que si el valor de la consecuencia es mayor que el valor de la respuesta (una forma de establecer el valor reforzante) se fortalece la conexión entre un estímulo y la respuesta que le sigue.

La estructura de las redes neuronales que contienen tres capas, lógicamente permite simular tanto el control de estímulos antecedentes a la conducta como el efecto de las consecuencias sobre la misma conducta. Esta característica la explotaron Donahoe, Burgos, y Palmer (1993) en uno de los modelos más representativos de la interacción entre los modelos conexionistas y el análisis de la conducta (véase también, Donahoe & Palmer, 1994; Burgos, 2000, 2001). La parte central del modelo de Donahoe et al. es que la estructura de la red está inspirada en el conocimiento actual sobre el papel del área ventral tegmental (vta) que se ha mostrado que está relacionada con el efecto del reforzamiento (Hoebel, 1988) y las células del hipocampo (ca1) que están relacionadas con la asociación entre la presentación de estímulos y las respuestas subsecuentes. La estructura del modelo se muestra en la Figura 6.

Figura 6. Red neuronal descrita por Donahoe et al. (2003). En este diagrama R representa una respuesta. RC / RI representa una respuesta condicional e incondicional, vta representa el área ventral tegmental y ca1 representa a las células del hipocampo



En el modelo, S^* representa un reforzador. Una función del reforzador es como un EI que controla las respuestas que le siguen (RC/RI) de manera directa. Cualquier estímulo de entrada que se active junto con el S^* aumentará el peso de la conexión entre dicho estímulo y las respuestas subsecuentes. El efecto reforzante del S^* está mediado por el vta que aumenta el peso de conexiones entre la segunda capa oculta y las respuestas subsecuentes. El valor que se asigna a las ca1 funciona como el sesgo convencional que se mencionó en la sección anterior y cambia el peso de las conexiones de la primera capa oculta con la segunda capa oculta. Una característica importante del modelo es que únicamente distingue entre condicionamiento respondiente y operante en términos de si el efecto del reforzador se observa antes o después de la presentación de éste. Este modelo es uno de los que permite mostrar más claramente que la red neuronal puede servir para modelar procesos de condicionamiento operante y permite simular el funcionamiento del sistema nervioso central.

Conclusiones

A pesar de que algunos autores dentro de la tradición del análisis de la conducta han criticado las simulaciones computacionales de la conducta (e.g., Epstein, 1984), estas críticas se han dirigido a los modelos simbólicos y en especial a su aplicación a la simulación de procesos cognoscitivos. Por ejemplo Epstein (1999) notó que simular procesos cognoscitivos es incorrecto en varios aspectos. Por un lado, la topografía de la “conducta” en un modelo está determinada por la salida del modelo y aunque ésta podría ser similar a la topografía de la conducta humana, la función de la conducta es claramente diferente. Mientras que la “conducta” de un modelo está basada exclusivamente en reglas que se ajustan a las instrucciones del operador, la conducta humana está controlada tanto por reglas como por contingencias de reforzamiento y de castigo. Algunas otras críticas fueron que los modelos simbólicos de procesos cognoscitivos tienen poco en común con el funcionamiento del cerebro en los procesos cognoscitivos humanos, que se puede generar un gran número de modelos que produzcan el mismo resultado y que los

modelos de diferentes procesos cognoscitivos (e.g., atención, memoria, imaginación, lenguaje y percepción) tienen poco en común unos con otros. En contraste, Epstein (1999) aplicó las simulaciones por computadora de patrones conductuales para clarificar la descripción de su teoría generativa o de creatividad que describe la ocurrencia de nuevos patrones conductuales a partir de los patrones observados.

Aún existen relativamente pocos modelos de redes neuronales que integren principios importantes para el análisis de la conducta como el reforzamiento y el castigo (cf. Donahoe et al. 1993). Sin embargo, es notable que algunos de los modelos existentes provienen de tradiciones diferentes al análisis de la conducta. Por ejemplo, Enquist y Ghirlanda (2005), siguiendo un enfoque evolutivo, describieron como conceptos como motivación, entendida como un estado interno o externo al organismo, reforzamiento y castigo (descrito como reforzamiento negativo) pueden integrarse a los modelos de redes neuronales para simular conducta animal. En un ejemplo simple descrito por los autores, la motivación puede considerarse como un estado que interactúa con la disponibilidad de recursos. En este caso, la “motivación para comer” (privación de comida) puede ser alta o nula (valores de activación en la capa de entrada del modelo de 1 y 0 respectivamente). Al mismo tiempo el alimento puede estar disponible o no disponible (valor de activación de 1 y 0, respectivamente). Con estos valores, y siguiendo la lógica de modelos como el perceptron, podría simularse la ocurrencia de conducta de alimentación sólo si los valores de activación de ambos nodos en la capa de entrada son iguales a 1. Para Enquist y Ghirlanda, el reforzamiento es parte integral de los modelos de redes con aprendizaje supervisado pero, de acuerdo con los autores, únicamente cuando el valor de activación de la capa de salida se compara con un nivel de umbral que permita determinar si ocurrió o no una “respuesta”. El ajuste de los pesos, en este caso, podría verse como análogo al efecto del reforzamiento. Aunque este modelo es uno de los más simples descritos por Enquist y Ghirlanda, es útil para mostrar cómo pueden integrarse conceptos importantes para el análisis de la conducta en los modelos de redes neuronales. En este ejemplo en particular sería importante determinar cómo podría sustituirse el concepto de motivación, entendida como estado, por el concepto de operación motivacional, de establecimiento o de abolición, y modular los efectos del reforzamiento y el castigo (e.g., Michael, 2004).

Las redes neuronales pueden ofrecer una aproximación para simular algunos fenómenos conductuales pero no son la única opción. En el área conocida como aprendizaje por reforzamiento dentro del campo del aprendizaje de máquinas, se ha usado el principio de reforzamiento para entrenar diferentes funciones en modelos por computadora. En algunas aplicaciones aisladas del uso de aprendizaje por reforzamiento, algunos investigadores han usado algunos principios del condicionamiento operante en el diseño de modelos usados en robótica. Por ejemplo, Touretzky y Saksida (1997) integraron el fenómeno de la formación de cadenas conductuales para moldear nuevas respuestas en robots llamados *Skinnerbots*. Hutchison (2012) ha desarrollado algunos algoritmos que permiten el establecimiento de nuevas conductas en robots que no fueron entrenadas directamente (véase también Maki & Abunawass, 1991).

Es notable que en el campo del aprendizaje por reforzamiento los autores se refieren al efecto de las consecuencias como recompensas positivas y recompensas negativas (e.g., Sutton & Barto, 1988) en lugar de los conceptos del análisis de la conducta de reforzamiento positivo y castigo positivo. Desde luego que la distinción entre contingencias positivas y negativas no es siquiera considerada. Esto ejemplifica el poco contacto que tiene el análisis de la conducta con el campo del aprendizaje por reforzamiento. Aunque es probable que los analistas de la conducta puedan hacer contribuciones importantes al desarrollo de las redes neuronales y el aprendizaje por reforzamiento, este tipo de interacción entre los dos campos es limitada. Por ejemplo, uno de los problemas centrales en este campo es la asignación de crédito que se refiere a que es difícil determinar cuál y cómo una respuesta se asocia con una consecuencia que puede estar demorada. En el campo del aprendizaje por reforzamiento se han

usado modelos de decisión Markovianos para solucionar este problema (Sutton & Barto). Una solución aparentemente más simple fue la propuesta por Touretzky y Saksida (1997) que consiste en integrar el concepto del encadenamiento y que, de hecho, está basada en hallazgos en análisis de la conducta.

A pesar de que el concepto de red neuronal tiene más de 70 años, su aplicación en psicología y, particularmente, en el análisis de la conducta sigue siendo escasa. Este año se habrán cumplido 21 años de la publicación del modelo de Donahoe et al. (1993) que prometía la expansión del desarrollo de modelos de redes neuronales en el análisis de la conducta. En el año 2000 un número especial dedicado a los avances en el tema de las redes neuronales en análisis de la conducta fue publicado en la *Revista Mexicana de Análisis de la Conducta*. En dicho número los trabajos de Burgos (2000) y de Potter y Wilson (2000) describieron algunos modelos desarrollados en el análisis de la conducta y en el campo del aprendizaje asociativo basados en redes neuronales. A pesar de que, como Potter y Wilson notaron, los avances en las computadoras parecían favorecer el desarrollo de nuevos modelos de redes neuronales, éstos no han generado las contribuciones esperadas. Una explicación es que aunque existen numerosos manuales sobre el funcionamiento de las redes neuronales, éstos están dirigidos a especialistas en programación o en ingeniería y no a especialistas en comportamiento. Se espera que esta introducción a las redes neuronales más comunes que usan funciones de activación sigmoidales y reglas de aprendizaje de retro propagación sirva para estimular la aplicación de las redes a diferentes problemas en análisis de la conducta y en psicología en general. Por ejemplo, además de la simulación de procesos conductuales, otra posible aplicación de las redes neuronales puede ser el diseñar procedimientos para moldear conducta de un manera similar a como Platt (1973) y Galbicka (1994) han descrito la aplicación de programas de percentiles. Las redes neuronales bien podrían usarse para reconocer la respuesta a reforzar y hacer más restrictivo el criterio en las iteraciones siguientes.

Los modelos de redes neuronales pueden clasificarse dentro de lo que Skinner (1974) describió como el análisis de lo que ocurre dentro del organismo y que puede ayudarnos a “llenar los espacios” en las relaciones funcionales entre el ambiente y la conducta. De acuerdo con Skinner, los descubrimientos en fisiología no invalidan las leyes de la ciencia de la conducta sino que eventualmente nos permitirán tener una descripción más completa de la conducta. Aunque aún queda por resolverse el problema de si los modelos de redes neuronales realmente simulan la actividad del sistema nervioso o si son descripciones puramente conceptuales, la noción de los modelos conexionistas puede ayudar a entender fenómenos que tradicionalmente se estudian en la psicología cognoscitiva (Donahoe & Palmer, 1994). El ejemplo más directo es el caso de la “memoria” que conforme a los modelos de redes puede entenderse únicamente como el resultado del funcionamiento completo de la red, lo cual es incongruente con la metáfora del almacenamiento y la recuperación de la información que ha dominado en la psicología cognoscitiva. Es notable que Skinner (1974; véase también Epstein, 1984) ya había descrito que la metáfora del almacenamiento y la recuperación podría reemplazarse con la noción de que los organismos son cambiados por las contingencias. Epstein hizo claro este argumento en la siguiente descripción:

Un estudiante expuesto a una fotografía en un experimento de imaginación el lunes, se comportará de manera diferente a fotografías similares el martes. ¿Cómo podemos explicar tal cambio sin apelar a las metáforas de la representación y el almacenamiento? ... Digamos que cuando una neurona (o grupo de neuronas...) en el cerebro de una rata (o de un estudiante) está en un cierto estado –llamémoslo estado activo-, la rata tiende a flexionar la pata cuando se expone a una luz roja. Digamos también que el estado de la célula es normalmente inactivo pero lo cambiamos a activo al parear la luz roja con la aplicación de un choque eléctrico en la pata de la rata... con esta operación hemos cambiado a la rata de tal forma que en el futuro cuando se exponga a una luz roja, flexionará la pata. Nótese que cuando la rata cambia no contiene una regla acerca de la nueva relación... las células activas [neuronas o grupos de neuronas] no son análogos a una instrucción

en una computadora; en el mejor de los casos, podrían realizar una función similar una marca en la memoria de la computadora (p. 52-53, traducción del autor).

El funcionamiento de las redes neuronales ofrece apoyo a la noción de Skinner (1974) y de Epstein (1984) y provee un modelo que podría ser útil para integrar la conceptualización de los procesos cognoscitivos en análisis de la conducta con hallazgos en las neurociencias. La integración de los principios del análisis de la conducta con disciplinas como el aprendizaje de máquinas y con las neurociencias cognoscitivas podría no sólo ayudar a aumentar la visibilidad y las contribuciones del análisis de la conducta sino que, como sugirió Skinner, podría incluso ayudarnos a hacer más completa la descripción de la conducta.

Referencias

- Anderson, J. A. (1988). General Introduction (pp. xiii-xxi). En J. A. Anderson and E. Rosenfeld (Eds.). *Neurocomputing, Foundations of Research*. Cambridge, MA: MIT Press.
- Burgos, J. E. (2000). Superstition in artificial neural networks: A case study for selectionists approaches to reinforcement. *Revista Mexicana de Análisis de la Conducta*, 26, 159-190.
- Burgos, J. E. (2001). A neural-network interpretation of selection in learning and behavior. *Behavioral and Brain Sciences*, 24, 531-532.
- Burgos, J. E. (2002). Herencia genética, sistema nervioso y conducta. En E. Ribes (Ed.), *Psicología del Aprendizaje* (pp. 43-78). México: Manual Moderno
- Caudill, M., & Butler, B. (1992). *Understanding neural networks*. Cambridge, MA: MIT Press.
- Donahoe, J. W., Burgos, J. E., & Palmer, D. C. (1993). A selectionist approach to reinforcement. *Journal of the Experimental Analysis of Behavior*, 60, 17-40.
- Donahoe, J. W., & Palmer, D. C. (1994). *Learning and complex behavior*: Boston, MA: Allyn & Bacon.
- Enquist, M., & Ghirlanda, S. *Neural networks and animal behavior*. Princeton, NJ: Princeton University Press.
- Epstein, R. (1984). Simulation research in the analysis of behavior. *Behaviorism*, 12, 41-59.
- Epstein, R. (1999). Generativity theory. En M. Runco (Ed.). *Encyclopedia of creativity* (pp.759-766). New York: Academic Press.
- Galbicka G. (1994). Shaping in the 21st century: Moving percentile schedules into applied settings. *Journal of Applied Behavior Analysis*, 27, 739-760.
- Gazzaniga, M. S. (2008). *Human: The science behind what makes us unique*. New York: Harper Collins.
- Heaton, J. (2011). *Introduction to the math of neural networks*. Chesterfield MO: Heaton Research.
- Hebb, D. O. (1949). *The organization of behavior*. New York: Wiley.
- Hinton, G. E., J. L. McClelland, and D. E. Rumelhart. (1986). Distributed representations. En D. E. Rumelhart and J. L. McClelland (Eds.). *Parallel Distributed Processing: Explorations in the Microstructure of Cognition* (pp. 77-109). Cambridge, MA: MIT Press,

- Hoebel, B. G. (1988). Neuroscience and motivation: Pathways and peptides that define motivational systems. En R. C. Atkinson, R. J. Herrnstein, G. Lindzey, & R. D. Luce (Eds.). *Stevens' handbook of experimental psychology: Vol. 1. Perception and motivation* (pp. 547-625). New York: Wiley.
- Hutchison, W. R. (1984, December). Cognitive vs. behavioral approaches to artificial intelligence. *Newsletter for the Behavioral Artificial Intelligence Network, 1*, 5-20.
- Hutchison, W. R. (2012). The Central Role for Behavior Analysis in Modern Robotics, and Vice Versa. *The Behavior Analyst, 35*, 29–35.
- Hutchison, W. R., & Stephens, K. R. (1992). Behavioral Personal Digital Assistants: The Seventh Generation of Computing. *The Behavior Analyst, 10*, 149-156.
- Kehoe, E. J. (1989). Connectionist models of conditioning: A tutorial. *Journal of the Experimental Analysis of Behavior, 52*, 427-440.
- Kelley, T. D. (2003). Symbolic and sub-symbolic representations in computational models of human cognition: What can be learned from biology? *Theory & Psychology, 13*, 847–860
- Kosslyn, S. M. (1980). *Image and Mind*. Cambridge, MA: Harvard University Press.
- Lewis, R. L. (1999). Cognitive modeling, symbolic. En Wilson, R. and Keil, F. (Eds.). *The MIT Encyclopedia of the Cognitive Sciences*. Cambridge, MA: MIT Press.
- Maki, W. S., & Abunawass, A. M. (1991). A connectionist approach to conditional discriminations: Learning, short-term memory, and attention. En M. L. Commons, S. Grossberg, J. E. R. and Staddon. (Eds.). *Neural Network Models of Conditioning and Action* (pp. 241-278). Hillsdale, NJ: Lawrence Erlbaum Associates.
- McCulloch, W. S., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics, 5*, 115–133.
- Michael, J. L. (2004). *Concepts and principles of behavior analysis*. Kalamazoo: MI: Association for Behavior Analysis International.
- Minsky, M. L., & Papert, S. (1969). *Perceptrons: An introduction to computational geometry*. Cambridge, MA: MIT Press.
- Mitchell, T. M. (1997). *Machine Learning*. New York: McGraw Hill.
- Olson, M. H., & Hergenhahn, B. R. (2009). *An introduction to theories of learning* (8a Ed.). Upper Saddle River, NJ: Pearson.
- Paivio, A. (1979). *Imagery and Verbal Processes*. Hillsdale, NJ: Lawrence Erlbaum Associates.
- Palmer, D. C., & Donahoe, J. W. (1992). Essentialism and selection in cognitive science and behavior analysis. *American Psychologist, 47*, 1344-1358.
- Pinker, S. (1997). *How the mind works*. New York, NY: Norton & company.
- Potter, B., & Wilson, M. (2000). Behavior analysis and artificial neural networks. *Revista Mexicana de Análisis de la Conducta, 26*, 141-158.

- Platt, J. R. (1973). Percentile reinforcement: Paradigms for experimental analysis of response shaping. En: G. H. Bower. (Editor). *The psychology of learning and motivation: Vol. 7. Advances in theory and research* (pp. 271-296). New York: Academic Press.
- Putnam, H. (1961, December). Brains and behavior. Trabajo presentado en la American Association for the Advancement of Science. Reimpreso en N. Block (Ed.). (1980). *Readings in philosophy of psychology* (pp. 24-36). Cambridge, MA: Harvard University Press.
- Pylyshyn, Z. W. (1973). What the Mind's Eye Tells the Mind's Brain: A Critique of Mental Imagery. *Psychological Bulletin*, 80, 1–25.
- Rescorla, R. A. & Wagner, A. R. (1972). A theory of Pavlovian conditioning: Variations in the effectiveness of reinforcement and nonreinforcement. En A. H. Black & W. F. Prokasy (Eds.), *Classical conditioning II: Current research and theory* (pp. 64-99). New York: Appleton-Century-Crofts.
- Rosenblatt, F. (1958). The perceptron: A probabilistic method for information storage and organization in the brain. *Psychological Review*, 65, 386–408.
- Rumelhart, D. E., & McClelland, J. L. (1986). *Parallel distributed processing: Explorations in the microstructure of cognition: Vol. 1. Foundations*. Cambridge, MA: MIT Press.
- Rumelhart, D. E., Hinton, G. E., & Williams, R.J. (1986). Learning internal representations by error propagation. En D. E. Rumelhart, J. L. McClelland and The PDP Research Group, *Parallel distributed processing: Explorations in the microstructure of cognition. Volume1: Foundations* (pp. 318–362). Cambridge, MA: MIT Press.
- Skinner, B. F. (1950). Are theories of learning necessary? *Psychological Review*, 57, 193–216.
- Skinner, B. F. (1974). *About behaviorism*. New York: Knopf.
- Skinner, B. F. (1977). Why I am not a cognitive psychologist. *Behaviorism*, 5, 1–10.
- Skinner, B. F. (1988). Responses to commentaries. En A. C. Catania & S. Harnad (Eds.), *The Selection of Behavior: The Operant Behaviorism of B. F. Skinner*. New York: Cambridge University Press.
- Spratling, M. W., & Johnson, M. H. (2004) .Neural Coding Strategies and Mechanisms of Competition. *Cognitive Systems Research*, 5, 93–117.
- Sutton, R. S., & Barto, A. G. (1981). Toward a modern theory of adaptive networks: Expectation and prediction. *Psychological Review*, 88, 135-171.
- Sutton, R. S., & Barto, A. G. (1988). *Reinforcement Learning: An Introduction*. Cambridge, MA: MIT Press.
- Touretzky, D.S., & Saksida, L. M. (1997) Operant conditioning in Skinnerbots. *Adaptive Behavior* 5, 219-247.
- Turing, A. (1936). On Computable Numbers, with an Application to the Entscheidungsproblem. *Proceedings of the London Mathematical Society* 42, 230-265.
- Wegner, D. (2005). Who is the controller of controlled processes? En R.R. Hassin, J. S Uleman, J A. Bargh (Eds.). *The new unconscious* (pp. 19-36). New York: Oxford University Press.

Widrow, B., & Hoff, M. E. (1960). Adaptive switching circuits. *1960 IRE WESCON Convention Record, New York IRE*, 4, pp. 96–104.