

ISBN: 970-27-0770-6

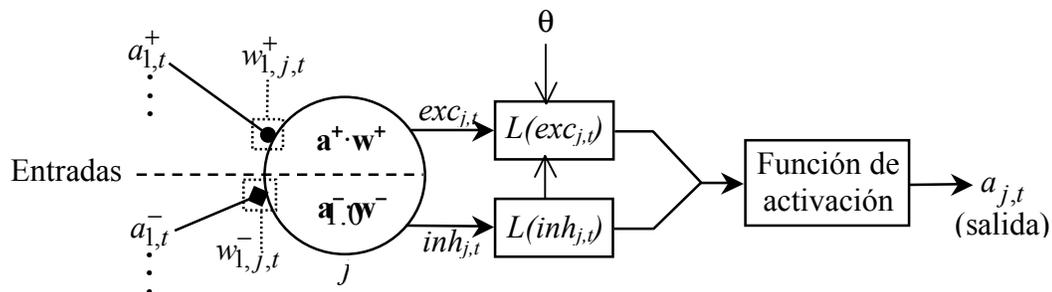
## CONDICIONAMIENTO DE SEGUNDO ORDEN EN REDES NEURALES ARTIFICIALES

**Antonio Ponce Rojo\***  
 Centro Universitario de la Costa  
 aponce@pv.udg.mx

**José Enrique Burgos Triano**  
 Centro de Estudios e Investigaciones en Comportamiento

El condicionamiento de segundo orden es un fenómeno de condicionamiento pavloviano, en el cual un estímulo previamente condicionado EC1 adquiere la capacidad de funcionar como reforzador secundario de un estímulo condicionado nuevo EC2. El procedimiento básico consiste de dos fases. En una primera fase, EC1 se aparea con el estímulo incondicionado (EI), hasta que se obtiene una respuesta condicionada estable. En una segunda fase, un nuevo estímulo condicionado EC2 se aparea con EC1. El resultado es EC2 adquiere la capacidad de producir la respuesta. El objetivo de este trabajo es demostrar que este fenómeno puede ser simulado (y por tanto explicado) mediante el modelo neurocomputacional propuesto inicialmente por Donahoe, Burgos y Palmer (1993).

El modelo describe el elemento procesador neural (EPN), una especie de neurona abstracta que funge de unidad estructural y funcional básica de una red neural artificial. La siguiente figura muestra un EPN genérico. El EPN incluye sensores que pueden detectar señales ( $a_{i,t}$ ) del medio ambiente local del EPN (sea externo o interno, el último constituido



por señales de otros EPNs) en un momento  $t$ . Cada sensor está conectado a la unidad  $j$  con una cierta fuerza representada numéricamente por un peso ( $w_{i,j,t}$ ). Un EPN puede recibir hasta dos tipos diferentes de sensores: excitatorios e inhibitorios. Para todo momento  $t$ , la unidad  $j$  calcula el producto interno entre el vector de señales de entrada y el vector de pesos separadamente para cada tipo de sensor. Estos productos son entonces pasados por funciones logísticas ( $L$ ), sobre las cuales se calcula la activación del elemento según la siguiente función:

$$a_{j,t} = \begin{cases} L(exc_{j,t}) + \tau_j L(exc_{j,t-1})[1 - L(exc_{j,t})] - L(inh_{j,t}) & \text{si } L(exc_{j,t}) > L(inh_{j,t}) \text{ and } L(exc_{j,t}) \geq \theta_j \\ a_{j,t-1} - \kappa a_{j,t-1}(1 - a_{j,t-1}) - L(inh_{j,t}) & \text{si } L(exc_{j,t}) > L(inh_{j,t}) \text{ and } L(exc_{j,t}) < \theta_j \\ 0 & \text{si } L(exc_{j,t}) \leq L(inh_{j,t}) \end{cases}$$

donde

$$L(x) = \frac{1}{1 + e^{\frac{-(x-\mu)}{\sigma}}}; \quad x = \sum_{i=1}^s a_{i,t} w_{i,j,t}$$

$\theta$  es un número aleatorio según una función gaussiana con media de 0.2 y desviación de 0.15,  $s$  es el número total de entradas de cierto tipo (excitatorias o inhibitorias) conectadas a  $j$ ,  $\tau$  es un parámetro de sumación temporal (el cual se fijó en 0.1),  $\kappa$  es un parámetro de decaimiento temporal (el cual se fijó en 0.2),  $\mu$  y  $\sigma$  son respectivamente la media y desviación de la distribución logística (las cuales se fijaron en 0.5 y 0.1, respectivamente). Toda activación oscila entre 0.0 y 1.0.

En este tipo de modelo, el aprendizaje se define como cambio en uno o más pesos. En el presente modelo, dicho cambio viene dado por la siguiente función:

$$\Delta w_{i,j,t} = \begin{cases} \alpha_j a_{j,t} d_t p_{i,t} r_{j,t} & \text{si } d_t \geq 0.001 \\ -\beta_j w_{i,j,t-1} a_{i,t} a_{j,t} & \text{si } d_t < 0.001 \end{cases}$$

donde

$d_t = d_{s,t} = \phi_t + \nu_t(1 - \nu_t)$ , si  $j$  es un EPN *sa* o *cal* (ver modelo de red), o

$d_t = d_{m,t} = \nu_t$ , si  $j$  es un EPN *ma*, salida, o *vta*

$\phi_t = |\text{Media}(\mathbf{h}_t - \mathbf{h}_{t-1})|$ ;  $\nu_t = \text{Media}(\mathbf{v}_t - \mathbf{v}_{t-1})$

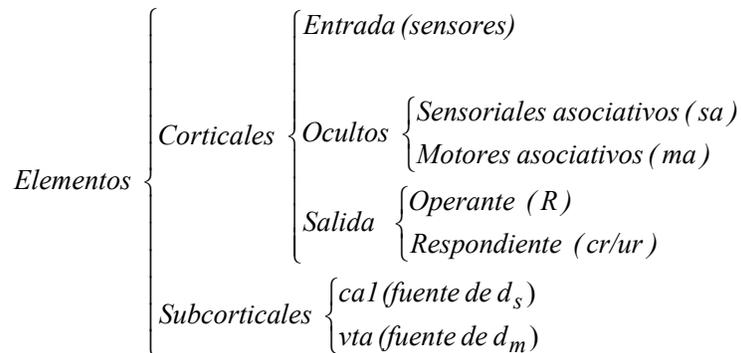
$$p_{i,t} = \frac{a_{i,t} w_{i,j,t-1}}{N}, \quad r_{j,t} = 1 - \sum_{i=1}^s w_{i,j,t}$$

$N = exc_{j,t}$  o  $N = inh_{j,t}$

$\alpha = 0.5$ ,  $\beta = 0.05$

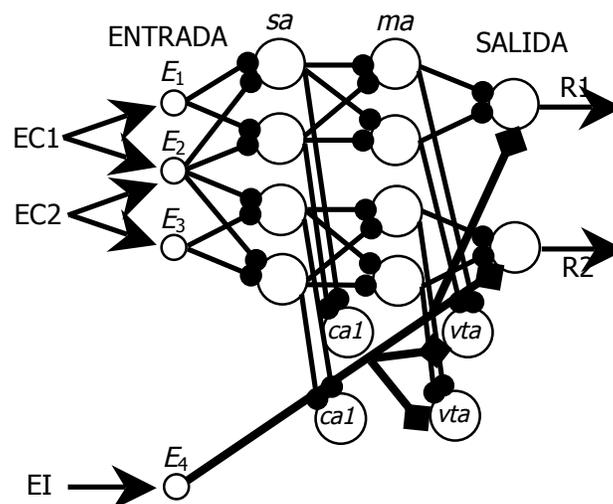
Todo peso oscila entre 0.0 y 1.0. Los factores  $p$  y  $r$  muestran que esta función es competitiva. Ello significa que hay una cantidad limitada de peso disponible (1.0) que pueden ganar las conexiones que coinciden en un mismo EPN. Esta cantidad se reduce a medida que las conexiones van ganando peso.

Una red neural es un sistema de EPNs conectados de cierta manera. La siguiente tabla muestra los distintos tipos de elementos que pueden constituir una red neural en el presente modelo:



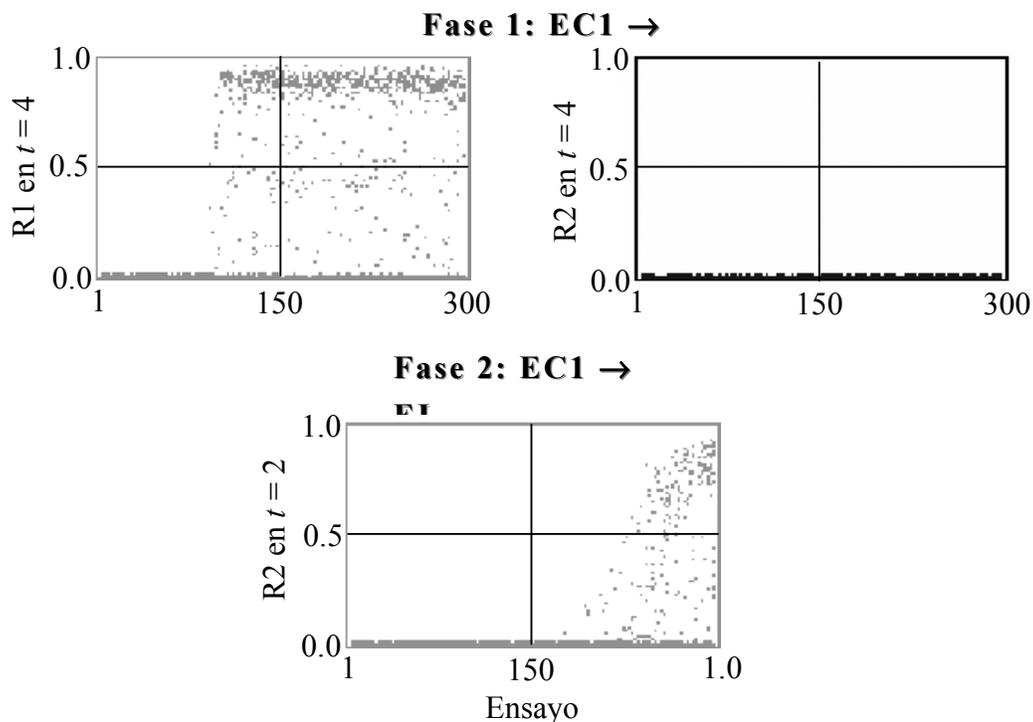
Estrictamente, los elementos de entrada no son EPNs, ya que sus activaciones no son calculadas según la regla de activación. Tales activaciones son asignadas manualmente y representan la ocurrencia de estímulos en el medio ambiente de la red. Las activaciones de algunos elementos de entrada representan la ocurrencia de estímulos sensoriales como luces o tonos, comúnmente utilizados como estímulos condicionados (ECs) en investigación en condicionamiento pavloviano. La ocurrencia de estímulos como comida, agua, choques eléctricos, comúnmente utilizados como estímulos incondicionados (EIs), se representa por la activación de un elemento especialmente destinado para tal función.

En la simulación, una red experimentalmente ingenua (i.e., con pesos iniciales de 0.01) con la siguiente arquitectura:



fue expuesta al siguiente procedimiento. En la Fase 1 se presentaron 300 ensayos de EC1 apareado con el EI (EC1+). EC1 fue definido como  $a(E_1) = 1.0$  y  $a(E_2) = 0.25$  por cinco momentos temporales, mientras que EI fue definido como  $a(E_4) = 1.0$  en el quinto momento de EC1. En la Fase 2, se presentaron 300 ensayos de EC1+ aleatoriamente entremezclados con 300 ensayos de apareamiento de un nuevo estímulo condicionado EC2 con EC1. EC2 se definió como  $a(E_2) = 0.25$  y  $a(E_3) = 1.0$  por cinco momentos temporales. EC1 y EC2, entonces, fueron patrones no ortogonales de entrada, lo cual simula una semejanza entre ellos. Esta semejanza puede interpretarse como la presencia de un contexto tónico que es común a dos estímulos fásicos. En esta fase, EC1 coincidió con los tres últimos momentos temporales de EC2.

La siguiente figura muestra los resultados tal y como son presentados por el simulador.



El efecto crítico se observa en el panel inferior, el cual muestra la activación de R2 en el momento inmediatamente anterior al inicio de EC1 en la Fase 2. Debido a la arquitectura de la red, esta activación puede ser sustancial sólo en presencia del EC2. Un incremento en esta activación, pues, indica el efecto condicionado de EC2.

Estos resultados son consistentes con lo que se ha observado en organismos naturales. Ello muestra que el modelo es capaz de simular el fenómeno básico de condicionamiento de segundo orden. Bajo el modelo, este fenómeno se explica de la siguiente manera. El entrenamiento en la Fase 1 causa un incremento de los pesos de las conexiones  $E_1$ -sa más significativo que el de los pesos de las conexiones  $E_2$ -sa, ya que la activación de  $E_2$  fue sustancialmente menor (0.25) que la de  $E_1$  (1.0). Las activaciones altas de R1, entonces, se debieron principalmente a las activaciones de  $E_1$ .

Las bajas activaciones de R2 en la Fase 1 se debieron a una interacción entre la baja activación de  $E_2$  y la arquitectura de la red. Aunque la activación de R2 también depende de la de  $E_2$ , esta activación por sí sola fue muy baja como para poder activar R2 sustancialmente. Además, durante esta fase, las conexiones  $E_3$ -sa no ganaron peso, ya que  $E_3$  no fue activada. Todo ello permitió que EC1 produjera una señal de discrepancia lo suficientemente alta como para que, al ser apareado con EC2 en la Fase 2, los pesos de las conexiones  $E_3$ -sa se incrementaran de manera sustancial, obteniéndose así activaciones sustanciales de R2 en presencia de EC2.

### Referencia

Donahoe, J. W., Burgos, J. E., & Palmer, D. C. (1993). A selectionist approach to reinforcement. *Journal of Experimental Analysis of Behavior*, 60, 17-40.