

ISBN: 970-27-0770-6

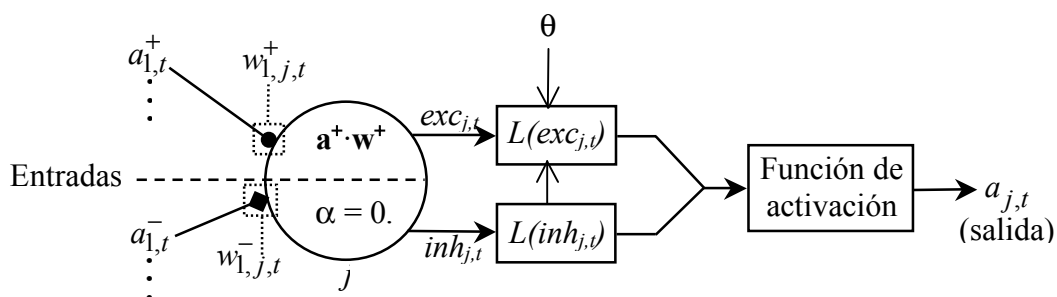
CAMBIAR EL CONTEXTO REDUCE LA RESPUESTA CONDICIONADA EN REDES NEURALES ARTIFICIALES

Esther Murillo Rodríguez*
José Enrique Burgos Triano

Departamento de Ciencias Ambientales
Centro de Estudios e Investigaciones en Comportamiento

El condicionamiento contextual es un fenómeno de aprendizaje que ha recibido considerable atención desde que fue estudiado por primera vez por Gabriel (1972). La evidencia experimental muestra que el contexto en el cual ocurre el aprendizaje modula su forma y velocidad. Por ejemplo, cuando un estímulo condicionado (EC) es apareado con un estímulo incondicionado (EI) en un cierto contexto (CTXa) y probado en otro contexto (CTXb), la respuesta condicionada (RC) es más débil en CTXb que en CTXa (e.g., Durlach, 1984). El objetivo de este trabajo es demostrar que este fenómeno puede ser simulado (y en esa medida explicado) mediante el modelo neurocomputacional propuesto originalmente 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

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

θ 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 , τ es un parámetro de sumación temporal (el cual se fijó en 0.1), κ es un parámetro de decaimiento temporal (el cual se fijó en 0.2), μ y σ 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:

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

$d_t = d_{s,t} = \phi_t + \nu_t(1 - \nu_t)$, 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*

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

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

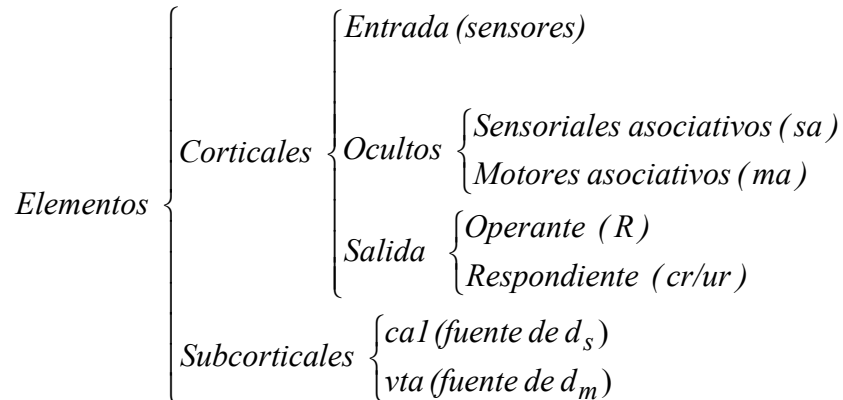
$N = exc_{j,t}$ o $N = inh_{j,t}$

donde

$\alpha = 0.5, \beta = 0.05$


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, dos redes experimentalmente ingenuas (i.e., con pesos iniciales de 0.01) con la siguiente arquitectura:



fueron expuestas el siguiente procedimiento. En la Fase 1 (entrenamiento), se presentaron 150 ciclos de 15 momentos temporales cada uno. El contexto de entrenamiento (CTXa) se definió como $a(I_1) = 1.0$ y $a(I_2) = 0.0$ en todo el ciclo. El EC se definió como $a(I_3) = 1.0$ en los momentos 10 a 15. El EI se definió como $a(I_4) = 1.0$ en el momento 15. En la Fase 2 (prueba), se presentaron 25 ciclos en los que la función de aprendizaje fue deshabilitada y el EC fue presentado en un contexto diferente (CTXb), el cual se definió como $a(I_1) = 0.0$ y $a(I_2) = 1.0$. La siguiente figura muestra los resultados individuales de cada red neuronal (N1 y N2) para cada fase del experimento (“+” significa “apareado con el EI”, “-” significa “no apareado con el EI”, “s/a” significa “función de activación deshabilitada”).



Estos resultados son consistentes con lo que se ha observado en organismos naturales. Ello muestra que el modelo es capaz de simular el decremento de la respuesta condicionada causado por un cambio del contexto. Bajo el modelo, este resultado se explica de la siguiente manera. El entrenamiento en la Fase 1 causó un incremento en los pesos tanto de las conexiones I_1 - sa como de las conexiones I_3 - sa . Este incremento resultó en activaciones de salida altas en presencia del estímulo compuesto CTXa|EC. Durante el entrenamiento, las conexiones I_2 - sa no ganaron peso puesto que I_2 no fue activada. Ello hizo que las activaciones de salida fueran sustancialmente menores en presencia del nuevo compuesto CTXb|EC en la Fase 2.

Referencias

- Gabriel, M. (1972). Incubation of avoidance produced by generalization to stimuli of the conditioning apparatus. En R. Thompson & A. Voss (Eds.), *Topics in learning and performance*. New York: Academic.
- Donahoe, J. W., Burgos, J. E., & Palmer, D. C. (1993). A selectionist approach to reinforcement. *Journal of Experimental Analysis of Behavior*, 60, 17-40.
- Durlach, P. (1984). Pavlovian learning and performance when CS and US are uncorrelated. In M. Commons, R. Herrnstein, & A. R. Wagner (Eds.), *Quantitative Analyses of Behavior: Volume 3: Acquisition*. Cambridge, MA: Ballinger.