



Una breve introducción a las Teorías de Redes Neuronales: 2






Juan Valle Lisboa,
Sección Biofísica, 2022.

Las memorias asociativas




Tipos de excitabilidad (Hodgkin, 1948)

Morris-Lecar






Class 1 Neural Excitability

Hodgkin-Huxley



Class 2 Neural Excitability


Sinapsis química



Resumen


- Las neuronas son células excitables, que cuando reciben un estímulo suficiente su potencial cambia y “disparan un potencial de acción”.
- A mayor estímulo en un mismo tiempo mayor número de potenciales de acción.
- Los potenciales de acción viajan sin decremento hasta el botón sináptico.
- El estímulo que una neurona genera en otra depende de las propiedades sinápticas.
- De acuerdo a como se integren los estímulos la siguiente neurona va a disparar o no.

Karl Lashley buscando el engrama



Text-fig. 8. The relation of errors in maze learning to extent of cerebral damage in the rat. The extent of brain injury is expressed as the percentage of the surface area of the isocortex destroyed. Data from 60 normal and 127 brain-operated animals are averaged by class intervals of 5% destruction. The curve is the best fitting one of logarithmic form. For lesions above 45% the number of cases (indicated by numerals on the graph) is too small for reliability. (After Lashley & Wiley, 1933.)


Hebb y la revitalización de la hipótesis sináptica






“Cuando un axón de una célula A está lo suficientemente cerca de una célula B, como para excitarla, y participa repetida o persistentemente en su disparo, ocurre algún proceso de crecimiento o cambio metabólico, en una o en ambas células, de modo tal que la eficacia de A, como una de las células que hacen disparar a B, aumenta”.

Eric Kandel (premio Nobel 2000)

- Many years later, Chip Quinn, one of the first scientists to conduct genetic studies of learning in the fruit fly, noted that the ideal experimental animal for biological studies of learning must have “no more than three genes, be able to play the cello or at least recite classical Greek, and learn these tasks with a nervous system containing only ten large, differently colored and therefore easily recognizable neurons.” Tomado de Kandel, 2006, in Search of Memory.)




Experimentos clásicos sobre LTP/LTD



(A) Specificity

Pathway 1:
Active




Synapse strengthened

Pathway 2:
Inactive




Synapse not strengthened




(B) Associativity

Pathway 1:
Strong stimulation




Synapse strengthened

Pathway 2:
Weak stimulation



Synapse strengthened



Resumen


La memoria y el aprendizaje no parecen depender de un sitio específico en el cerebro.

Si bien eso se relativizó, la idea es que la memoria se almacena en forma distribuida.

La forma en que se podría lograr ese aprendizaje es a través de las sinapsis “Hebbianas”.



En aplysia (Kandel) o en ratas (Bliss & Luomo) se observan cambios en la fuerza sináptica que se vinculan al aprendizaje.

Neuronas Analógicas: un modelo simple



$$g \equiv s_i - \bar{s}_i$$

$$f \equiv \vec{u} - \vec{u}_0$$




- La frecuencia de disparo es en cierto rango aproximable por una función lineal.
- Si asumimos que existe una frecuencia basal la actividad frente a un estímulo es la diferencia entre la frecuencia de disparo y la basal.

Un modelo de neurona simplificado

En ecuaciones:


$$g_i = \phi \left(\sum_j m_{ij} f_j \right)$$



Lo más simple es suponer que la función ϕ es la identidad.

Por motivos algebraicos es útil poner cada una de las señales en un vector.

Las redes



Esta red, puede aprender a asociar un conjunto de entradas con un conjunto de salidas utilizando la regla de cambiar los pesos en proporción a la entrada y la salida deseada (c.f. Donald Hebb)

Esto es lo mismo que hacer una matriz que sea la suma de los productos externos.

Si los vectores de entrada son todos perpendiculares entre si (son ortogonales decimos $f(k) \cdot f(l) = 0$) entonces esa memoria es perfecta.

Interludio matemático

$$\mathbf{f} = \begin{bmatrix} f_1 \\ f_2 \\ \vdots \\ f_i \\ \vdots \\ f_n \end{bmatrix} \quad \mathbf{g} = \begin{bmatrix} g_1 \\ g_2 \\ \vdots \\ g_j \\ \vdots \\ g_m \end{bmatrix} \quad \mathbf{M} = \begin{bmatrix} m_{11} & m_{12} & \cdots & m_{1i} & \cdots & m_{1n} \\ m_{21} & m_{22} & \cdots & m_{2i} & \cdots & m_{2n} \\ \vdots & \vdots & \ddots & \vdots & \ddots & \vdots \\ m_{m1} & m_{m2} & \cdots & m_{mi} & \cdots & m_{mn} \end{bmatrix}$$


\mathbf{g} = vector de salida

$$\mathbf{g} = \mathbf{M}\mathbf{f}$$


\mathbf{M} = matriz de pesos sinápticos

\mathbf{f} = vector de entradas

B : p rows q columns



Producto interno y externo



Producto Escalar

$$\vec{a} \cdot \vec{b} = \|\vec{a}\| \cdot \|\vec{b}\| \cdot \cos\alpha$$

$$\begin{bmatrix} a & b \end{bmatrix} \cdot \begin{bmatrix} x \\ y \end{bmatrix} = a.x + b.y$$


$$\begin{bmatrix} a & b & c \end{bmatrix} \cdot \begin{bmatrix} x \\ y \\ z \end{bmatrix} = a.x + b.y + c.z$$

$$\begin{bmatrix} a & b & c & d \end{bmatrix} \cdot \begin{bmatrix} x \\ y \\ z \\ t \end{bmatrix} = a.x + b.y + c.z + d.t$$


Producto externo

$$T = \begin{pmatrix} a_1 \\ a_2 \\ a_3 \end{pmatrix} (b_1 \quad b_2 \quad b_3) = \begin{pmatrix} a_1 b_1 & a_1 b_2 & a_1 b_3 \\ a_2 b_1 & a_2 b_2 & a_2 b_3 \\ a_3 b_1 & a_3 b_2 & a_3 b_3 \end{pmatrix}.$$


Veamos una red simple




Veamos una red simple: números




Veamos una red simple: números




Veamos una red simple: números



Esta red produce infinitas respuestas




Veamos una red simple: números




Introducción al aprendizaje

Aprendizaje Hebbiano: Si queremos asociar un conjunto de entradas con uno de salidas, presentamos en la entrada cada ejemplo, y modificamos los pesos agregando a cada peso el producto de la entrada por la salida deseada.



Las redes



Cada peso va a ser la suma de las asociaciones correspondientes a todos los pares entrada salida. Si las entradas no están correlacionadas, en una red de N neuronas se pueden almacenar N asociaciones de forma perfecta.

El problema de los pares asociados


$$\mathbf{f}(\mathbf{1}) = \begin{bmatrix} f_1 \\ f_2 \\ \vdots \\ f_j \\ \vdots \\ f_r \end{bmatrix} \quad \mathbf{g}(\mathbf{1}) = \begin{bmatrix} g_1 \\ g_2 \\ \vdots \\ g_i \\ \vdots \\ g_s \end{bmatrix}$$

$\mathbf{f}(\mathbf{1})$ y $\mathbf{g}(\mathbf{1})$ se denominan par asociado, patrón asociado (de pattern), vectores asociados.

El problema del aprendizaje asociativo:

Encontrar los pesos sinápticos que hagan que cada vez que un patrón está presente en la entrada, el asociado correspondiente esté en la salida, para una cierta cantidad de pares asociados $\{\mathbf{f}(k), \mathbf{g}(k)\}$

Ej: Usando esta red.....



Almacenar...


PRIMER PAR				SEGUNDO PAR				TERCER PAR				
f(1)	f ₁ (1)	0.5	g(1)	1	f(2)	0.5	g(2)	-2	f(3)	0.5	g(3)	3,14
	f ₂ (1)	0.5		-0.3		-0.5		0.5		0.5		2.73
	f ₃ (1)	0.5		3		0.5		0.4		-0.5		-1
	f ₄ (1)	0.5				-0.5				-0.5		

Primer par a asociar

Entra:

0.5 0.5 0.5 0.5

Queremos que salga:




Primer par a asociar


Entra:

0.5 0.5 0.5 0.5

Queremos que salga:




Primer par a asociar



Primer par a asociar

Entra:




Primer par a asociar


Entra:

0.5 0.5 0.5 0.5

Queremos que salga:



Primer par a asociar




Segundo par a asociar


Entra:

0.5 ● -0.5 ● 0.5 ● -0.5 ●


Queremos que salga:



Tercer par a asociar



Sumando todo




¿Qué pasa si presentamos la entrada original?

PRIMER PAR				SEGUNDO PAR				TERCER PAR				
f(1)	f ₁ (1)	0.5	g(1)	1	f(2)	0.5	g(2)	-2	f(3)	0.5	g(3)	3,14
	f ₂ (1)	0.5		-0.3		-0.5		0.5		0.5		2.73
	f ₃ (1)	0.5		3		0.5		0.4		-0.5		-1
	f ₄ (1)	0.5				-0.5				-0.5		


Sumando todo




A



B




C



La esencia de estos modelos

Generalización en memorias asociativas

$$dog(dog_1)^T + dog(dog_2)^T + \dots + dog(dog_n)^T = Ndog \overline{dog}^T$$



En las redes neuronales la generalización disponible es de tipo interpolación entre rasgos de los diferentes elementos.

Fin clase 2