



# UNA NEURONA ARTIFICIAL

Ya hablamos un poquito de como funciona una neurona biológica



En 1943 el neurólogo y cibernético norteamericano **Warren McCulloch**, junto al lógico **Walter Pitts** propusieron un modelo muy simple para emular matemáticamente el funcionamiento de una neurona real. Este modelo de neurona se conoce como **McCulloch-Pitts**.

El profico esquemático del modelo neuronal, que permite ensamblarlos para formar una red neuronal artificial



El cuerpo de la neurona artificial  $i$  realiza una suma lineal y ponderada de los estados de las neuronas pre-sinápticas (en este caso 3)

$$h_i = (W_{i1} n_1(t) + W_{i2} n_2(t) + W_{i3} n_3(t))$$

$h_i(t)$  modela el potencial de membrana (entre el interior y el exterior) en el cuerpo de la neurona, el cual surge de la contribución lineal de las neuronas pre-sinápticas.

$n_j(t)$  es el estado de la neurona  $j$

$$n_j(t) = \begin{cases} +1 & \text{si la neurona } j \text{ dispara en tiempo } t \\ 0 & \text{si la neurona } j \text{ no dispara en tiempo } t \end{cases}$$

$w_{ij}$

es la eficiencia sináptica entre la neurona presináptica  $j$  y la post-sináptica  $i$ .

Puede tomar cualquier valor real

$$w_{ij} \begin{cases} > 0 & \text{sinapsis excitadora} \\ = 0 & \text{sinapsis neutra} \\ < 0 & \text{sinapsis inhibitoria} \end{cases}$$

Nos interesa entender como se determina el estado de la neurona post-sináptica  $i$  en el tiempo  $t+1$

$$n_i(t+1) = \Theta(h_i(t) - \theta_i)$$

donde  $\Theta(x)$  es la función Heaviside o escalón

$$\Theta(x) = \begin{cases} 0 & \text{si } x < 0 \\ 1 & \text{si } x \geq 0 \end{cases}$$

Entonces :

$$n_i(t+1) = \Theta (h_i(t) - \mu_i)$$

$$= \Theta \left( \sum_{j=1}^3 w_{ij} n_j(t) - \mu_i \right)$$

$$= \begin{cases} 0 & \text{si } \sum_{j=1}^3 w_{ij} n_j(t) < 0 \\ 1 & \text{si } \sum_{j=1}^3 w_{ij} n_j(t) \geq 0 \end{cases}$$

Entonces, nuestra neurona artificial de McCulloch-Pitts calcula la diferencia de potencial en el tiempo  $t$  en el cuerpo celular,  $h_i(t)$ , y lo compara con

$\mu_i$  : umbral de activación de la neurona  $i$

Si la diferencia de potencial sobrepasa el umbral de activación, la neurona  $i$  estará en el estado  $+1$ , o sea, disparará.

$$h_i(t) \geq \mu_i \implies n_i(t+1) = +1.$$

Si la diferencia de potencial **no** sobrepasa el umbral de activación, la neurona  $i$  estará en el estado  $0$ , o sea, dispareará.

$$h_i(t) < \mu_i \implies n_i(t+1) = 0.$$

A lo largo del curso mantendremos la estructura de esta neurona artificial. A lo menos cambiaremos la función  $\Theta$ , o incluso la complejizaremos definiendo varias funciones por cada neurona.

Con esto podemos definir una **RED NEURONAL** como un conjunto de  $N$  neuronas artificiales. En el tiempo  $t$ , la red neuronal está definida por la palabra entera (en términos computacionales)

$$\vec{n}(t) = (n_1(t), n_2(t), n_3(t), \dots, n_N(t))$$

Para la red esté definida además por la matriz de eficiencias sinápticas

$$W = \begin{pmatrix} W_{11} & W_{12} & \dots & W_{1N} \\ W_{21} & W_{22} & \dots & W_{2N} \\ \vdots & \vdots & \ddots & \vdots \\ W_{N1} & W_{N2} & \dots & W_{NN} \end{pmatrix}$$

que nos dice quién se conecta con quién, y con que eficacia y con que carácter (si excitatorio o inhibitorio). Y también se define por un vector de umbrales de activación, uno por neurona:

$$\bar{\mu} = (\mu_1, \mu_2, \mu_3, \dots, \mu_N)$$

En general (salvo casos contados), tendremos que **APRENDER** los elementos de **W** y de  **$\bar{\mu}$** , de forma que asocie correctamente configuraciones iniciales  $\bar{\pi}(0)$  con estados estacionarios  $\lim_{t \rightarrow \infty} \bar{\pi}(t)$ .


Cuando nos referimos a APRENDER, queremos decir que, partiendo de valores aleatorios de  $w$  y  $\mu$  vamos variándolos lentamente


$$w_{ij}^{\text{nuevo}} \rightarrow w_{ij}^{\text{anterior}} + \Delta w_{ij}$$

$$\mu_i^{\text{nuevo}} \rightarrow \mu_i^{\text{anterior}} + \Delta \mu_i$$

hasta alcanzar un conjunto de valores que cumplan con la premisa de asociar correctamente los estados iniciales con los finales.

Una red de neuronas de McCulloch-Pitts "viven" en un hiperespacio de  $N$  bits





$$N = 3$$

Dado que la red tiene  $N$  neuronas de  $Z$  estados, el número total de estados posibles es:

$$Z^N$$

Si tenemos  $N = 4$  hay 16 estados posibles

Mínimo una evolución posible

$$\vec{n}(0) = (1, 0, 0, 1)$$

$$\vec{n}(1) = (0, 0, 0, 1)$$

$$\vec{n}(2) = (1, 0, 1, 1)$$

$$\vec{n}(3) = (1, 0, 1, 1)$$

estado estacionario

Si en dos tiempos sucesivos está en el mismo estado, se quedará para siempre en ese estado, pues el sistema es determinista.

La red asoció el estado inicial

$$\begin{array}{ccc} \text{input} & & \text{output} \\ (1, 0, 0, 1) & \longrightarrow & (1, 0, 1, 1) \end{array}$$