


## APRENDIZAJE SUPERVIZADO


### ARQUITECTURAS FEED-FORWARD

1 capa



Perceptron simple

2 capas




salida

oculta


entrada

Perceptron multi capas

## EL PERCEPTRON SIMPLE



Consideremos una arquitectura feed-forward como la de la figura. Observen que tenemos 3 redes desacopladas con una única salida cada una, pues no comparten ninguna sinapsis. El problema entonces puede desacoplarse. Esto no sucede si la red tiene capas ocultas o si es recurrente.



1 neurona de salida  $O_i$

N entradas

$\xi_k$

$(k=1, 2, \dots, N)$

El conjunto  $\{\xi_1, \xi_2, \dots, \xi_N\}$  puede pensarse como un vector en  $\mathbb{R}^N$

$$\vec{\xi} = (\xi_1, \xi_2, \xi_3, \dots, \xi_N) \in \mathbb{R}^N$$

Las variables  $\xi_k$  pueden tomar valores discretos o continuos (acotados o no).


El rango de valores que puede tomar  $\mathcal{O}_i$  estará dado por la función de activación  $g(x)$

$$\begin{aligned} \mathcal{O}_i &= g(h_i - \mu_i) \\ &= g\left(\sum_{k=1}^N w_{ik} \xi_k - \mu_i\right) \end{aligned}$$

$w_{ik}$  : eficacia sináptica entre entrada  $k$  y neurona  $i$


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

### Perceptron




$$\mathcal{O}_i \in \{0, 1\}$$

### Sigmoid




$$0 < \mathcal{O}_i < 1$$

### Ising




$$\mathcal{O}_i \in \{-1, +1\}$$

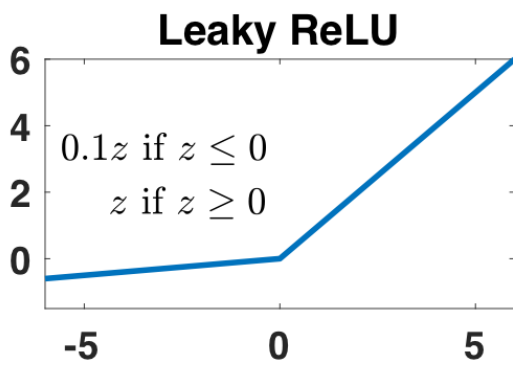
### Tanh



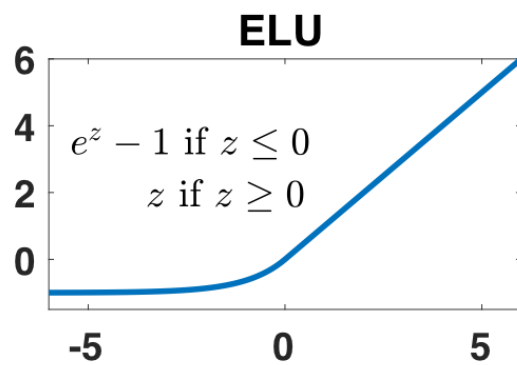
$$-1 < \mathcal{O}_i < +1$$



$$0 \leq \mathcal{O}_i < +\infty$$



$$-\infty < \mathcal{O}_i < +\infty$$



$$-1 < \mathcal{O}_i < +\infty$$

# Aprendizaje supervisado

Supondremos que disponemos de  $p$  entradas de estados

$$\vec{x}^{\mu} = (x_1^{\mu}, x_2^{\mu}, \dots, x_N^{\mu})$$

con  $\mu = 1, 2, 3, \dots, p$ , a los cuales le conocemos la salida correcta, estado  $d_i^{\mu}$ .

$$\vec{x}^{\mu} \longmapsto \sum_i \in \mathbb{R}$$

El desafío consiste en encontrar el conjunto de acoplamientos  $w_{i1}, w_{i2}, \dots, w_{iN}$  que hagan correctamente esta asociación. *también  $f_i$*

Notem que los acoplamientos definen un vector

$$\vec{w}_i = (w_{i1}, w_{i2}, \dots, w_{iN})$$

y que, al igual que  $\vec{x}$ , pertenece a  $\mathbb{R}^N$ .

O sea,  $\vec{x} \in \mathbb{R}^N$  y  $\vec{w}_i \in \mathbb{R}^N$ .

(suponemos  $M$  neuronas de salida  $O_i, i=1,2,\dots,M$ )

Resumiendo, tenemos muchas cosas ya definidas:

$\vec{x}$  : vector de entrada ( $N$  componentes)

$\vec{x}^M$  :  $p$  entradas particulares ( $N \times p$  componentes)

$\vec{y}_i^M$  : salida conectada asociada a  $\vec{x}_i^M$

$O_i^M$  : salida real asociada a  $\vec{x}_i^M$

$\mu_i$  : umbral de activación asociado a la neurona  $i$  (salida).

$\vec{W}_i$  : conjunto de coeficientes sinápticos.  
( $M \times N$ )



$$\xi_i, \xi_i^H, \bar{w}_i \in \mathbb{R}^N$$

$$\xi_i^H, \theta_i^H, \mu_i \in \mathbb{R}$$

con  $\mu = 1, 2, \dots, p$ .

### Como deshacernos del molesto $\mu_i$

Vamos a imaginar que en la capa de entrada tenemos una neurona extra a la cual le asignamos el subíndice  $k=0$ , y además le asignamos el valor fijo  $\xi_0 = -1$ , cualquiera sea la entrada.

$$\begin{aligned} h_i - \mu_i &= \sum_{k=1}^N w_{ik} \xi_k - \mu_i \\ &= \sum_{k=1}^N w_{ik} \xi_k + \mu_i \xi_0 \end{aligned}$$

$$h_i - \mu_i = \sum_{k=0}^N w_{ik} \sum_k$$

si hacemos  $w_{i0} = \mu_i$ .

Con esto nos podemos olvidar del trato diferenciado que requiere  $\mu_i$ .

Ahora, para nosotros **APRENDER** significa encontrar un conjunto de acoplamientos

$$\bar{w} = (w_{i0}, w_{i1}, \dots, w_{iN})$$

tales que, ante cualquier entrada  $\sum_k^M$  del conjunto de entrenamientos, la red de la salida correcta:

$$O_i^M = g(h_i^M) = g\left(\sum_{k=0}^N w_{ik} \sum_k^M\right) = J_i^M$$

$$O_i^M = J_i^M \quad (\text{la salida es la deseada})$$

No siempre podemos aprender "perfectamente",  
y encontraremos maneras eficientes de medir  
cuán cerca estamos de una solución "perfecta".