

Asignatura: **MODELOS COMPUTACIONALES**

Ingeniería técnica en informática de gestión

Horario Clases: **Martes y Jueves 17:30-19:30**

Aula: 3.05

Profesor: Leonardo Franco Despacho 3.2.29

Email: lfranco@lcc.uma.es

Web: <http://www.lcc.uma.es/~lfranco/docencia.html>

Horario tutorías : Lunes: 10:30-13:30 hs.
Miércoles: 17:00-19:30 hs.

Por favor, avisar por correo electrónico la asistencia a tutorías para confirmar horario

Modelos computacionales

2^{da} clase 26 de Febrero de 2008

Tipos de redes neuronales según
arquitectura y tipo de aprendizaje

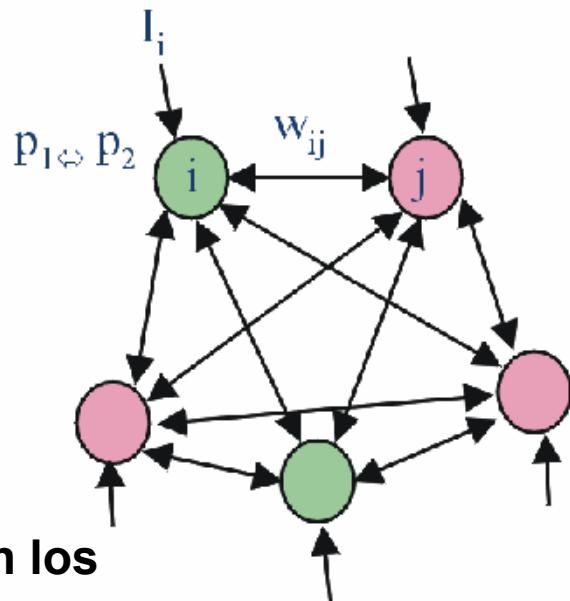
Funcionamiento de neurona biológica y
modelos de neuronas artificiales

¿Qué es una Red Neuronal?

Sistema de procesamiento masivo de información compuesto de unidades de proceso simples, llamadas **neuronas**, que se utiliza para almacenar conocimiento a través de un proceso de aprendizaje.

Basadas en la idea de cómo funciona el cerebro en los siguientes dos sentidos:

1. El conocimiento de la red es adquirido a través de un **proceso de aprendizaje**.
2. El conocimiento se almacena en las conexiones entre las neuronas, llamadas **pesos sinápticos**.



Redes neuronales artificiales

Modelos simplificados que emulan el funcionamiento del cerebro

Las redes de neuronas artificiales son modelos computacionales **paralelos** que constan de **unidades de proceso** (neuronas) **adaptativas y masivamente interconectadas**.

Son, por tanto, procesadores **distribuidos masivamente en paralelo** para almacenar conocimiento experimental y hacerlo disponible para su uso.

Tipos de redes neuronales

¿Qué clase de información procesamos y cómo fluye esta información? → **Arquitectura** : conexionado y tipo de neurona (función de activación)

¿Cómo modificamos los pesos sinápticos?

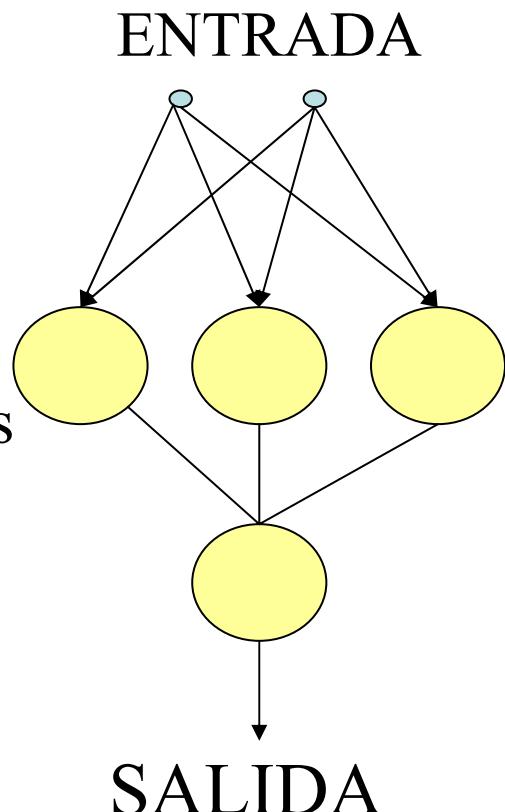
Algoritmos de Aprendizaje y dinámica del aprendizaje

Tipos de redes neuronales

Una red de neuronas artificiales está caracterizada por su:

- **Arquitectura:** patrón de conexiones entre las unidades de proceso

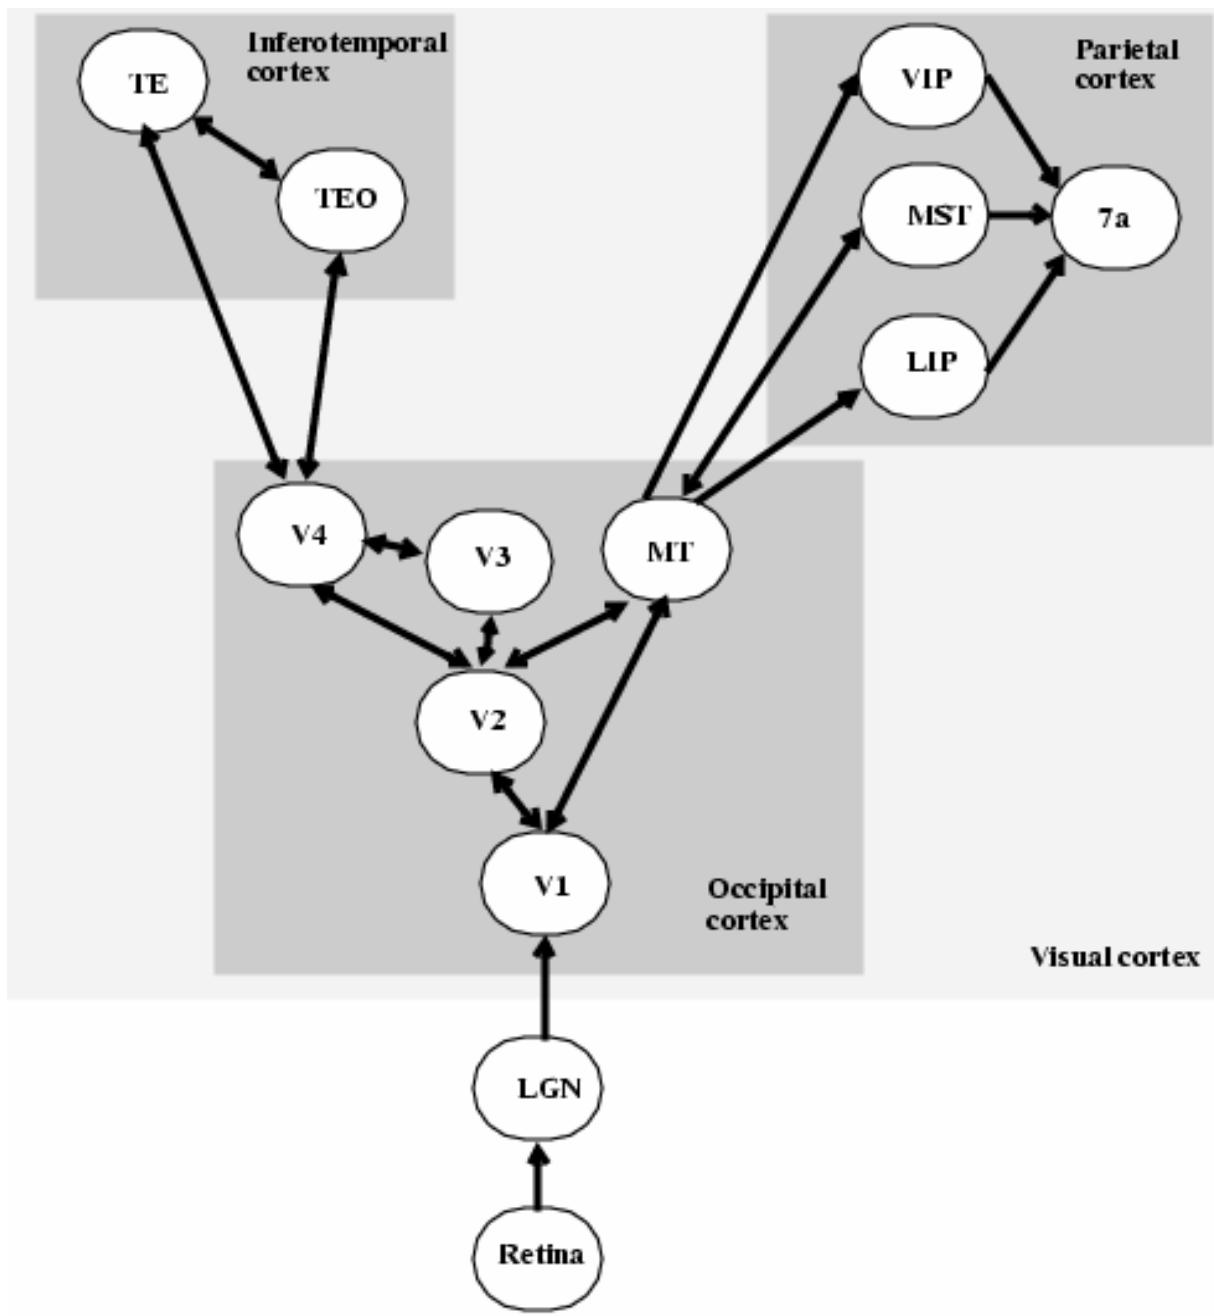
Capas ocultas
ó
Capas intermedias



La información
fluye en un solo
sentido

Red de
procesamiento
hacia adelante

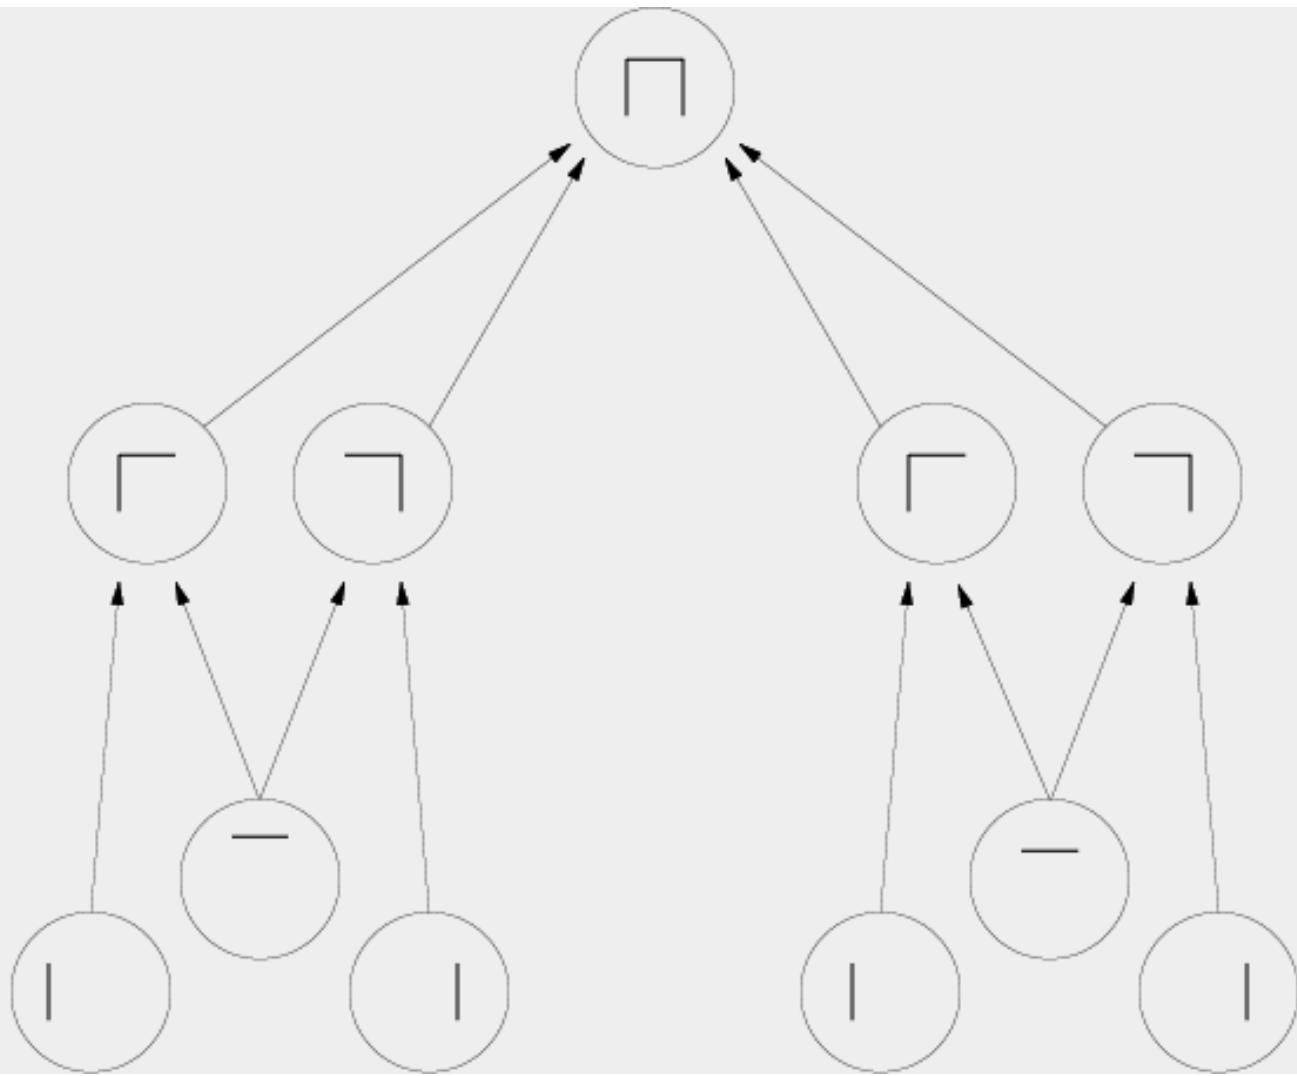
Principales áreas visuales y flujo de la informació n



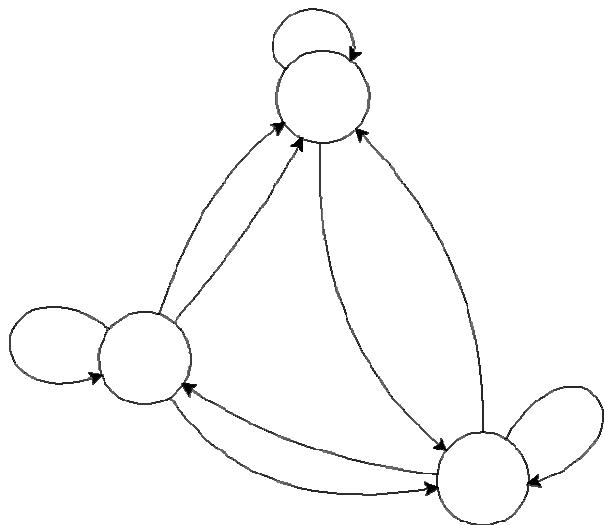
Top layer

Intermediate
layers

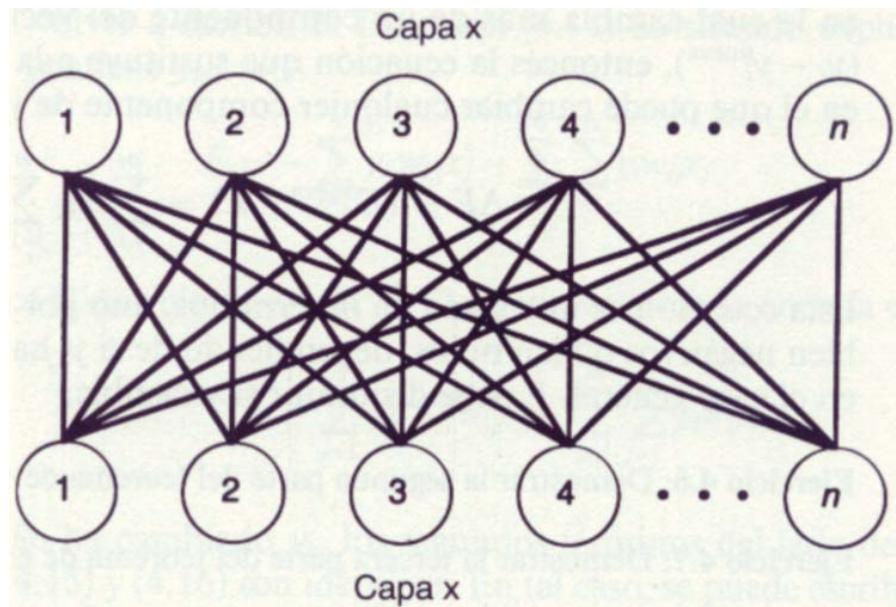
Input (V1)



Redes recurrentes



Red de Hopfield



Red tipo BAM:

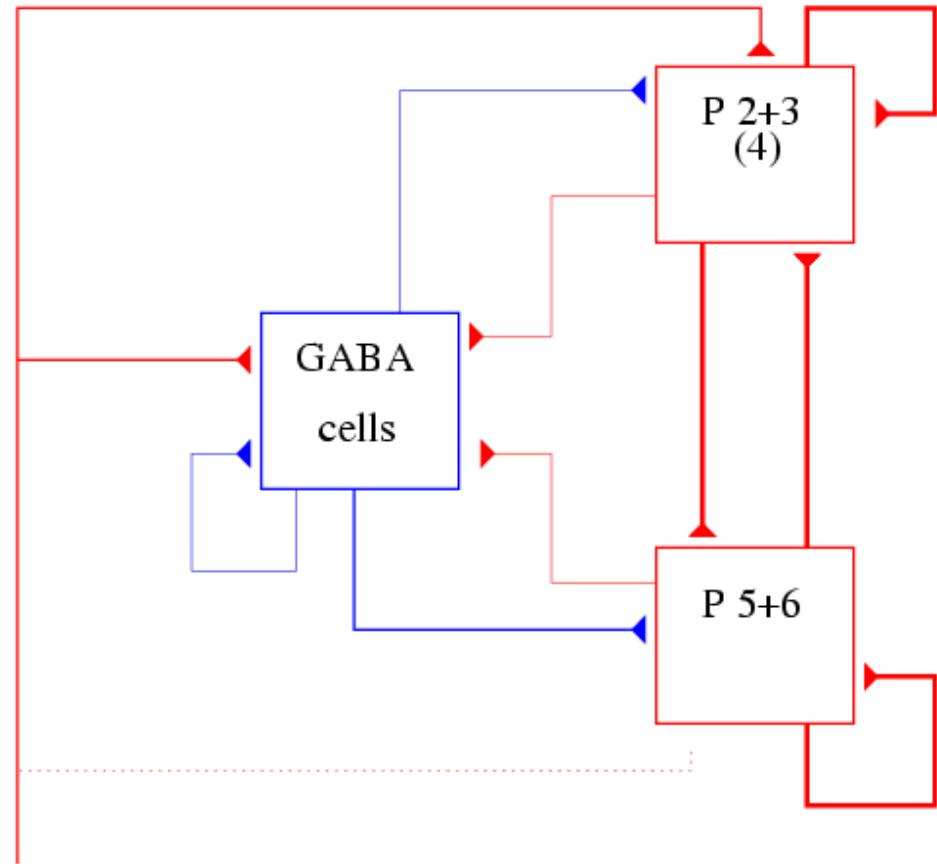
memoria asociativa

bidireccional

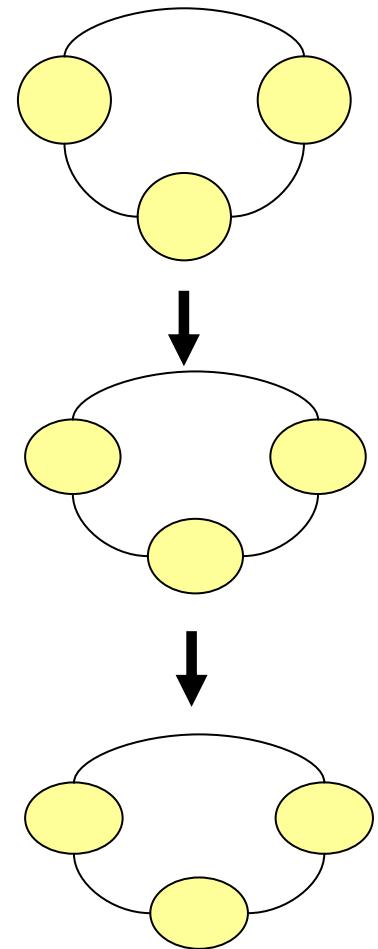
Conectividad bidireccional

Modelos de Memoria,
Problemas de optimización

Modelo de chip neuronal

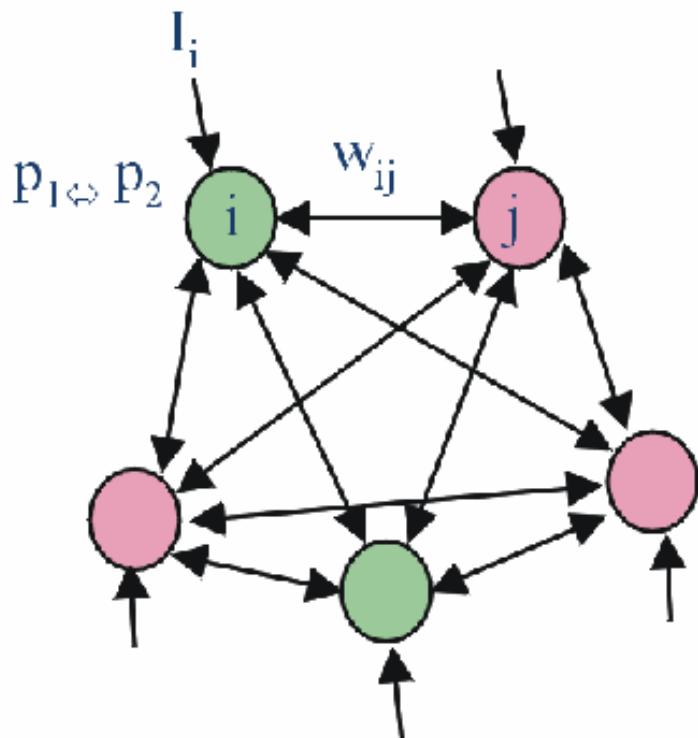


Excitatory
Inhibitory



Red de Hopfield

Red neuronal totalmente conectada auto-asociativa



Permite almacenar información y
Recuperarla cuando se presenta sólo
Una parte de la información guardada

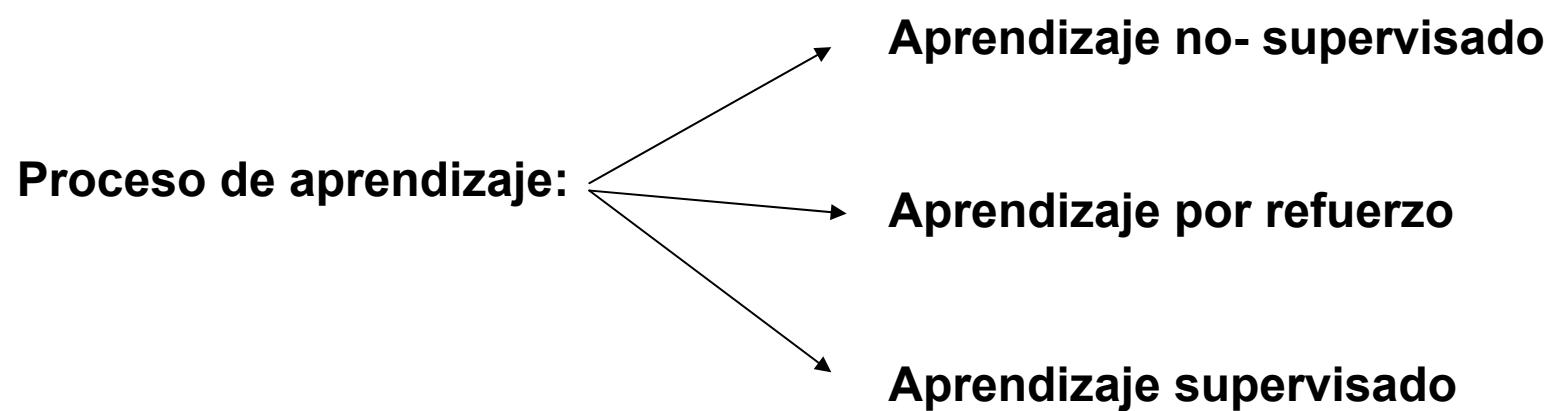
Dinámica:
¿Cómo actualizamos
la información ? Valor
de salida de las
neuronas y pesos

Aprendizaje

Redes neuronales \leftrightarrow capacidad de aprender

Mediante un **proceso adaptativo** en el cual modificamos los **pesos sinápticos** o conexiones.

Aprendizaje \longleftrightarrow Modificación de pesos sinápticos



Aprendizaje no supervisado (competitivo o autoorganizado), en el que vamos a disponer de un conjunto de patrones de entrenamiento pero no vamos a conocer las salidas deseadas de la red.

La red por sí misma buscará su comportamiento más adecuado atendiendo a cierto criterio y **encontrará estructuras o prototipos** en el conjunto de patrones de entrenamiento.

Presentamos patrones a la red pero **no le indicamos** como mejorar $\leftarrow \rightarrow$ Regla dada apriori

Ejemplo: Reconocimiento de fonemas en



Aprendizaje por refuerzo.

La idea de este paradigma surge en la psicología en relación con el estudio del aprendizaje en los animales. Si una **acción** supone una **mejora** en el comportamiento entonces la tendencia a producir esta acción **se refuerza** y en caso contrario se **debilita**.

Por ello, vamos a tener un **conjunto de patrones de entrenamiento y sus correspondiente señales evaluativas**, que suelen ser valores -1 ó +1.

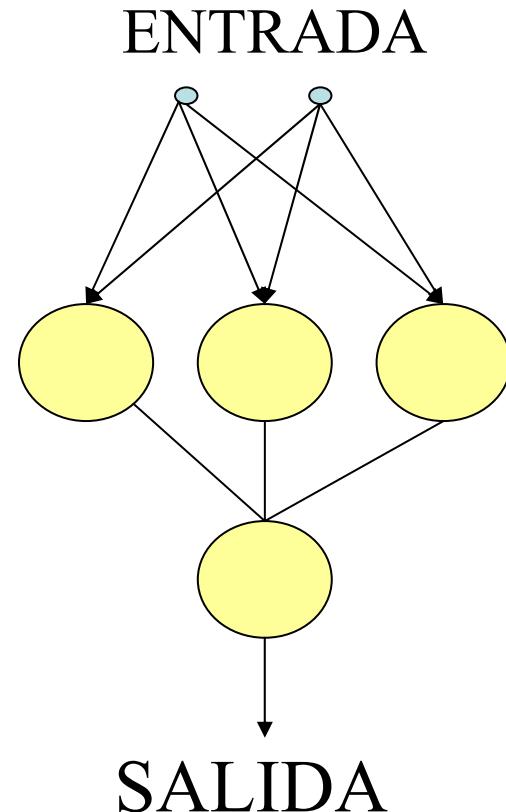


Aprendemos con ejemplos y corregimos los pesos si a través de una **señal evaluativa general**.

Ej.: Preguntas Si/No

Aprendizaje supervisado

Aprendizaje supervisado, en el que vamos a disponer de un conjunto de patrones de entrenamiento para los que conocemos perfectamente la salida deseada de la red.



Entrenamos a través de ejemplos y podemos analizar el **comportamiento interno** de la red para realizar modificaciones:

Redes multicapas: perceptrones

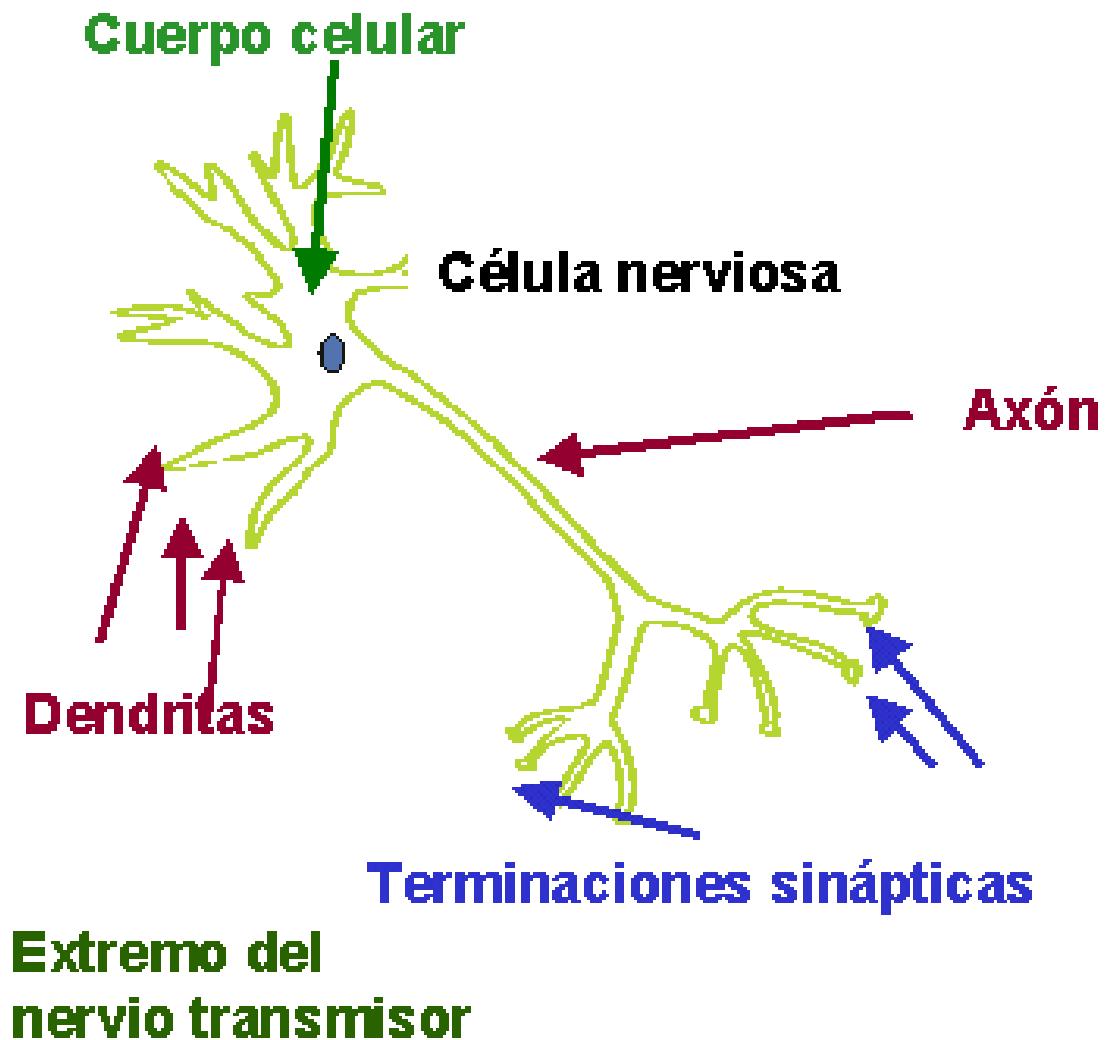
La Neurona biológica

Morfología:

- Dendritas
- Soma
- Axón
- Sinapsis

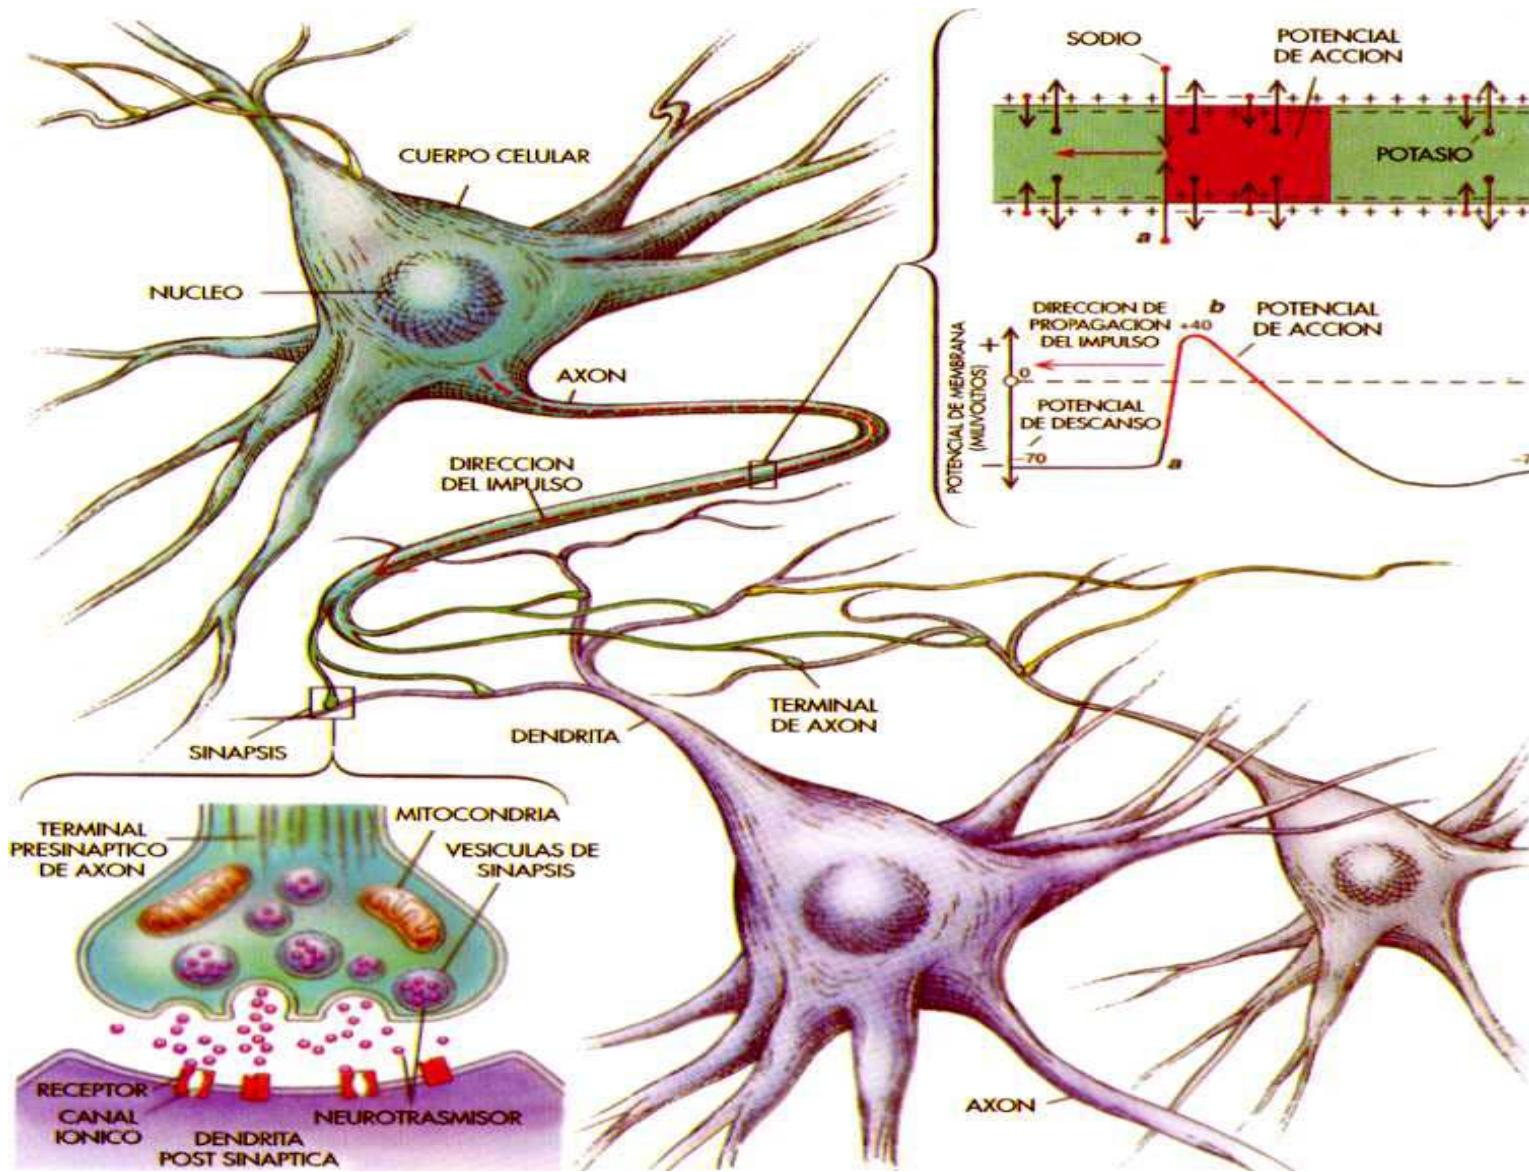
isiología:

- Pesos sinápticos
- Potencial sináptico
- Umbral
- Activación/Inhibición



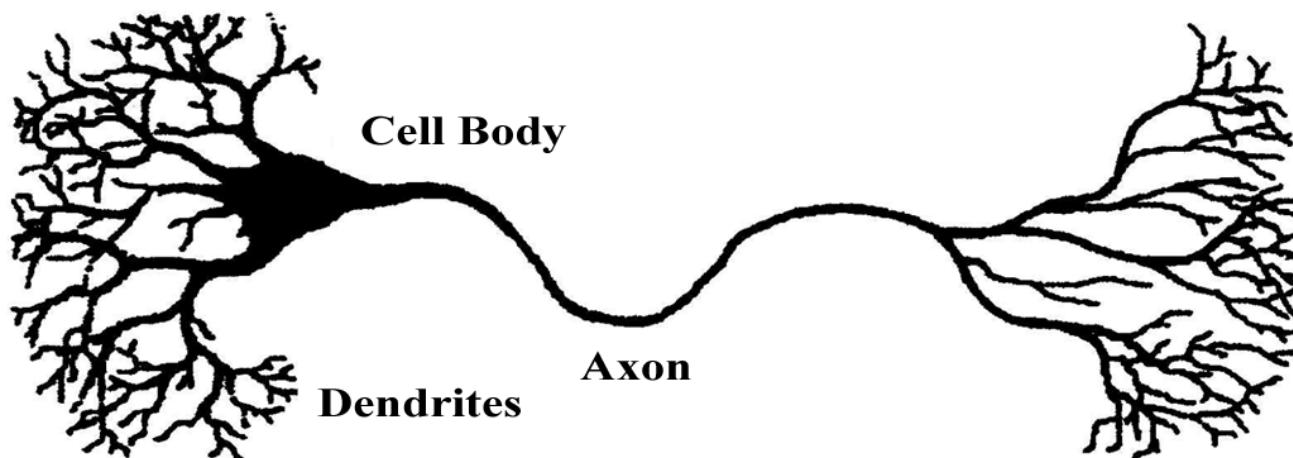
Componentes básicos de Neuronas biológicas

1. La gran mayoría de las **neuronas** biológicas codifican su estado (activación o salida) por una serie de impulsos eléctricos (disparos).
2. El cuerpo celular o **soma** procesa la información de llegada y determina el estado de activación de la neurona.
3. Las **dendritas** que emanan del soma reciben los impulsos provenientes de otras neuronas.
4. El **axón** transmite los impulsos del soma a otras neuronas.
5. La unión de contacto entre axón y dendrita es llamada **sinapsis** y es la que permite la transmisión de la información entre dos o más neuronas.



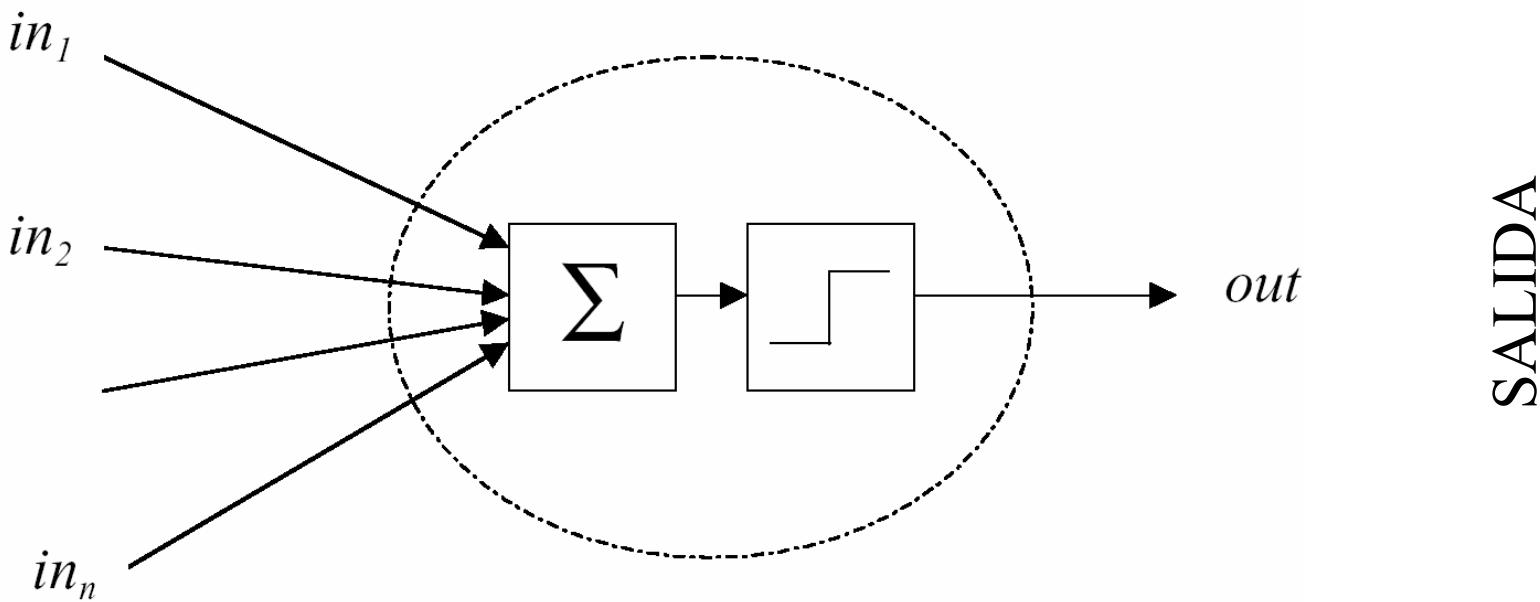
Funcionamiento Neurona

Video

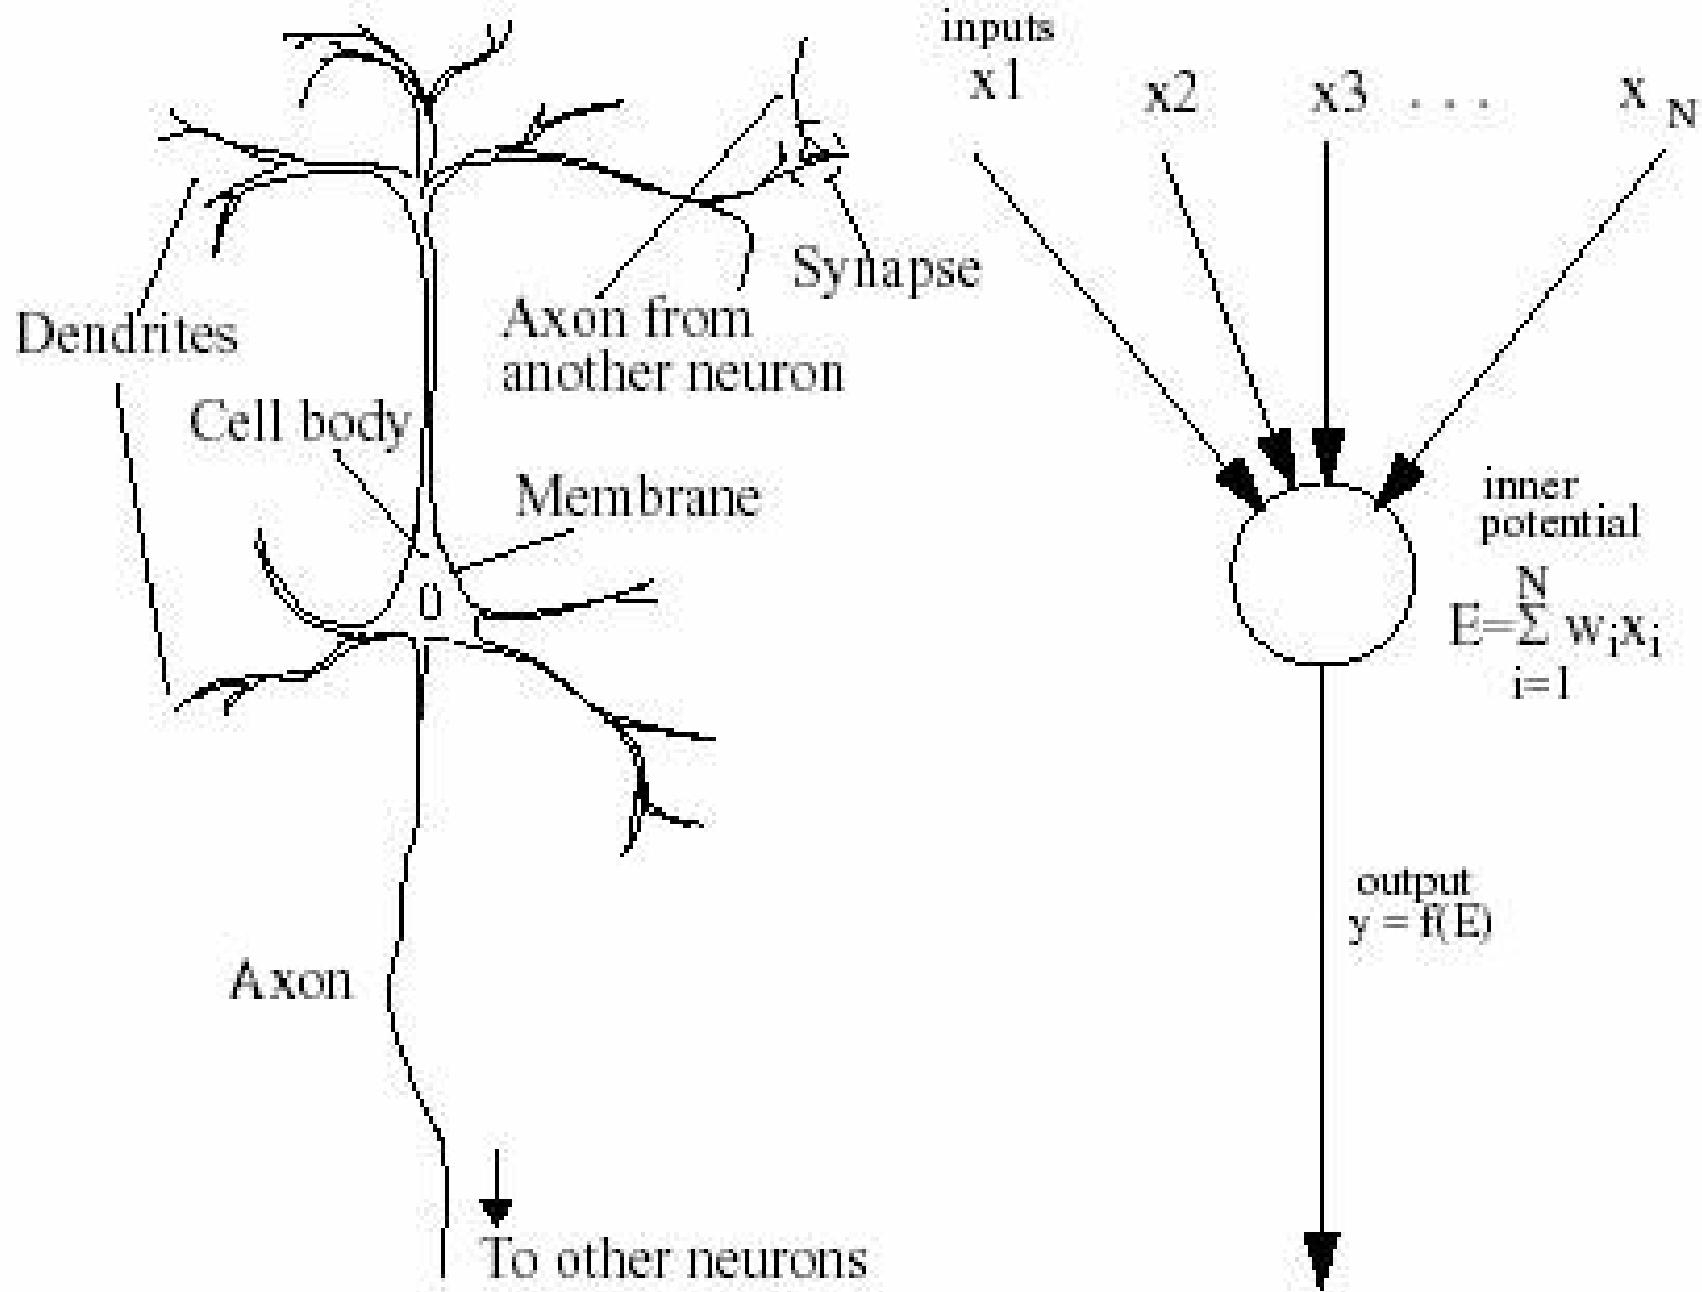


Modelo de neurona de McCulloch-Pitts

ENTRADA

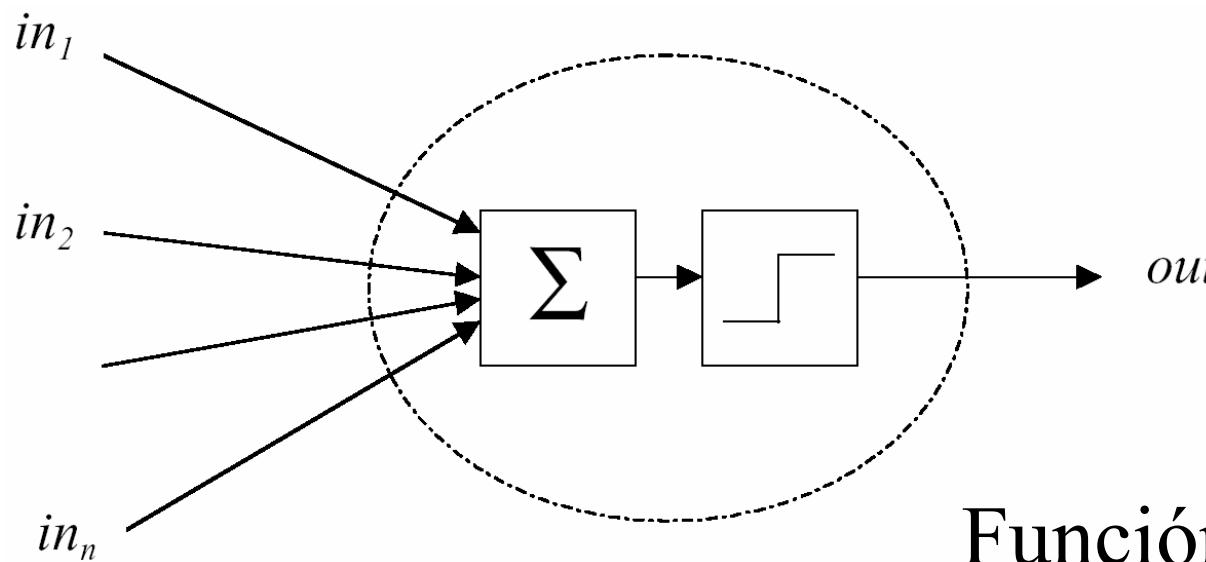


1. Un conjunto de **conexiones** transmite la información proveniente de otras neuronas
2. La unidad de proceso **suma** las entradas y aplica una **función de transferencia no-lineal** . (ej. Función **Umbral**).
3. El valor de activación es enviado a otras neuronas.



Modelo de neurona de McCulloch-Pitts

ENTRADA



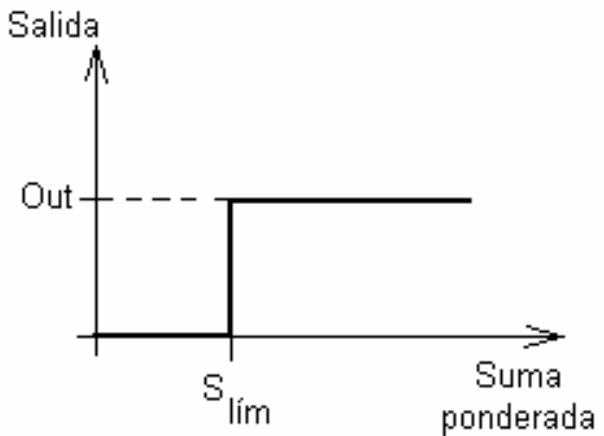
SALIDA

Función escalón

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

Función signo

Salida [-1,1]

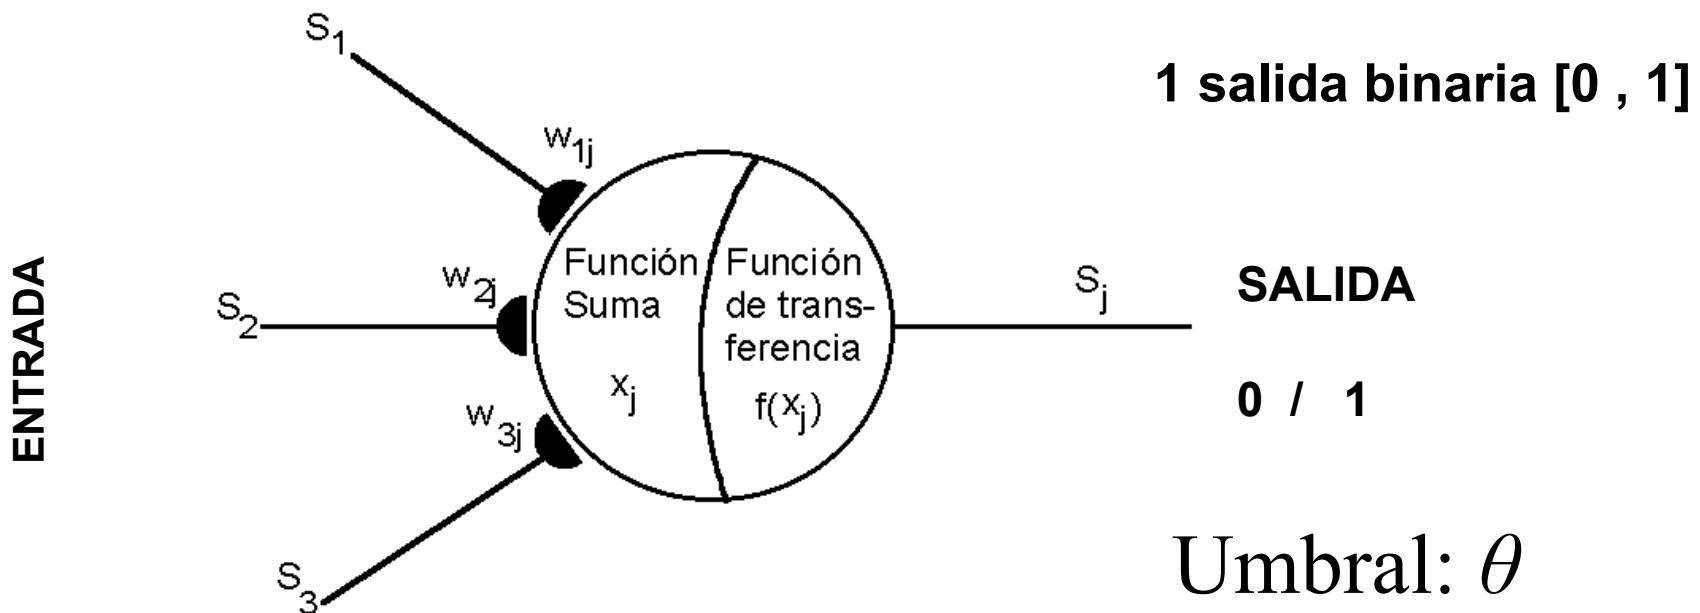


Salida [0,1]

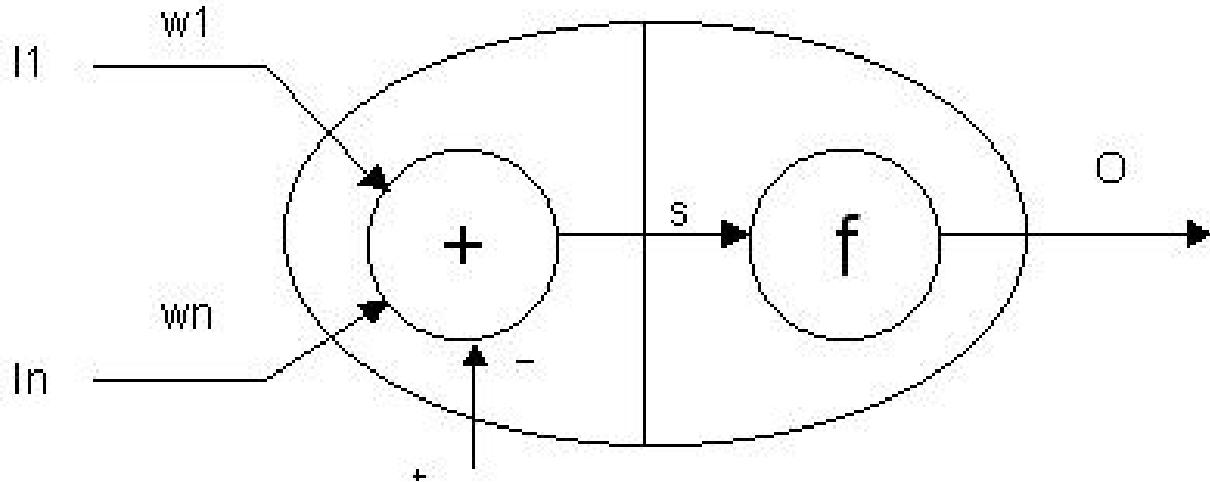
Neurona Binaria

Suma ponderada de entradas → Función no-lineal → salida binaria

N entradas binarias $[0, 1]^N$



$$f(x_1, x_2, \dots, x_n) = \begin{cases} 1 & \text{si } w_1x_1 + w_2x_2 + \dots + w_nx_n \geq \theta \\ 0 & \text{si } w_1x_1 + w_2x_2 + \dots + w_nx_n < \theta \end{cases}$$



Neurona con 2 entradas y función de activación escalón (umbral = 1.5)

ENTRADA

1

$w_1=1$

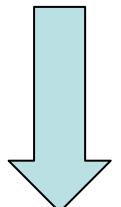
1

$w_2=1$

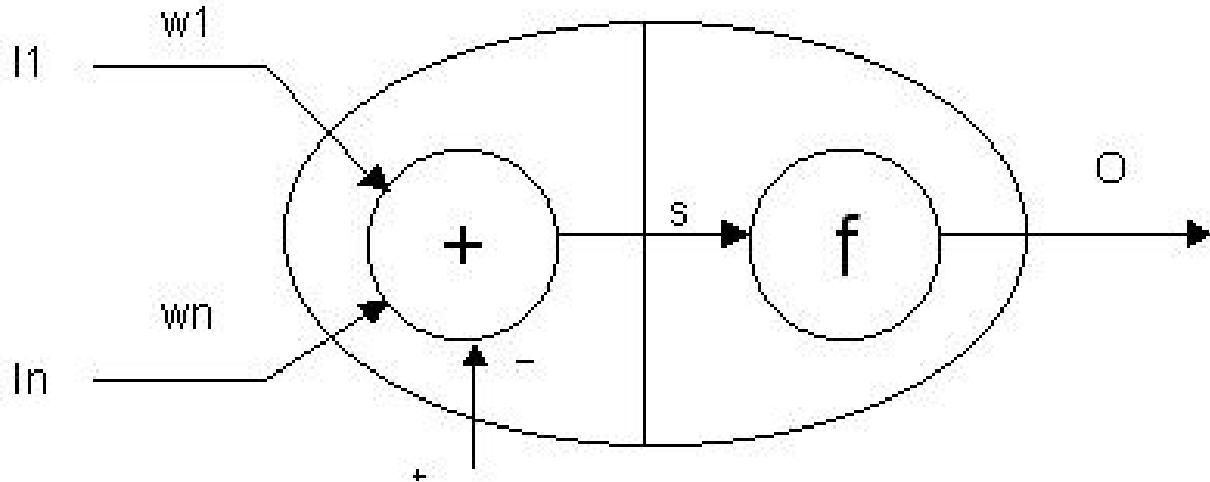
Potencial
Sináptico

$$= 1 * 1 + 1 * 1 = 2$$

$2 > \text{umbral}$



Salida =



Neurona con 2 entradas y función de activación escalón (umbral = 1.5)

ENTRADA

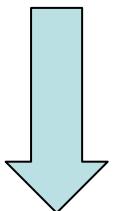
0
1

$w_1=1$
 $w_2=1$

Potencial
Sináptico

$$= 0 * 1 + 1 * 1 = 1$$

$1 < \text{umbral}$

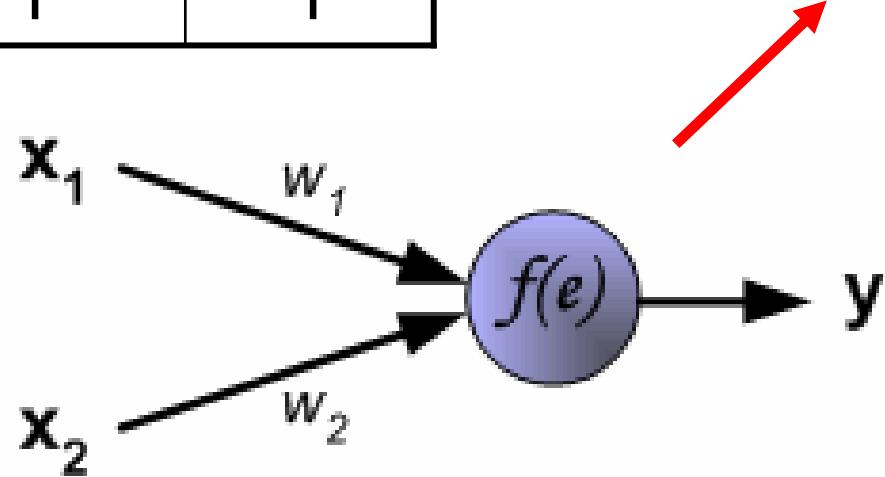
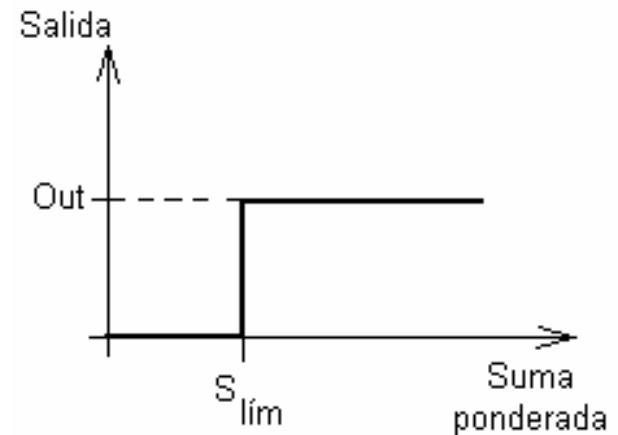


Salida = 0

Entrada	Pesos sinápticos		Potencial sináptico	umbral	Salida	
0	0	1	1	0	1.5	0
0	1	1	1	1	1.5	0
1	0	1	1	1	1.5	0
1	1	1	1	1	1.5	1

FUNCIÓN BOOLEANA AND

X1	X2	AND
0	0	0
0	1	0
1	0	0
1	1	1



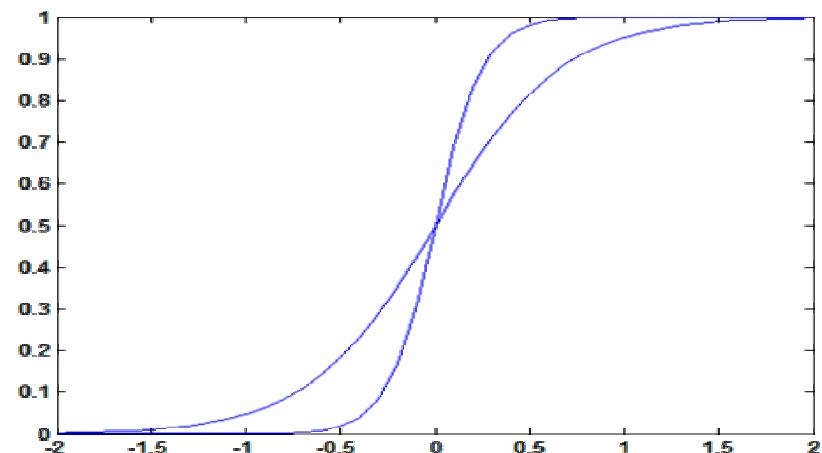
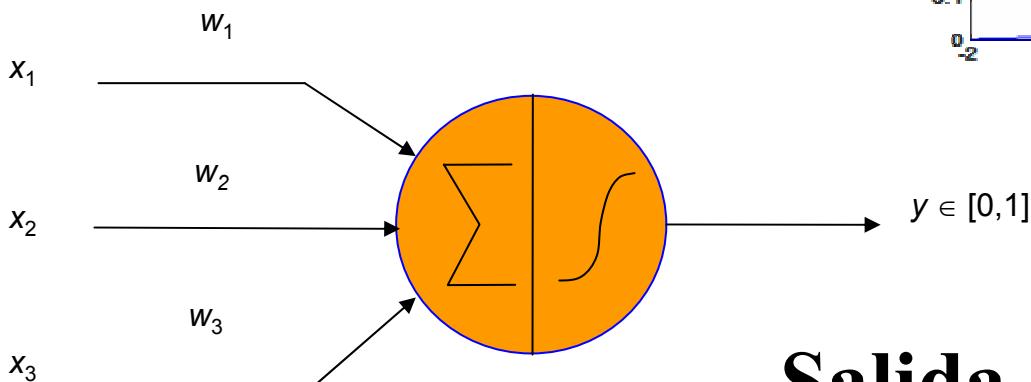
$$W1=1$$

$$W2=1$$

$$\text{Umbral}=1.5$$

Función sigmoidea logística (Salida continua entre 0 y 1)

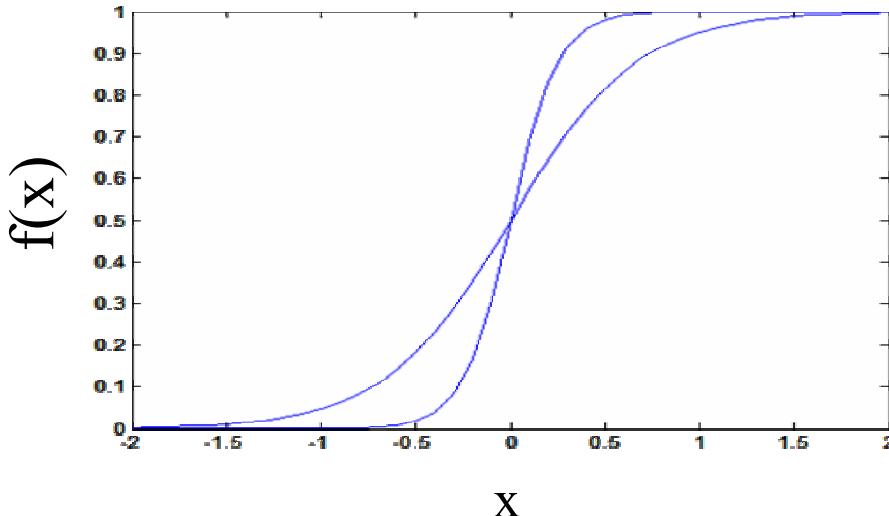
$$f(x_1, x_2, \dots, x_n) = \frac{1}{1 + \exp\left(-2\beta \sum_{i=1}^n w_i x_i\right)}$$



Salida continua entre 0 y 1

Trabajar con funciones continuas permite el cálculo de derivadas

Función sigmoidea logística (Salida **continua** entre 0 y 1)



$$f(x) = \frac{1}{1+e^{-\beta x}}$$

Si aumenta el factor β , la función se parece cada vez más a una función escalón con umbral en 0.

$$f(-\infty) \rightarrow 0$$

$$f(0) = 0.5$$

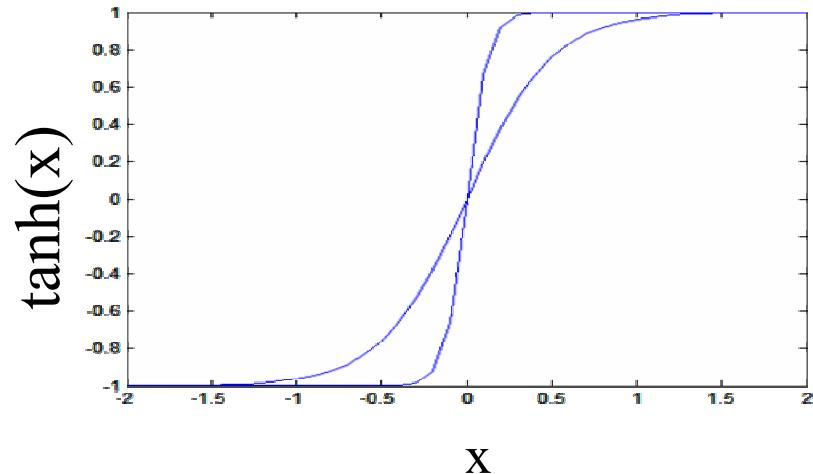
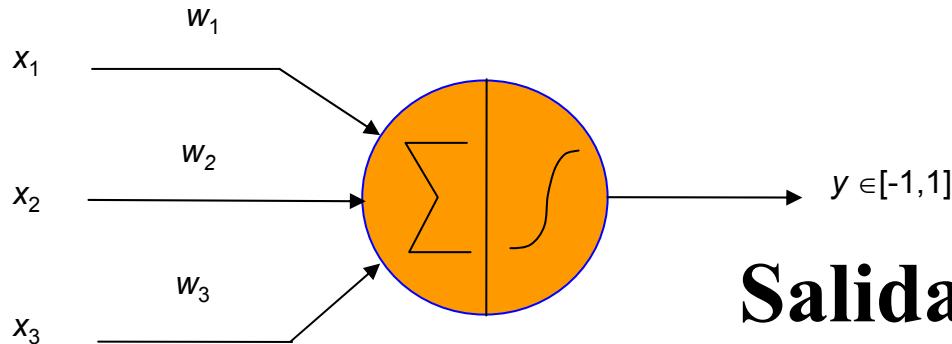
$$f(+\infty) \rightarrow 1$$

Neurona con función de activación tangente hiperbólica (salida entre -1 y 1)

Una **unidad de proceso tangente hiperbólica** es una función de R^n en $[-1,1]$ dada por la expresión

$$f(x_1, x_2, \dots, x_n) = \tanh(\beta \sum_{i=1}^n w_i x_i)$$

$$f(x_1, x_2, \dots, x_n) = \frac{\exp\left(\beta \sum_{i=1}^n w_i x_i\right) - \exp\left(-\beta \sum_{i=1}^n w_i x_i\right)}{\exp\left(\beta \sum_{i=1}^n w_i x_i\right) + \exp\left(-\beta \sum_{i=1}^n w_i x_i\right)}$$



Salida continua entre -1 y 1

Cuestionario de autoevaluación

1. Las neuronas biológicas tienen un soma, axón dendritas y sinapsis. Realice un diagrama y represente estos elementos.
2. Dibuje un modelo computacional de neurona equivalente
3. Mencionar las principales diferencias entre el modelo computacional y el biológico.
4. ¿Qué ventajas pueden tener los modelos computacionales distribuidos frente a modelos computacionales tipo ordenador de von Neumann? ¿Qué significa que las redes neuronales ~~pueden aprender~~ En qué se diferencia el aprendizaje supervisado del no-supervisado?
6. Mencione algunos tipos usuales de funciones de activación. ¿Son funciones no-lineales? ¿Por qué? ¿Cuál es la utilidad de usar funciones no-lineales?

Redes neuronales artificiales

Las redes de neuronas artificiales son
modelos computacionales.

Modelos simplificados que emulan el
funcionamiento
del cerebro
Operan masivamente en paralelo para
almacenar conocimiento experimental y
hacerlo disponible para su uso en diversos
problemas.