


-
-
-
-
-
-
-
-
-
-
-
-

Redes Neuronales

Introducción



José Manuel Quero Reboul
Dpto. Ingeniería Electrónica
Universidad de Sevilla

-
-
-

Indice

- Motivación
- Arquitectura
- Leyes de Aprendizaje
- Aplicaciones

DILEMA

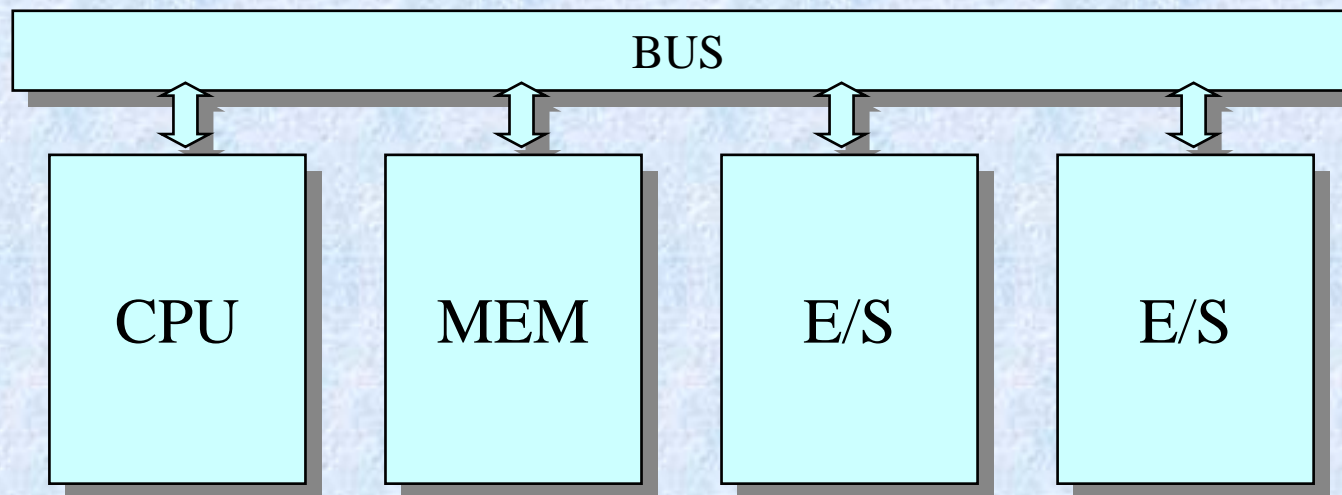
CALCULO

- Aritmética → 1 cerebro=1/10 calculadora de bolsillo
- Visión → 1 cerebro=1000 supercomputadores

MEMORIA

- Datos → cerebro mucho peor
- Direccionada por contenido → cerebro mucho mejor

Arquitectura Von Newman



Bus de datos: Cuello de Botella (Secuencialidad)

Cerebro

- 10^{10} neuronas (10ms)
- 10^4 dendritas
- 10^{14} pesos de conexión
- Los pesos almacenan y procesan



Definición

Computación neuronal:

Computación en redes masivas paralelas de procesadores simples y no lineales, que almacenan todo su contenido en los pesos de conexión

Propiedades:

- Eliminación del cuello de botella
- Inteligencia artificial llevada al límite

-
-
-

Indice

- Motivación
- Arquitectura
- Leyes de Aprendizaje
- Aplicaciones

Neurona Artificial

Ley de Propagación

$$net_i = \sum_j W_{ij} I_j$$

Ley de Activación

$$a(t+1) = F(a(t), net_1(t), net_2(t), \dots)$$

Función de Salida

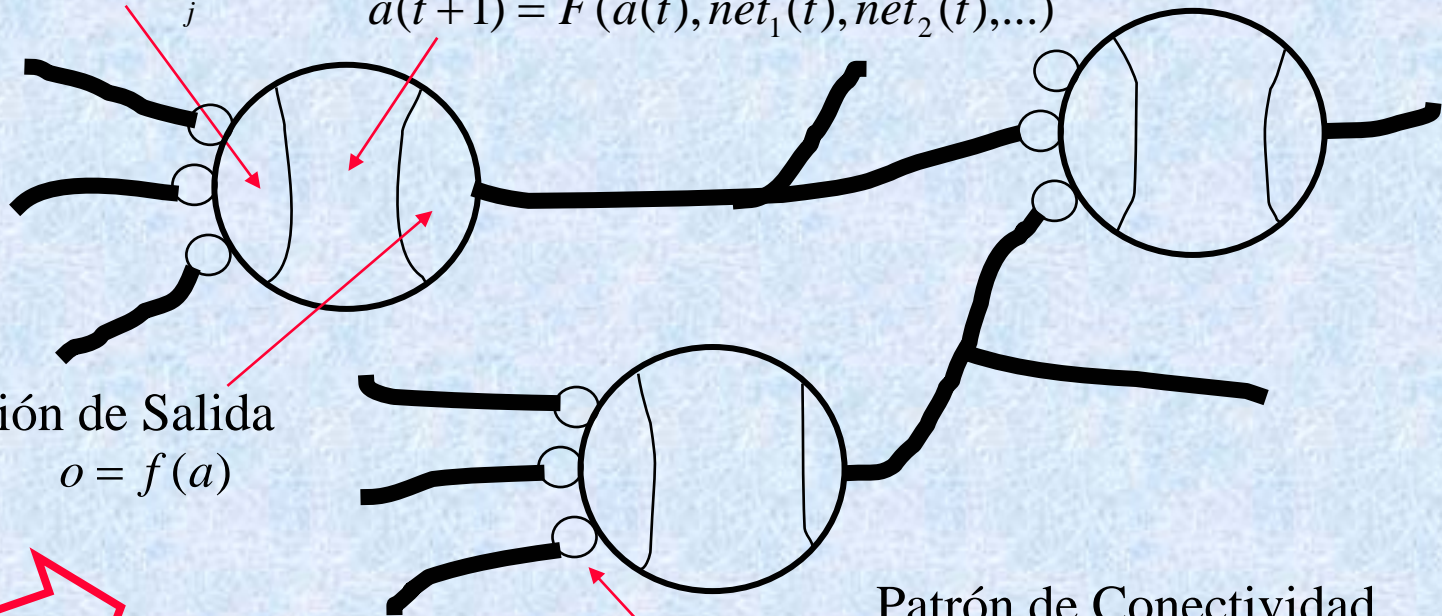
$$o = f(a)$$

Patrón de Conectividad

Ley de Aprendizaje


$$w_{ij}(t+1) = g(w_{ij}(t), net_i(t), a(t), o(t))$$

Entorno



-
-
-

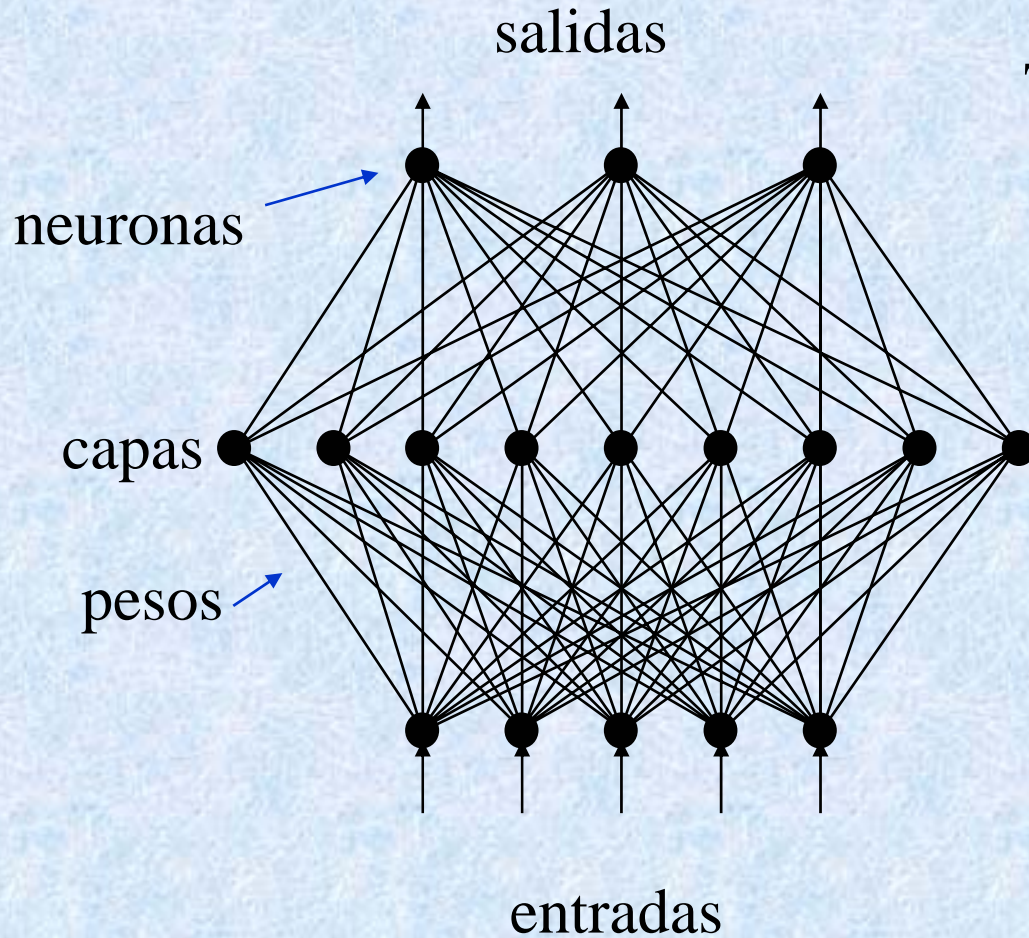
Función de activación



Función sigmoïdal:
$$\sigma(x) = \frac{1}{1 + e^{-x}}$$

•
•
•

Red neuronal



Topologías:

- Monocapa
- Multicapa
- Redes forward
- Redes recurrentes
- Redes realimentadas
- Redes de funciones radiales

• • • • • • • • • •

-
-
-

Indice

- Motivación
- Arquitectura
- Clasificación
- Leyes de Aprendizaje
- Aplicaciones

Aprendizaje

- El conocimiento es obtenido a partir de la experiencia y almacenado en los pesos
- Tipos de aprendizajes:
 - Preprogramadas
 - Ley de Hebb
 - Aprendizaje competitivo
 - Aprendizaje supervisado
- La red extrae y copia la estructura interna del conocimiento del entorno

-
-
-

Leyes de Aprendizaje

$$o = f(W^T I)$$

$$\frac{dW}{dt} = \dot{W} = \phi(\cdot)I - \gamma(\cdot)W$$

W : Vector de pesos

$\phi(\cdot), \gamma(\cdot)$: Funciones escalares (W, I, o)

I : Señales de entrada

o : salida

Función de Transferencia no lineal

Leyes de Aprendizaje

- Justificación

1) Ley de Hebb: Cuanto mayor sea la excitación, mayor será el refuerzo de la conexión

$$\phi(\cdot)I$$

2) Factor de Olvido: Proporcional a la propia magnitud

$$-\gamma(\cdot)W$$

- Condiciones (estabilidad dinámica)

1) **si** $o(t)$ **acotada** $\Rightarrow W(t)$ **finita** $\forall t$

2) **si** $I \neq 0 \Rightarrow W(t) \nrightarrow 0 \quad t \rightarrow \infty$

-
-
-

Indice

- Motivación
- Arquitectura
- Clasificación
- Leyes de Aprendizaje
- Aplicaciones

-
-
-

Propiedades de las RN


- Procesamiento de un gran conjunto de datos
- Baja densidad de información
- Robustez ante fallo en estructura
- Robustez ante inconsistencia en los datos de entrada
- Datos y reglas de procesamiento confundidos en las conexiones
- Procesamiento altamente paralelo
- Capacidad de Autoorganización. Adaptabilidad

¿Cuándo usar Redes Neuronales?

- Cuando se quiere desarrollar un modelo (funcional, clasificador, predicción de serie temporal,...)
- Ejemplos
 - Finanzas: Modelos de mercado
 - Ingeniería: Modelado de procesos y control adaptativo
 - Medicina: Diagnósis


¿Cuándo usar Redes Neuronales?

- En análisis de datos con baja densidad de información
- Ejemplos:
 - Reconocimiento de imágenes
 - Reconocimiento de firmas
 - Análisis de encuestas
 - Predicción meteorológica



Redes Neuronales

Aprendizaje Supervisado




-
-
-

Indice

- Perceptrón
 - Regla delta
- Perceptrón Multicapa
 - Retropropagación
- Ejemplos

Perceptrón

• Memoria Asociativa




Interpretación Geométrica

$$i_1 = -\frac{w_0}{w_1} i_0 + \frac{\theta}{w_1}$$



Recta de Decisión



Perceptrón

- Aprendizaje Supervisado: Regla δ

$$\frac{dw_i}{dt} = \alpha[d(t) - o(t)]i_i(t) \quad 0 \leq i \leq n-1 \quad d(t), o(t) \in \{-1, 1\}$$


Aprendizaje a partir de w_i aleatorios

Problema: Oscilación ante entradas no separables

Ejemplo: función XOR

Patron de Entrada Patron de Salida

00	→	0
01	→	1
10	→	1
11	→	0




Perceptrón

Solución: Añadir una dimensión adicional

Patron de Entrada Patron Intermedio Patron de Salida

00	→	000	→	0
01	→	010	→	1
10	→	100	→	1
11	→	111	→	0

Nodos de representación interna


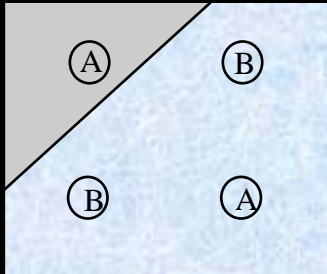
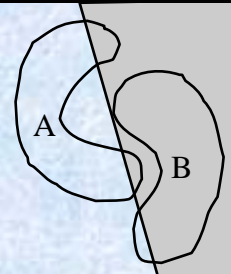

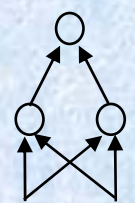
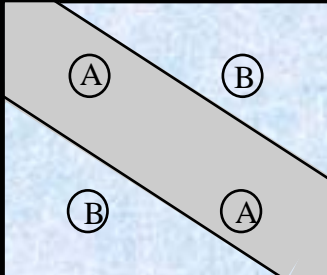
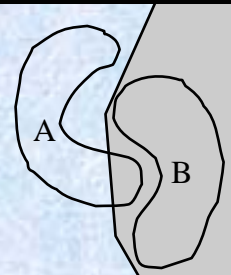
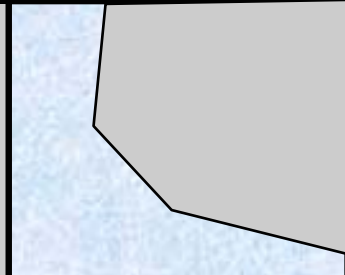
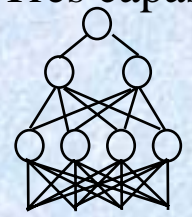
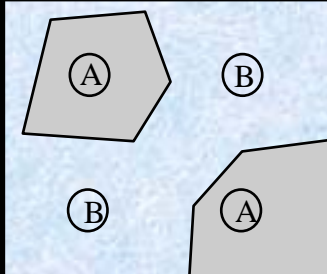
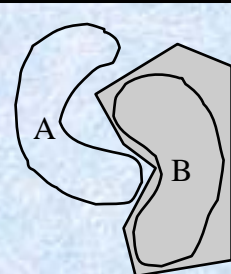
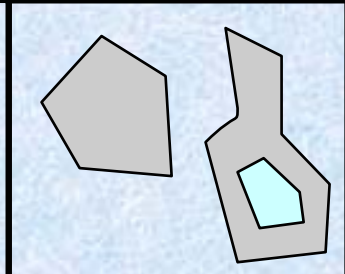


-
-
-


Indice

- Perceptrón
 - Regla delta
- Perceptrón Multicapa
 - Retropropagación
- Ejemplos

Perceptrón Multicapa

Estructura	Regiones de Decisión	Problema XOR	Clases Complejas	Regiones de Decisión Generales
<p>Una capa</p> 	<p>Semiespacios limitados por hiperplanos</p>			
<p>Dos capas</p> 	<p>Regiones convexas abiertas o cerradas</p>			
<p>Tres capas</p> 	<p>Arbitrarias. Complejidad limitada por el número de nodos</p>			

Perceptrón Multicapa



OR

AND


HIPERPLANOS

$$o_i = f(net_i - \theta) \quad net_i = \sum_{j=1}^n w_{ij} \cdot i_j$$




$$o_i = f(net_i)$$

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



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

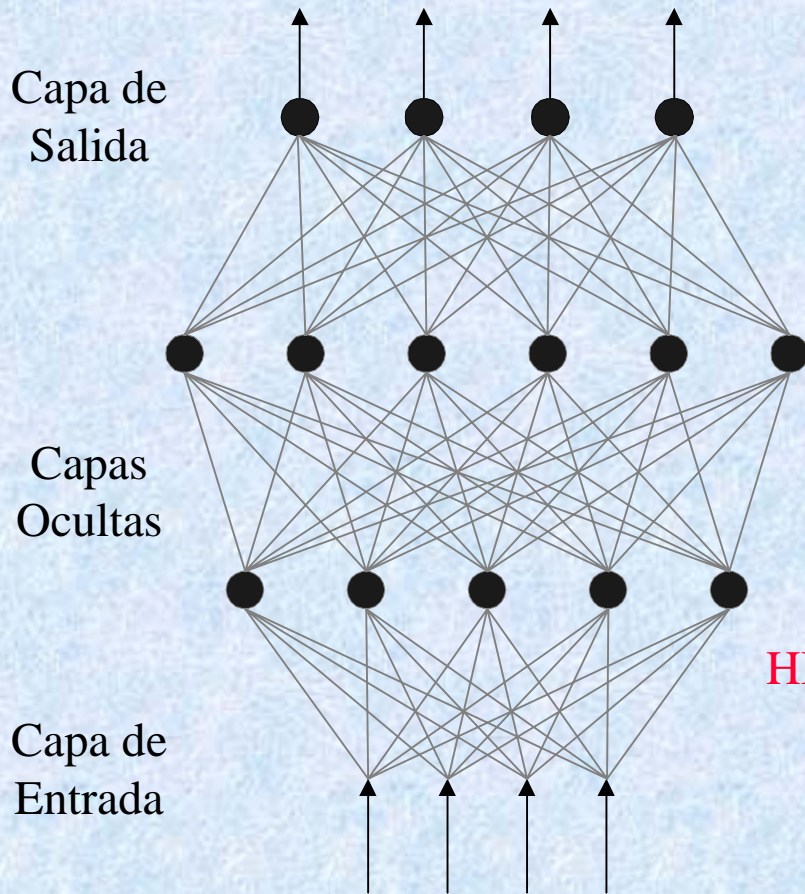


-
-
-

Indice

- Perceptrón
 - Regla delta
- Perceptrón Multicapa
 - Retropropagación
- Ejemplos

Perceptrón Multicapa



OR

AND

HIPERPLANOS

Retropropagación

(Regla δ generalizada)

$$\Delta_p w_{ij}(t+1) = \eta \delta_j i_i \quad \text{capa } i \text{ previa a } j$$

$$\delta_j = \begin{cases} f'_j(\text{net}_{pj})(d_j - o_j) & \text{Capa de Salida} \\ f'_j(\text{net}_{pj}) \sum_k \delta_k w_{kj} & \text{Capas Ocultas} \end{cases}$$

Perceptrón Multicapa

Retropropagación: Demostración

Error Cuadrático Médio

$$E \equiv \sum_p E_p = \frac{1}{2} \sum_p \sum_j (d_{pj} - o_{pj})^2$$

Regla de la cadena

$$\frac{\partial E_p}{\partial w_{ji}} = \frac{\partial E_p}{\partial net_{pj}} \frac{\partial net_{pj}}{\partial w_{ji}} \quad (1)$$

Cambio de la excitación la variar el peso de conexión

Segundo Término

$$\frac{\partial net_{pj}}{\partial w_{ji}} = \frac{\partial}{\partial w_{ji}} \left(\sum_i w_{ji} o_{pi} \right) = o_{pi} \quad (2)$$

Cambio del error al variar la excitación en j

Primer Término

$$\text{Definamos } \delta_{pj} \equiv -\frac{\partial E_p}{\partial net_{pj}} \quad (3) \quad \text{Sustituyendo (2) y (3) en (1)} \Rightarrow \Delta_p w_{ji} = \eta \delta_{pj} o_{pi}$$

Queda determinar qué es δ_{pj} para cada neurona

Perceptrón Multicapa

Regla de la cadena $\delta_{pj} = -\frac{\partial E_p}{\partial net_{pj}} = -\frac{\partial E_p}{\partial o_{pj}} \frac{\partial o_{pj}}{\partial net_{pj}}$

→ Cambio de la salida por cambiar la excitación

→ Cambio del error al variar la salida

Segundo Término

Dado que $o_{pj} = f(net_{pj}) \Rightarrow \frac{\partial o_{pj}}{\partial net_{pj}} = f'(net_{pj})$ Derivada de la función de salida

Primer Término

Para neurona de salida. Dado que $E_p = \frac{1}{2} \sum_j (d_{pj} - o_{pj})^2 \Rightarrow \frac{\partial E_p}{\partial o_{pj}} = -(d_{pj} - o_{pj})$

$\Rightarrow \delta_{pj} = f'(net_{pj})(d_{pj} - o_{pj})$

Perceptrón Multicapa

Para neurona oculta.

$$\frac{\partial E_p}{\partial o_{pj}} = \sum_k \frac{\partial E_p}{\partial net_{pk}} \frac{\partial net_{pk}}{\partial o_{pj}} = \sum_k \frac{\partial E_p}{\partial net_{pk}} \frac{\partial}{\partial o_{pj}} \left(\sum_i w_{ki} o_{pi} \right) = \sum_k \frac{\partial E_p}{\partial net_{pk}} w_{kj} = - \sum_k \delta_{pk} w_{kj}$$

Cómo afecta a la capa previa

δ de la capa previa

Conexión con la neurona previa

$$\Rightarrow \delta_{pj} = f'(net_{pj}) \sum_k \delta_{pk} w_{kj}$$

Particularizando $o_{pj} = \frac{1}{1 + e^{-net_j}} \Rightarrow o'_{pj} = f'(net_j) = \frac{e^{-net_j}}{(1 + e^{-net_j})^2} = o_{pj}(1 - o_{pj})$

$$\Rightarrow \delta_j = \begin{cases} o_j(1 - o_j)(d_j - o_j) & \text{Capa de Salida} \\ i_j(1 - i_j) \sum_k \delta_k w_{ij} & \text{Capas Ocultas} \end{cases}$$

-
-
-

Indice

- Perceptrón
 - Regla delta
- Perceptrón Multicapa
 - Retropropagación
- Ejemplos