


# Perceptrón y Adaline

Teoría de Autómatas y Lenguajes Formales II. Curso 2008-09.  
3º curso de Ingeniería Técnica en Informática de Sistemas  
Escuela Técnica Superior de Ingeniería Informática  
Universidad de Valladolid

## Definición y funcionamiento

La misma arquitectura:




$$T: \mathbb{R}^n \rightarrow \mathbb{R}^m$$

- Las neuronas de entrada:
  - Propagan una componente del vector a todas las neuronas de salida
  - No realizan procesamiento alguno
- Las neuronas de salida:
  - Se ajustan al modelo de McCulloch-Pitts
  - Perceptrón simple:  $F(x) = \text{sgn}(x)$
  - Adaline:  $F(x) = x$

## Interpretación geométrica


Separador lineal:



$$u = w_1 x_1 + w_2 x_2 + \Theta$$

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

Activación:



## Aprendizaje del perceptrón

1. Pesos iniciales aleatorios
2. En cada iteración:
 
$$w(t+1) = w(t) + \Delta w(t)$$
3. Para cada muestra de aprendizaje:
  - Si  $y(x) = d(x) \Rightarrow \Delta w(t) = 0$
  - Si  $y(x) \neq d(x) \Rightarrow \Delta w_i(t) = d(x) x_i$

Adaptación de la Regla de Hebb:

  - Reforzar las conexiones, cuya entrada sea del mismo carácter que la salida: inhibitoras o excitadoras
  - $\Delta w_i(t) \propto y(x) x_i$
4. ¿ $y(x) = d(x)$  para toda muestra de aprendizaje?
  - No: vuelta a 3
  - Sí: FINAL

## Ejemplo de aprendizaje (perceptrón)


### Iteraciones # 1

muestras	$x_1$	$x_2$	$d(x)$	$u(x)$	$y(x)$	$w_1$	$w_2$	$\theta$
Pesos iniciales <sup>(1)</sup>						0.75	1	-3
A <sup>(2)</sup>	1	1	1	-1.25	-1	1.75	2	-2
B	2	1	1	3.5	1	1.75	2	-2
C	3	2	1	7.25	1	1.75	2	-2
D	2	3	1	7.5	1	1.75	2	-2
E	-1	-1	-1	-5.75	-1	1.75	2	-2
F	-2	2	-1	-1.5	-1	1.75	2	-2
G <sup>(3)</sup>	-1	3	-1	2.25	1	2.75	-1	-3

### Iteraciones #2

muestras	$x_1$	$x_2$	$d(x)$	$u(x)$	$y(x)$	$w_1$	$w_2$	$\theta$
A <sup>(4)</sup>	1	1	1	-1.25	-1	3.75	0	-2
B	2	1	1	5.5	1	3.75	0	-2
C	3	2	1	9.25	1	3.75	0	-2
D	2	3	1	5.5	1	3.75	0	-2
E	-1	-1	-1	-5.75	-1	3.75	0	-2
F	-2	2	-1	-9.5	-1	3.75	0	-2
G	-1	3	-1	-5.75	-1	3.75	0	-2
A	1	1	1	1.75	1	3.75	0	-2

## Representación gráfica - ejemplo



## Teorema de Convergencia del Perceptrón

Si existe una transformación capaz de realizar:


$$T : \mathcal{R}^n \rightarrow \mathcal{R}^m$$

para toda muestra de aprendizaje, entonces el algoritmo convergerá a una solución en un número finito de pasos. Es posible que esta solución sea diferente de la inicialmente supuesta.

## Aprendizaje del Adaline

La respuesta de la red es:  $y_i^p = \sum_{j=1}^n w_{ij} x_j^p + \Theta_i$

- Aplicación del método de mínimos cuadrados
  - Distribuye el error para su minimización:
    - Problemas con puntos aislados
    - Malos resultados en clasificación



## Regla Delta (I)

- Error cuadrático medio por muestra (p):

$$E^p = \frac{1}{2} (\bar{d}^p - \bar{y}^p)^2 = \frac{1}{2} \sum_{i=1}^m (d_i^p - y_i^p)^2$$

- El error total será:  $E = \sum_p E^p$
- La modificación de pesos se basa en el algoritmo del gradiente muestra a muestra aplicado a  $E^p$ .

$$\Delta_p w_{ij} = -\gamma \frac{\partial E^p}{\partial w_{ij}}$$

## Regla Delta (II)

- Aplicación de la regla de la cadena:

$$\frac{\partial E^p}{\partial w_{ij}} = \frac{\partial E^p}{\partial y_i^p} \frac{\partial y_i^p}{\partial w_{ij}}$$


$$\frac{\partial E^p}{\partial y_i^p} = -(d_i^p - y_i^p) = -\delta_i^p \quad \frac{\partial y_i^p}{\partial w_{ij}} = x_j^p$$

$$\Delta_p w_{ij} = \gamma \delta_i^p x_j^p$$

## Problema del XOR (I)

- No es separable linealmente: una sola recta


$x_1$	$x_2$	$d$
-1	-1	-1
-1	1	1
1	-1	1
1	1	-1



- Minsky y Papert sugirieron una separación mediante combinación de varias rectas

## Problema del XOR (II)

- Se propone añadir una neurona oculta



$x_1$	$x_2$	$u'$	$y'$	$u$	$y$	$d$
-1	-1	-2.5	-1	-0.5	-1	-1
-1	1	-0.5	-1	1.5	1	1
1	-1	-0.5	-1	1.5	1	1
1	1	1.5	1	-0.5	-1	-1