


Procesamiento Digital de Imágenes

Pablo Roncagliolo B.
Nº 21



Redes Neuronales



prb@2007

2

Redes Neuronales Básicas




➤ Células de McCulloch&Pitts

➤ El Perceptrón

➤ ADALINE

➤ El Perceptrón Multicapa



prb@2007


3

Celulas de McCulloch-Pitts



➤ 1943. Fueron un modelo simplificado del funcionamiento de las neuronas del cerebro.

➤ Cada célula puede tener dos estados de salida, 0 ó 1.



prb@2007


4

Celulas de McCulloch-Pitts



➤ Las células operan en lapsos discretos.

➤ Una red neuronal de células de McCulloch-Pitts tiene la capacidad de computo universal. Es decir, cualquier estructura que pueda ser programada en un computador, puede ser modelada con este tipo de redes.



➤ Sin embargo, el tamaño de estas redes para problemas complejos es muy elevado. Además el método de aprendizaje para redes muy grandes no es apropiado.


prb@2007

5

Celulas de McCulloch-Pitts



➤ Ejemplo: NOT



x_1	$\sum x_i w_i$	S
0	0	1
1	-1	0


prb@2007

6

Celulas de McCulloch-Pitts



➤Ejemplo: AND



x_1	x_2	$\sum x_i w_i$	S
0	0	0	0
0	1	1	0
1	0	1	0
1	1	2	1


prb@2007

7

Celulas de McCulloch-Pitts



➤Ejemplo: OR



x_1	x_2	$\sum x_i w_i$	S
0	0	0	0
0	1	1	1
1	0	1	1
1	1	2	1


prb@2007

8

Celulas de McCulloch-Pitts



➤ XOR ??? Con una celula no es posible.



x_1	x_2	$\sum x_i w_i$	S
0	0		0
0	1		1
1	0		1
1	1		0

prb@2007

9


El Perceptrón



➤ Rosenblat generalizó las células de McCulloch-Pitts

➤ Se concibió como un sistema capaz de realizar tareas de clasificación de forma automática.

➤ La idea era disponer de un sistema que a partir de un conjunto de ejemplos (patrones) de clases diferentes, fuera capaz de determinar las ecuaciones de las superficies que hacían de frontera de dichas clases.



$$y' = \sum_{i=1}^n w_i x_i$$

$$y = F(y', \sigma)$$

$$F(s, \sigma) = \begin{cases} 1 & \text{si } s > \sigma \\ -1 & \text{en caso contrario} \end{cases}$$

prb@2007

10

El Perceptrón



➤ Se puede expresar la misma ecuación considerando SIGMA como parte de la sumatoria de entrada a la función:

$$y = F\left(\sum_{i=1}^n w_i x_i + \sigma\right)$$

$$F(s, \sigma) = \begin{cases} 1 & \text{si } s > 0 \\ -1 & \text{en caso contrario} \end{cases}$$

➤ Ej. Para dos entradas:

$$y = F(w_1 x_1 + w_2 x_2 + \sigma)$$

➤ Se observa que el umbral que separa las dos respuestas de la red 1 y -1, corresponde a una recta con pendiente $-w_1/w_2$ e intercepto $-\sigma/w_2$


prb@2007

11

El Perceptrón



➤ Gráficamente, la separación de las dos clases:




prb@2007

12

El Perceptrón

➤ En el caso general sería:



➤ Dado el conjunto de puntos $A=(a_1, a_2, \dots, a_n)$ y $B=(b_1, b_2, \dots, b_n)$. Obtener el conjunto $W=(w_1, w_2, \dots, w_n)$ tal que:

$$\forall \vec{a} \in A: w_1 a_1 + \dots + w_n a_n + \sigma > 0$$

y

$$\forall \vec{b} \in B: w_1 b_1 + \dots + w_n b_n + \sigma > 0$$

➤ Esta es la base del aprendizaje del PERCEPTRON.

prb@2007

13

El Perceptrón

➤ El proceso de aprendizaje:

Sea:

$$d(x) = \text{clase del vector } x = \begin{cases} 1 \\ -1 \end{cases}$$

➤ **PASO 0:** Comenzar con valores aleatorios para pesos y umbral.

➤ **PASO 1:** Seleccionar un ejemplo X del conjunto de entrenamiento.

➤ **PASO 2:** Si $y \neq d(x)$, modificar w_i de acuerdo con:

$$\Delta w_i = d(x) x_i$$

➤ **PASO 3:** Si no se ha cumplido el criterio de finalización, volver a **1**

prb@2007

14



El Perceptrón



➤ El proceso de aprendizaje:

$$\Delta w_i = d(x)x_i$$

➤ Se observa que si la salida $y=d(x)=1$ para un vector x de clase -1 , entonces

$$\Delta w_i = -x_i$$

➤ El delta W es proporcional al nodo de entrada y en la dirección de clasificación del vector x .

prb@2007

15

El Perceptrón

$$y = F(w_1x_1 + w_2x_2 + \sigma)$$

$$F(s, \sigma) = \begin{cases} 1 & \text{si } s > 0 \\ -1 & \text{en caso contrario} \end{cases}$$

1




➤ Ejemplo: AND

x_1	x_2	AND
0	0	0(A)
1	0	0(A)
0	1	0(A)
1	1	1(B)

Patron	Salida	Clasifica
(0,0 0)	+1	Mal

Actualizo pesos



$$\Delta w_i = d(x)x_i$$

$$w_1 = w_1 + \Delta w_1 = 1 + (-1) * 0 = 1$$

$$w_2 = w_2 + \Delta w_2 = 1 + (-1) * 0 = 1$$

$$w_0 = w_0 + \Delta w_0 = 0.5 + (-1) * 1 = -0.5$$

prb@2007

16

El Perceptrón

$$y = F(w_1x_1 + w_2x_2 + \sigma)$$

$$F(s, \sigma) = \begin{cases} 1 & \text{si } s > 0 \\ -1 & \text{en caso contrario} \end{cases}$$


2



➤ Ejemplo: AND

x_1	x_2	AND
0	0	0(A)
1	0	0(A)
0	1	0(A)
1	1	1(B)

Patron	Salida	Clasifica
(0,1 0)	+1	Mal



$$\Delta w_i = d(x)x_i$$

$$w_1 = w_1 + \Delta w_1 = 1 + (-1) * 0 = 1$$

$$w_2 = w_2 + \Delta w_2 = 1 + (-1) * 1 = 0$$

$$w_0 = w_0 + \Delta w_0 = -0.5 + (-1) * 1 = -1.5$$

prb@2007

17

El Perceptrón


3



➤ Ejemplo: AND

x_1	x_2	AND
0	0	0(A)
1	0	0(A)
0	1	0(A)
1	1	1(B)

Patron	Salida	Clasifica
(1,0 0)	-1	Bien
(1,1 1)	-1	Mal



$$\Delta w_i = d(x)x_i$$

$$w_1 = w_1 + \Delta w_1 = 1 + (+1) * 1 = 2$$

$$w_2 = w_2 + \Delta w_2 = 0 + (+1) * 1 = 1$$

$$w_0 = w_0 + \Delta w_0 = -1.5 + (+1) * 1 = -0.5$$

prb@2007

18

El Perceptrón


4



➤ Ejemplo: AND

x_1	x_2	AND
0	0	0(A)
1	0	0(A)
0	1	0(A)
1	1	1(B)

Patron	Salida	Clasifica
(1,1 1)	+1	Bien
(0,0 0)	-1	Bien
(0,1 0)	+1	Mal



$$\Delta w_i = d(x)x_i$$

$$w_1 = w_1 + \Delta w_1 = 2 + (-1) * 0 = 1$$

$$w_2 = w_2 + \Delta w_2 = 1 + (-1) * 1 = 0$$

$$w_0 = w_0 + \Delta w_0 = -0.5 + (-1) * 1 = -1.5$$

prb@2007

19

El Perceptrón


5



➤ Ejemplo: AND

x_1	x_2	AND
0	0	0(A)
1	0	0(A)
0	1	0(A)
1	1	1(B)

Patron	Salida	Clasifica
(1,0 0)	+1	Mal



$$\Delta w_i = d(x)x_i$$

$$w_1 = w_1 + \Delta w_1 = 1 + (-1) * 1 = 0$$

$$w_2 = w_2 + \Delta w_2 = 0 + (-1) * 0 = 0$$

$$w_0 = w_0 + \Delta w_0 = -1.5 + (-1) * 1 = -2.5$$

prb@2007

20

El Perceptrón


6



➤ Ejemplo: AND

x_1	x_2	AND
0	0	0(A)
1	0	0(A)
0	1	0(A)
1	1	1(B)

Patron	Salida	Clasifica
(1,1 1)	-1	Mal



$$\Delta w_i = d(x)x_i$$

$$w_1 = w_1 + \Delta w_1 = 0 + (+1) \cdot 1 = 1$$

$$w_2 = w_2 + \Delta w_2 = 0 + (+1) \cdot 1 = 1$$

$$w_0 = w_0 + \Delta w_0 = -2.5 + (+1) \cdot 1 = -1.5$$

prb@2007

21

El Perceptrón



7



➤ Ejemplo: AND

x_1	x_2	AND
0	0	0(A)
1	0	0(A)
0	1	0(A)
1	1	1(B)

Patron	Salida	Clasifica
(0,0 0)	-1	Bien
(0,1 0)	-1	Bien
(1,0 0)	-1	Bien
(1,1 1)	+1	Bien



prb@2007

$$x_1 \cdot 1 + x_2 \cdot 1 - 1.5 = 0$$

⇒

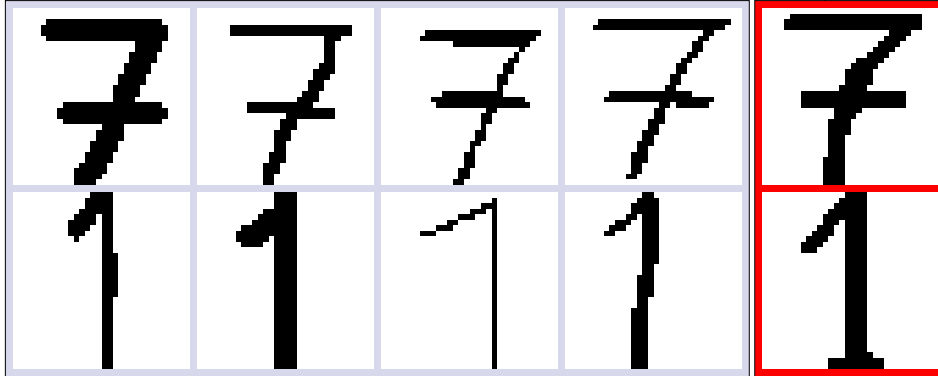
$$x_2 = -x_1 - 1.5$$

22

El Perceptrón



➤ Ejemplo práctico...



Set de ejemplos durante el entrenamiento

prb@2007

Ejemplos fuera del entrenamiento para verificar capacidad de generalización

23

El Perceptrón



➤ Paso 1

Respuestas correctas para los 8 ejemplos de entrenamiento

```
clear;

map1=(0:255)/255;
map=[map1' map1' map1'];
figure(1);
COLORMAP(map);

CLASE=[1 1 1 1 -1 -1 -1 -1];

PESOS=rand(1,1024);
UMB=rand(1,1);
```

$$y = F\left(\sum_{i=1}^n w_i x_i + \sigma\right)$$

prb@2007

24

El Perceptrón

El ciclo while se debería realizar hasta que todos los ejemplos sean clasificados correctamente de manera consecutiva.

➤ Paso 1

Lee imagen 32x32 →

Transforma en vector de 1024 →

$$y = F\left(\sum_{i=1}^n w_i x_i + \sigma\right)$$

```
index=1;
i=0;
while i<200
    A=double(imread(['f' num2str(index) '.bmp']));
    subplot(2,1,1); image(A);

    CAPA_ENTRADA=[];
    for f=1:32, CAPA_ENTRADA=[CAPA_ENTRADA A(f,:)];end;

    Y=sum(CAPA_ENTRADA.*PESOS+UMB);
    if (Y>0 & CLASE(index)<0) | (Y<0 & CLASE(index)>0)
        disp('ERROR')
        PESOS=PESOS+CLASE(index)*CAPA_ENTRADA;
        UMB=UMB+CLASE(index);
    end;

    index=index+1;
    if index>8, index=1; end;
    i=i+1;
end;
```

$$w_i = w_i + \Delta w_i = w_i + d(x)x_i$$

25

El Perceptrón → ADALINE

➤ ADALINE (ADAPtive LInear NEuron): Neuron Lineal Adaptativa

- La salida del perceptrón en binaria.
- La regla de aprendizaje del perceptrón no mide el grado de "error".
- Widrow & Hoff, 1960 proponen ADALINE.
 - Consiste simplemente en una transformación que permite adaptar una entrada X a una salida Y.

$$\vec{y} = \sum_{i=1}^n w_i x_i + \sigma$$

prb@2007

26

ADALINE



➤ La regla de aprendizaje de ADALINE considera el error entre la salida lograda **y** versus la salida deseada **d**

$$|\vec{d} - \vec{y}|$$

➤ Esta regla se conoce como REGLA DELTA

$$\Delta w_i = \alpha \sum_{\forall p} (d_p - y_p) x_i$$

➤ La constante α se denomina TASA DE APRENDIZAJE

prb@2007

27

ADALINE



➤ Al igual que en el perceptrón los pasos son:

1. Inicializar los pesos en forma aleatoria
2. Introducir PATRON de entrada
3. Calcular salida Y, y obtener diferencia $\sum_{\forall p} (d_p - y_p)$
4. Para todos los pesos, multiplicar dicha diferencia por la entrada correspondiente y ponderarla por la tasa α
5. Actualizar todos los pesos $w_i = w_i + \Delta w_i$
6. Si no se ha cumplido el criterio de convergencia, regresar a 2. Si se han acabado todos los patrones, empezar de nuevo a introducir patrones.

prb@2007

28

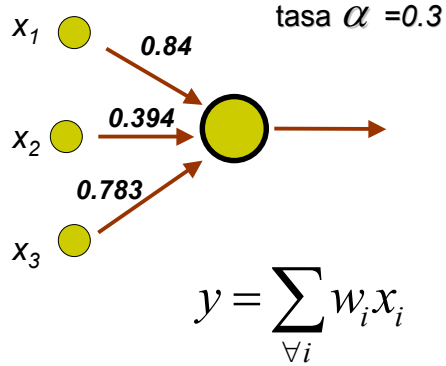
ADALINE

0



➤ Ejemplo: Decodificador Binario a Decimal

0	0	1	[1]
0	1	0	[2]
0	1	1	[3]
1	0	0	[4]
1	0	1	[5]
1	1	0	[6]
1	1	1	[7]



prb@2007

29

ADALINE

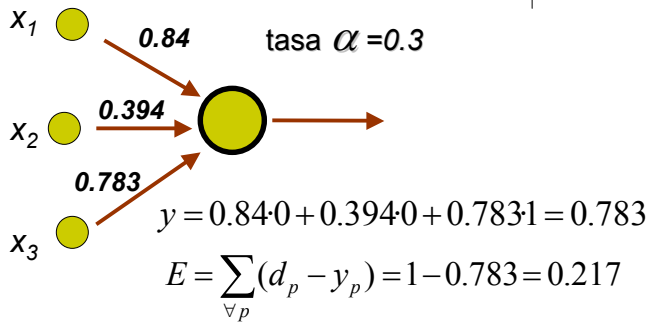
1



➤ Ejemplo: Decodificador Binario a Decimal

➔

0	0	1	[1]
0	1	0	[2]
0	1	1	[3]
1	0	0	[4]
1	0	1	[5]
1	1	0	[6]
1	1	1	[7]



$$w_1 = w_1 + \alpha E \cdot x_1 = 0.84$$

$$w_2 = w_2 + \alpha E \cdot x_2 = 0.394$$

$$w_3 = w_3 + \alpha E \cdot x_3 = 0.783 + 0.3 \cdot 0.217 \cdot 1 = 0.848$$

prb@2007


30

ADALINE

2



➤ Ejemplo: Decodificador Binario a Decimal



$$w_1 = w_1 + \alpha \cdot E x_1 = 0.84$$

$$w_2 = w_2 + \alpha \cdot E x_2 = 0.394 + 0.3 \cdot 1.61 \cdot 1 = 0.876$$

$$w_3 = w_3 + \alpha \cdot E x_3 = 0.848$$

prb@2007


31

ADALINE

7



➤ Ejemplo: Decodificador Binario a Decimal



**Resultado
despues de la
primera iteración
del
entrenamiento**

$$w_1 = w_1 + \alpha E \cdot x_1 = 3.09 + 0.3 \cdot 0.12 = 3.126$$

$$w_2 = w_2 + \alpha E \cdot x_2 = 1.966 + 0.3 \cdot 0.12 = 2.002$$

$$w_3 = w_3 + \alpha E \cdot x_3 = 1.825 + 0.3 \cdot 0.12 = 1.861$$

32

ADALINE



- Ejemplo: visualización de los pesos según iteraciones..

<i>Iteración</i>	<i>Pesos</i>		
1	3.12	2.00	1.86
2	3.61	1.98	1.42
3	3.82	1.98	1.2
4	3.92	1.98	1.1
5	3.96	1.99	1.02
6	3.99	2.00	1.01
7	4.00	2.00	1.00
8	4.00	2.00	1.00
9	4.00	2.00	1.00
10	4.00	2.00	1.00

> La tasa de aprendizaje α también puede ser adaptativa.

> Por ejemplo al inicio el valor puede ser alto, para dar “grandes pasos” de corrección del error y para salir de mínimos locales.

> Sin embargo al final del entrenamiento debe disminuir para hacer correcciones finas.

prb@2007

33

Sin embargo...




- El uso del Perceptrón o de las redes ADALINE permite aproximar de manera fácil, cualquier tipo de función o sistemas, sólo conociendo un conjunto de ejemplos.
- De esta manera cualquier sistema (caja negra), se puede representar por una red.
- Sin embargo, después de la década del 50 se demostró que estas técnicas poseen grandes limitaciones.
- Un ejemplo clásico es el OR Exclusivo.
- **CONCLUSION: éstas técnicas sólo pueden resolver sistemas donde los ejemplos son linealmente separables.**

prb@2007

34

Sin embargo...


- OR Exclusivo.



- El Perceptrón o ADALINE nunca convergen!!

- Solución: varias redes en cascada ➔ complejidad!!

prb@2007



35

Sin embargo...

Estructura	Regiones de Decisión	Problema de la XOR	Clases con Regiones Mezcladas	Formas de Regiones más Generales
1 Capa 	Medio Plano Limitado por un Hiperplano			
2 Capas 	Regiones Cerradas o Convexas			
3 Capas 	Complejidad Arbitraria Limitada por el Número de Neuronas			

prb@2007

36

Perceptrón Multicapa



- Corresponde a una generalización del Perceptrón y Adaline
- 1969, Minsky & Papert mostraron que el uso de varios perceptrones simples (neuronas ocultas) puede ser una solución para problemas no lineales. Sin embargo no dejaron en claro como se puede entrenar (ajustar los pesos ocultos)
- 1986, Rumelhart & ..., presentó un método para retropropagar el error medido en la salida hacia las neuronas ocultas. Se denomina REGLA DELTA GENERALIZADA.
- 1989, Cybenko, Hornik, han demostrado que el Perceptrón Multicapa es un aproximador universal. Cualquier función continua sobre R^n , puede ser aproximada, con al menos una capa oculta.

prb@2007

37


Perceptrón Multicapa



- El Perceptrón Multicapa: puede aprender a partir de ejemplos, aproximar relaciones no lineales, filtrar ruido, modelar sistemas...
- Con éxito ha sido aplicado a:
 - Reconocimiento del habla (Cohen, 93)
 - Reconocimiento de caracteres (Sackinger, 92)
 - Reconocimiento de caracteres escritos (Guyon, 91)
 - Control de Procesos (Werbos, 89)
 - Modelamiento de Sistemas Dinámicos (Narendra, 90)
 - Conducción de vehículos (Pomerleau, 92)
 - Diagnósticos médicos (Baxt, 92)
 - Predicción de Series Temporales (Weigend, 90)
 - Etc...

Perceptrón Multicapa


- Arquitectura:
 - CAPA DE ENTRADA
 - CAPAS OCULTAS
 - CAPA DE SALIDA
- Todas las neuronas transmiten información hacia delante: se denominan redes **feedforward**
- Cada neurona posee un umbral independiente. Se considera como una entrada más cuya entrada es 1.
- Generalmente se utilizan redes completamente conectadas
- Función de activación de las neuronas: sigmoideal, hiperbólica.




39

Perceptrón Multicapa

- Función de activación de las neuronas: sigmoideal, hiperbólica → son equivalentes ($f_2=2f_1-1$)



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



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

La derivada de la f. Sigmoideal es: $f(x)' = f(x)(1-f(x))$

prb@2007

40

Perceptrón Multicapa



➤ Algoritmo BACKPROPAGATION:

➤ Cada neurona de salida distribuye hacia atrás su error δ a las neuronas ocultas que se conectan a ella, ponderado por el valor de la conexión.

➤ Cada neurona oculta recibe un δ de cada neurona de salida. La suma de estas es el término δ de la neurona oculta.

➤ Se repite el proceso hacia atrás... Por ello el nombre "retropropagación del error".

prb@2007

41

Perceptrón Multicapa




➤ Algoritmo BACKPROPAGATION:

➤ Pesos de la capa oculta 1, y umbrales de la capa de salida:

$$w_{ji} = w'_{ji} + \alpha \cdot \delta_i \cdot x_j$$

$$u_i = u'_i + \alpha \cdot \delta_i$$

$$\delta_i = (s_i - y_i) \cdot y_i \cdot (1 - y_i)$$



prb@2007

42

Perceptrón Multicapa


➤ Algoritmo BACKPROPAGATION:

➤ Pesos de la capa entrada, y umbrales de la capa de salida:

$$w_{kj} = w'_{kj} + \alpha \cdot \delta_j \cdot x_k$$

$$u_j = u'_j + \alpha \cdot \delta_j$$

$$\delta_j = x_j (1 - x_j) \sum_{\forall i} w_{ji} \delta_i$$



prb@2007

43

Perceptrón Multicapa

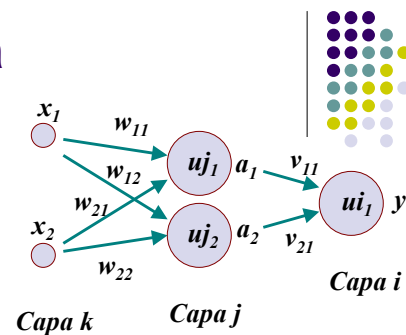
➤ Ejemplo: XOR

$$v_{11} = v'_{11} + \alpha \cdot \delta^i \cdot a_1$$

$$v_{12} = v'_{12} + \alpha \cdot \delta^i \cdot a_2$$

$$ui_1 = ui'_1 + \alpha \cdot \delta^i$$

$$\delta^i = (s - y) \cdot y \cdot (1 - y)$$



➤ TAREA: Implementar esta pregunta de prueba.

prb@2007

$$w_{11} = w'_{11} + \alpha \cdot \delta_1^j \cdot x_1$$

...

$$uj_1 = uj'_1 + \alpha \cdot \delta_1^j$$

$$\delta_1^j = a_1 (1 - a_1) \sum_{\forall i} v_{1i} \delta^i$$

44