

2. Perceptron

Prof. Renato Tinós

Depto. de Computação e Matemática (FFCLRP/USP)

2. Perceptron

2.1. Introdução

2.2. Funcionamento do perceptron

2.3. Aprendizado

2.4. Teorema da convergência

2.5. Alguns aspectos do problema de reconhecimento de padrões

2.3. Aprendizado

- Suponha que as variáveis de entrada se originem de duas classes C_1 e C_2 **linearmente separáveis**
- O problema do aprendizado do *perceptron* (treinamento) consiste em encontrar um conjunto de pesos e bias que definem um hiperplano que separe linearmente os vetores de entrada das classes C_1 e C_2
 - Isto é, um vetor de pesos w e um bias w_0 tal que
$$\begin{cases} \mathbf{w}^T \mathbf{x} + w_0 > 0 & , \text{ para todo } \mathbf{x} \text{ pertencente à classe } C_1 \\ \mathbf{w}^T \mathbf{x} + w_0 \leq 0 & , \text{ para todo } \mathbf{x} \text{ pertencente à classe } C_2 \end{cases} \quad (2.12)$$

2.3. Aprendizado

- Para isso, um conjunto com padrões para o treinamento do *perceptron* é definido
 - Conjunto de treinamento T
 - » Conjunto de pares entrada $x(n)$ e saída desejada $d(n)$
- O conjunto de treinamento T é composto por dois subconjuntos
 - T_1 composto por vetores de entrada que pertencem à classe C_1
 - T_2 composto por pares entrada que pertencem à classe C_2

2.3. Aprendizado

- Antes de apresentarmos a estratégia de treinamento, vamos definir o padrão de treinamento e o vetor de pesos na n -ésima iteração do algoritmo como

$$\mathbf{x}(n) = \begin{bmatrix} +1 \\ x_1(n) \\ x_2(n) \\ \vdots \\ M \\ x_m(n) \end{bmatrix} \quad \mathbf{w}(n) = \begin{bmatrix} w_0(n) \\ w_1(n) \\ w_2(n) \\ \vdots \\ M \\ w_m(n) \end{bmatrix} \quad (2.13)$$

- Note que o bias agora é visto como um peso
- A saída do k -ésimo neurônio será dada por

$$y_k(n) = \varphi(u_k(n)) = \varphi(\mathbf{w}(n)^T \mathbf{x}(n)) \quad (2.14)$$

2.3. Aprendizado

- **Estratégia de aprendizado para duas classes**

1. Se o padrão de treinamento $\mathbf{x}(n)$ é corretamente classificado utilizando-se o vetor de pesos $\mathbf{w}(n)$ calculado na n -ésima iteração do algoritmo, então o vetor de pesos não é corrigido. Ou seja,

$$\begin{cases} \mathbf{w}(n+1) = \mathbf{w}(n) & , \text{ se } \mathbf{w}(n)^T \mathbf{x}(n) > 0 \text{ e } \mathbf{x}(n) \text{ pertence à classe } C_1 \\ \mathbf{w}(n+1) = \mathbf{w}(n) & , \text{ se } \mathbf{w}(n)^T \mathbf{x}(n) \leq 0 \text{ e } \mathbf{x}(n) \text{ pertence à classe } C_2 \end{cases}$$

(2.15)

2.3. Aprendizado

- **Estratégia de aprendizado**

2. Caso contrário, o vetor de pesos é atualizado de acordo com

$$\begin{cases} \mathbf{w}(n+1) = \mathbf{w}(n) - \eta(n) \mathbf{x}(n) & , \text{ se } \mathbf{w}(n)^T \mathbf{x}(n) > 0 \text{ e } \mathbf{x}(n) \text{ pertence à classe } C_2 \\ \mathbf{w}(n+1) = \mathbf{w}(n) + \eta(n) \mathbf{x}(n) & , \text{ se } \mathbf{w}(n)^T \mathbf{x}(n) \leq 0 \text{ e } \mathbf{x}(n) \text{ pertence à classe } C_1 \end{cases} \quad (2.16)$$

na qual $\eta(n)$ é a **taxa de aprendizagem**, que controla o ajuste aplicado ao vetor de pesos na iteração n .

Se $\eta(n) = \eta > 0$, na qual η é uma constante, temos uma **regra de adaptação com incremento fixo** para o perceptron.

2.3. Aprendizado

- Usando-se a função sinal como ativação e considerando a taxa de aprendizagem fixa, podemos simplificar a regra de ajuste de pesos através de

$$\mathbf{w}(n+1) = \mathbf{w}(n) + \eta [d(n) - y(n)] \mathbf{x}(n) \quad (2.17)$$

na qual

$$y(n) = \varphi(\mathbf{w}(n)^T \mathbf{x}(n)) = \begin{cases} +1 & \text{se } \mathbf{w}(n)^T \mathbf{x}(n) > 0 \\ -1 & \text{se } \mathbf{w}(n)^T \mathbf{x}(n) \leq 0 \end{cases}$$
$$d(n) = \begin{cases} +1 & , \text{ se } \mathbf{x}(n) \text{ pertence à classe } C_1 \\ -1 & , \text{ se } \mathbf{x}(n) \text{ pertence à classe } C_2 \end{cases} \quad (2.18)$$

2.3. Aprendizado

- **Regra de adaptação com incremento fixo**
 - Proposta por Rosenblatt em 1958
 - Guarda uma certa semelhança com a Regra Delta
 - » A Regra Delta utiliza o conceito do gradiente descendente do erro médio quadrático

2.3. Aprendizado

Algoritmo perceptron ($\mathbf{X}_T$, $\mathbf{d}_T$, η)

// inicialização dos pesos

$\mathbf{w} \leftarrow \mathbf{0}$

$n \leftarrow 1$

faça

// ativação do neurônio (saída)

$y(n) \leftarrow \varphi(\mathbf{w}^\top \mathbf{x}(n))$

// ajuste de pesos

$\mathbf{w} \leftarrow \mathbf{w} + \eta [d(n) - y(n)] \mathbf{x}(n)$

$n \leftarrow n+1$

enquanto (erro na classificação não é aceitável)

2.3. Aprendizado

- **No algoritmo anterior,**

- O conjunto de treinamento T tem N padrões. Ou seja

$$\mathbf{X}_T = \begin{bmatrix} \mathbf{x}_1^T \\ M \\ \mathbf{x}_N^T \end{bmatrix} \quad \mathbf{d}_T = \begin{bmatrix} d_1 \\ M \\ d_N \end{bmatrix} \quad (2.19)$$

- O vetor de entradas $\mathbf{x}(n)$ e a saída desejada $d(n)$ podem ser obtidas a partir de $\mathbf{X}_T$ e $\mathbf{d}_T$ através de

$$\mathbf{x}(n) = \mathbf{x}_t \quad , \quad d(n) = d_t$$

na qual $t = \text{mod}(n-1, N) + 1$

- O erro é dado por

$$e(n) = d(n) - y(n) \quad (2.20)$$


2.3. Aprendizado

- **Escolha da taxa de aprendizagem η**
 - Deve se restringir ao intervalo $0 < \eta \leq 1$
 - η baixa:
 - » adaptação mais lenta
 - » a mudança dos pesos é mais estável
 - η alta:
 - » adaptação mais rápida
 - » a mudança dos pesos é menos estável

2.3. Aprendizado

Exemplo 2. Treine o *perceptron* para o problema de classificação da função AND

Padrão	x_1	x_2	Classe	d
1	0	0	C_1	1
2	0	1	C_1	1
3	1	0	C_1	1
4 (N)	1	1	C_2	-1




2.3. Aprendizado

Exemplo 2. função AND

- Taxa de aprendizagem

» $\eta = 0,01$

Pesos



Columns 1 through 8

0	0.0200	0.0200	0.0200	0	0.0200	0.0400	0.0400
0	0	0	0	-0.0200	-0.0200	-0.0200	-0.0200
0	0	0	0	-0.0200	-0.0200	0	0

Columns 9 through 16

0.0200	0.0200	0.0400	0.0600	0.0400	0.0400	0.0400	0.0600
-0.0400	-0.0400	-0.0400	-0.0200	-0.0400	-0.0400	-0.0400	-0.0200
-0.0200	-0.0200	0	0	-0.0200	-0.0200	-0.0200	-0.0200


Columns 17 through 19

0.0400	0.0400	0.0600
-0.0400	-0.0400	-0.0400
-0.0400	-0.0400	-0.0200

2.3. Aprendizado


Exemplo 2. função AND

Iteração 18: Erro médio quadrático = 0



2.3. Aprendizado

Exemplo 2.3.



2.3. Aprendizado

Exercício 2.1. Treine o *perceptron* para o problema de classificação da função OR

Padrão	x_1	x_2	Classe	d
1	0	0	C_1	1
2	0	1	C_2	-1
3	1	0	C_2	-1
4(N)	1	1	C_2	-1

2.3. Aprendizado

- **A convergência da regra de adaptação com incremento fixo para o *perceptron* pode ser provada**
 - As provas de convergência são em geral apresentadas para η igual a 1
 - O valor de η não é importante, desde que seja positivo
 - » Valores de η diferentes de 1 meramente escalam os vetores de entrada sem afetar sua separabilidade

2.4. Teorema da Convergência

- **Teorema da Convergência para a regra de adaptação com incremento fixo**

Sejam os subconjuntos de vetores de treinamento T_1 e T_2 linearmente separáveis. Suponha que as entradas apresentadas ao perceptron se originem destes dois subconjuntos. O perceptron converge após n_o iterações, significando que

$$\mathbf{w}(n_o) = \mathbf{w}(n_o+1) = \mathbf{w}(n_o+2) = \dots$$

é a solução para $n_o \leq n_{max}$.

Prova: ver [HAYKIN, 2001], Seção 3.1, p. 163-169.


2.5. Alguns Aspectos do Problema de Reconhecimento de Padrões

Exemplo 2.3. Problema de classificação da função XOR

Padrão	x_1	x_2	Classe	d
1	0	0	C_2	-1
2	0	1	C_1	1
3	1	0	C_1	1
4 (N)	1	1	C_2	-1

2.5. Alguns Aspectos do Problema de Reconhecimento de Padrões

Exemplo 2.3. Problema de classificação da função XOR



2.5. Alguns Aspectos do Problema de Reconhecimento de Padrões

- O *perceptron* não consegue resolver problemas de classificação que não são **linearmente separáveis**
 - Exemplo: função XOR
 - Este problema advém do fato de cada *perceptron* gerar apenas um hiperplano (e conseqüentemente uma FD)
 - É possível gerar mais de um hiperplano se utilizarmos mais de um *perceptron* (neurônio) em uma única camada
 - » No entanto, ainda teríamos o problema de como associar as diferentes regiões produzidas pelas FD com as diferentes classes
 - Então, como seria possível resolver este problema?

- **Referências**

- Haykin, S. S.. *Redes neurais: princípios e prática*. 2ª ed., Bookman, 2001.
 - » Capítulo 3
- Príncipe, J. C.; Euliano, N. R. & Lefebvre, W. C. *Neural and Adaptive Systems: Fundamentals Through Simulations*. John Wiley & Sons, Inc. 2000
 - » Seções 3.1 – 3.3
- Braga, A.P.; Carvalho, C.P.L.F. & Ludermir, T.B.. *Redes neurais artificiais: Teoria e Aplicações*. LTC, 2000.
 - Capítulo 3