






Perceptrons e *Backpropagation*

Germano C. Vasconcelos
Centro de Informática - UFPE

Neurônio Natural




Neurônio McCulloch-Pitts



$$y = f_h \left[\sum_{i=1}^n w_i x_i - \theta \right]$$


Perceptrons



Reconhecimento de Padrões


Peso

▲ Bailarina
■ Halterofilista



Altura

Uma Visão Matemática do Perceptron



$$f(x) = \sum w_i \cdot x_i - \theta$$

$$f(x) = (|W| \cdot |X| \cos \Phi) - \theta$$

Considere o ponto onde

$$f(x) = 0:$$

$$w_1 \cdot x_1 + w_2 \cdot x_2 - \theta = 0$$



$$x_2 = -w_1/w_2 \cdot x_1 + \theta/w_2$$

$$(y = m \cdot x + c)$$

Aprendizagem no Perceptron

- Se um padrão é *corretamente* classificado

$W(t+1) = W(t)$ se $\sum w_i.x_i - \theta \geq 0$ e X pertence a C1

$W(t+1) = W(t)$ se $\sum w_i.x_i - \theta < 0$ e X pertence a C2

Se um padrão é *incorretamente* classificado

$W(t+1) = W(t) - \eta X$ se $\sum w_i.x_i - \theta \geq 0$ e X pertence a C2

$W(t+1) = W(t) + \eta X$ se $\sum w_i.x_i - \theta < 0$ e X pertence a C1

Características do Perceptron


Simple Operation

Convergence Guaranteed

Capaz de resolver apenas problemas
linearmente separáveis

Adaline (Adaptive Linear Neuron)

Bernard Widrow 1960



Beleza do Rio de Janeiro

Aprendizagem no Adaline

- $e_i = (d_i - y_i)$
- $C \text{ (custo)} = \frac{1}{2} \sum_p (d_i - y_i)^2$
- $W(t+1) = W(t) + \eta e X(t)$

(Regra de Widrow-Hoff)


Características do Adaline

Simple Operation

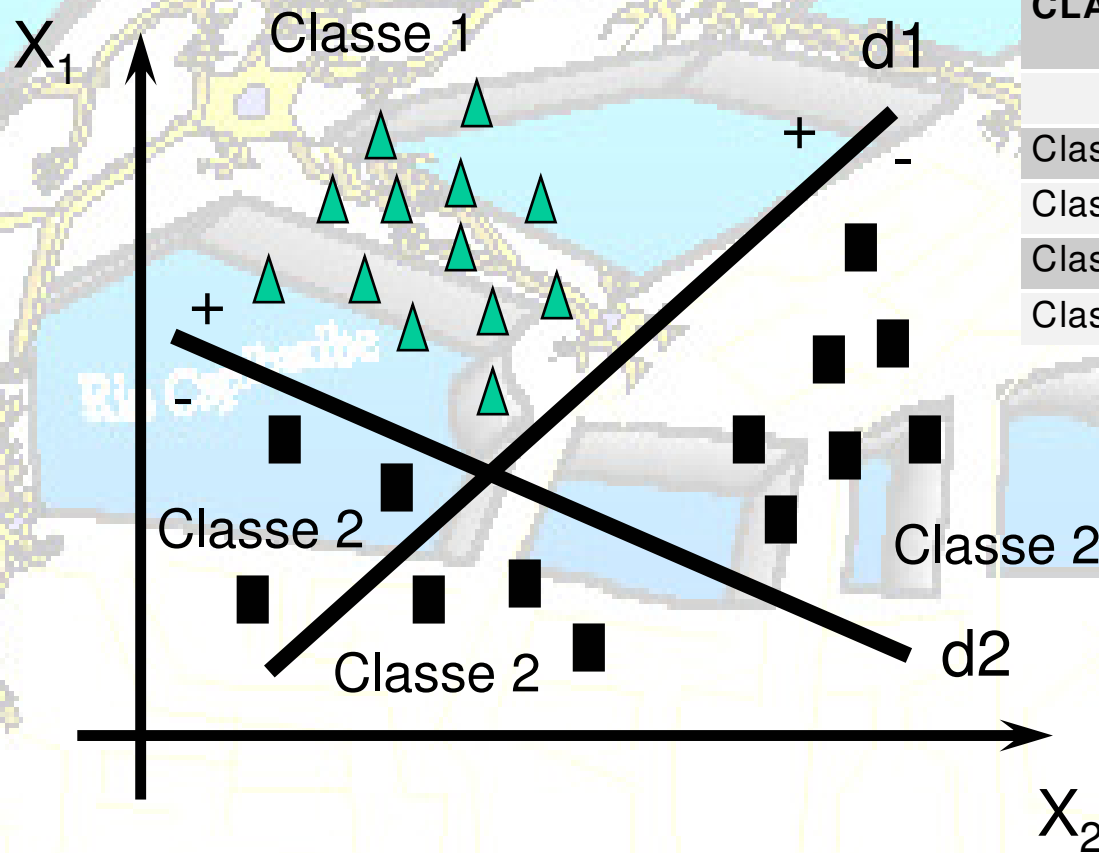
Convergence Guaranteed

Capaz de resolver apenas problemas
linearmente separáveis

Visualização do Treinamento

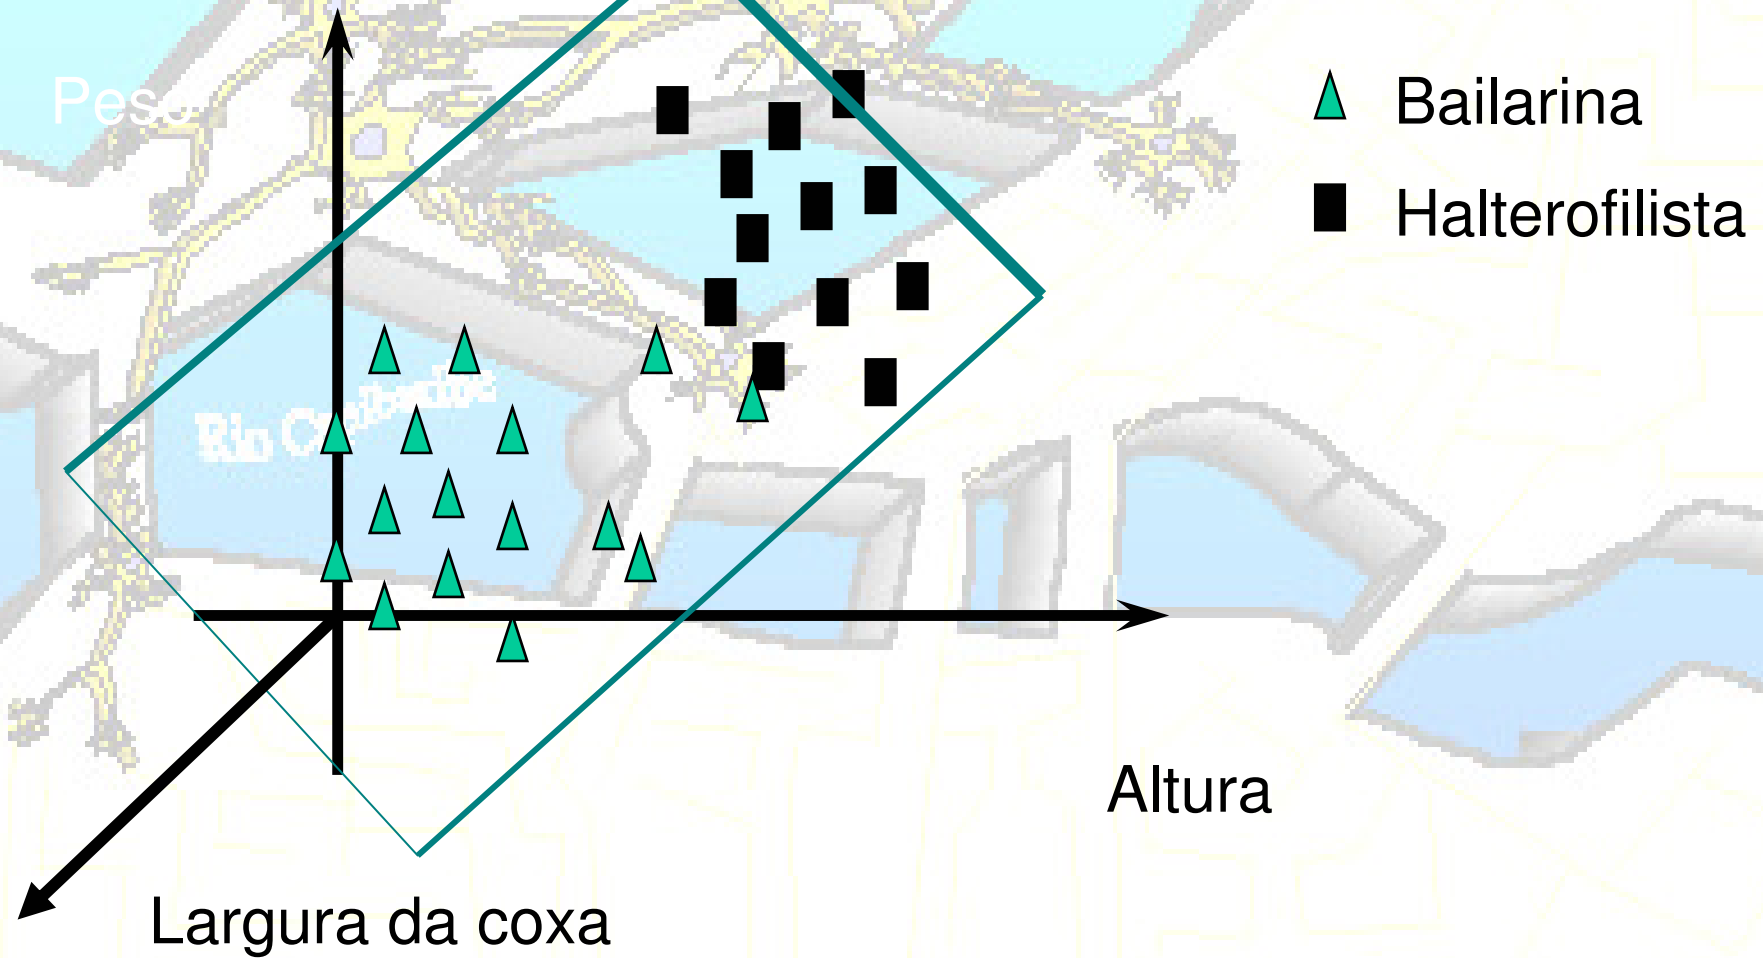


Classificadores lineares




CLASSIFICAÇÃO	SINAL DA LINHA DE DECISÃO	
	d1	d2
Classe 1	+	+
Classe 2	+	-
Classe 2	-	+
Classe 2	-	-


Classificadores Lineares




O Problema do Ou-exclusivo (XOR)



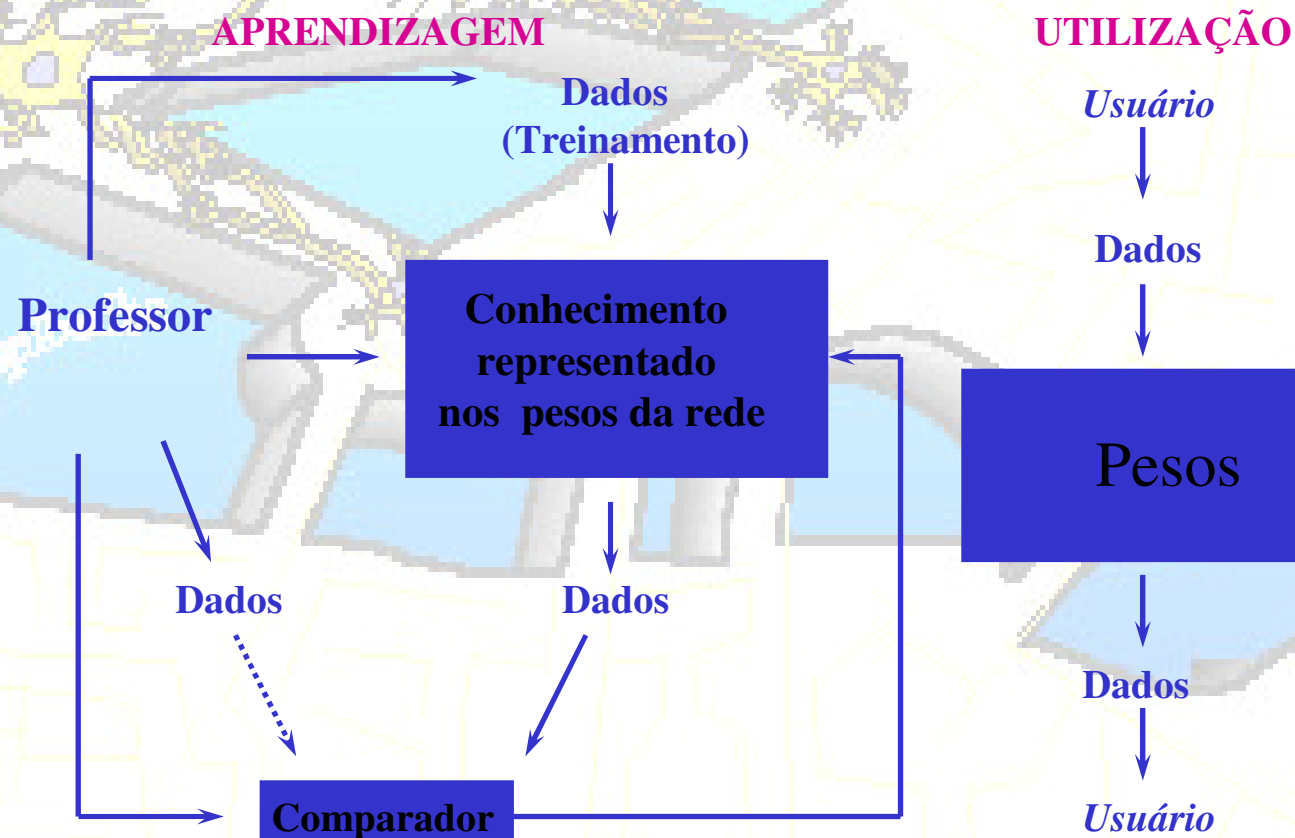
Solução para o XOR



Multilayer Perceptron (MLP) e Backpropagation



Funcionamento do MLP





Funcionamento do MLP

- Duas fases de operação
 - Passo para frente (*forward pass*)
 - Passo para trás (*backward pass*)
- Dado um conjunto de pares (X_p, Y_p) ,
construir um mapeamento $F(W; X_p) \Rightarrow Y_p$

Como construir $F(W; X_p) \Rightarrow Y_p$?

Regra Delta Generalizada ou Error-Back Propagation

O erro na camada de saída :

$$E_p = \frac{1}{2} \sum_{j=1}^n (t_{pj} - o_{pj})^2$$

Para minimizar o erro :

$$\Delta_p W_{ji} \propto - \frac{\partial E_p}{\partial W_{ji}}$$

$$\frac{\partial E_p}{\partial W_{ji}} = \frac{\partial E_p}{\partial net_{pj}} \frac{\partial net_{pj}}{\partial W_{ji}}$$

$$\frac{\partial net_{pj}}{\partial W_{ji}} = \frac{\partial}{\partial W_{ji}} \sum_k w_{jk} o_{pk} = o_{pi}$$

$$\delta_{pj} = - \frac{\partial E_p}{\partial net_{pj}} \longrightarrow - \frac{\partial E_p}{\partial W_{ji}} = \delta_{pj} o_{pi}$$

$$\Delta_p W_{ji} = \eta \delta_{pj} \cdot O_{pi}$$

$$\delta_{pj} = - \frac{\partial E_p}{\partial net_{pj}} = - \frac{\frac{\partial E_p}{\partial O_{pj}}}{\frac{\partial O_{pj}}{\partial net_p}}$$

$$\frac{\partial O_{pj}}{\partial net_{pj}} = f'_j(net_{pj})$$

$$\frac{\partial E_p}{\partial O_{pj}} \quad (2 \text{ casos precisam ser considerados!})$$

Primeiro caso : j é uma unidade de saída

$$\frac{\partial E_p}{\partial o_{pj}} = -(t_{pj} - o_{pj})$$
$$\delta_{pj} = (t_{pj} - o_{pj}) f_j'(net_{pj})$$

Segundo caso : j é uma unidade intermediária

$$\frac{\partial E_p}{\partial O_{pj}} = \sum_k \frac{\partial E_p}{\partial net_{pk}} \frac{\partial net_{pk}}{\partial o_{pj}}$$


$$\frac{\partial E_p}{\partial o_{pj}} = - \sum_k \frac{\partial E_p}{\partial net_{pk}} \frac{\partial}{\partial O_{pj}} \sum_i w_{ik} o_{pi}$$

$$\Rightarrow \frac{\partial E_p}{\partial o_{pj}} = - \sum \delta_{pk} w_{jk}$$

$$\delta_{pj} = f'_j(net_{pj}) \sum \delta_{pk} w_{jk}$$

E a função de ativação f ?

Considerando uma função sigmoid



$$f'(net_{pj}) ?$$

$$o_{pj} = f(net_{pj}) = \frac{1}{1 + \exp(-net_{pj})}$$

$$f'(net_{pj}) = o_{pj}(1 - o_{pj})$$



Características do MLP

- Aproximador Universal de Funções
 - Uma única camada intermediária é capaz de aproximar qualquer função contínua definida em um hipercubo
- Alta capacidade de generalização
- Convergência para mínimo global não garantida
- Em alguns casos, lento na aprendizagem

De uma maneira geral...

Uma rede neural pode ser vista como um conjunto de funções $Y_k(X_p; W)$, tal que dado $X_p \Rightarrow Y_p$

No caso de **classificação**

$Y_k = 1$ se $X_p \in k$
0, caso contrário

No caso em que Y_k são variáveis contínuas

\Rightarrow problema de regressão

\Rightarrow ou problema de **aproximação de funções**

Reconhecimento de Padrões

Verificação

$\in ?$

X_p

C_i

Classificação

$\in ?$

C_1

C_2

C_3





C_n

X_p


$$Y_k = Y_k(X_p; W)$$

$$k = 1, 2, \dots, n$$

Reconhecimento de Padrões






Complexidade Funcional do MLP x Número de Camadas



(after Lippmann, IEEE ASSP April 1987)

Complexidade Funcional versus Over-fitting



Treinamento com Validação Cruzada






Figure 9.7. A schematic illustration of the behaviour of training and validation set errors during a typical training session, as a function of the iteration step τ . The goal of achieving the best generalization performance suggests that training should be stopped at the point $\hat{\tau}$ corresponding to the minimum of the validation set error.

Aplicações do MLP



Análise de mercado




Proc. voz




Data mining




Análise de crédito



Previsão séries



Det. fraudes




Proc. sinais


Luciana de Sales Maciel



Diagnose médica




Rec. odores



Interfaces


Complexidade Funcional (I)

Análise de crédito



Comple

Análise de crédito




- Hiperplano oblíquo: melhor separação:
- Exemplos:
 - regressão linear;
 - perceptron;

x: exemplo recusado
o: exemplo aceito

Complexidade Funcional (III)

Análise de crédito




x: exemplo recusado
o: exemplo aceito

- Superfície não linear: melhor poder de classificação, pior interpretação;
- Exemplos:
 - perceptrons multicamadas;
 - regressão não-linear;

Complexidade Funcional (IV)


Análise de crédito



- Métodos baseado em exemplos;
- Exemplos:
 - k-vizinhos mais próximos;
 - raciocínio baseado em casos;

Complexidade Funcional (V)

Análise de crédito



- Agrupamento
- Exemplo:
 - *vector quantization*;

+: exemplo