




Universidade Federal do Espírito Santo
Centro de Ciências Agrárias – CCA UFES
Departamento de Computação



Perceptron de Múltiplas Camadas e Backpropagation

Redes Neurais Artificiais

Site: <http://jeiks.net>


E-mail: jacsonrcsilva@gmail.com

Perceptron de Múltiplas Camadas

- O Perceptron simples não consegue trabalhar com sistemas não lineares.
- Porém, o Perceptron de Múltiplas Camadas consegue efetuar o mapeamento não linear do espaço de entrada X para o espaço de saída y .
- Para resolver o problema do XOR (ou exclusivo) foi utilizado um Perceptron de uma camada intermediária (oculta) e uma função de ativação de sinal (sgn).

MLP – XOR


- Perceptron de Múltiplas Camadas
(*MLP – Multi-Layer Perceptron*)



x_1	x_2	XOR
-1	-1	-1
-1	1	1
1	-1	1
1	1	-1

- Vamos trabalhar na implementação de uma Função Discriminativa Não-Linear usando uma camada intermediária que realiza o mapeamento não linear.

MLP – XOR



$$\Phi(\underline{x}) = \begin{pmatrix} \Phi_0(\underline{x}) \\ \Phi_1(\underline{x}) \\ \Phi_2(\underline{x}) \end{pmatrix} = \begin{pmatrix} \Phi_0(x_0; x_1; x_2) \\ \Phi_1(x_0; x_1; x_2) \\ \Phi_2(x_0; x_1; x_2) \end{pmatrix}$$

$$\Phi_0(\underline{x}) = 1$$


$$\Phi_1(\underline{x}) = \text{sgn}\left(\frac{1}{2} \cdot x_0 + 1 \cdot x_1 + 1 \cdot x_2\right)$$

$$\Phi_2(\underline{x}) = \text{sgn}\left(-\frac{3}{2} \cdot x_0 + 1 \cdot x_1 + 1 \cdot x_2\right)$$

$$y = \text{sgn}\left(-1 \cdot \Phi_0 + 0,7 \cdot \Phi_1(x) - 0,4 \cdot \Phi_2(x)\right)$$

Abra o Octave, crie o vetores X , y , y_est , W , W_y , e teste essa RNA e suas sinapses.

MLP – XOR



x_1	x_2	Φ_0	Φ_1	Φ_2
-1	-1	1	-3/2	-7/2
-1	1	1	1/2	-3/2
1	-1	1	1/2	-3/2
1	1	1	5/2	1/2

Perceptron de Múltiplas Camadas

- Em geral, o perceptron com uma camada oculta calcula:

$$\begin{aligned}
 y_i(\underline{x}) &= Z_i(\underline{W}_i \cdot \underline{\Phi}(\underline{x})) = Z_i\left(\sum_{k=0}^H W_{ik} \cdot \Phi_k(\underline{x})\right) \\
 &= Z_i\left(\sum_{k=0}^H W_{ik} \cdot F(W_k \cdot \underline{x})\right) \\
 &= Z_i\left(\sum_{k=0}^H W_{ik} \cdot F\left(\sum_{j=0}^d W_{kj} \cdot x_j\right)\right)
 \end{aligned}$$

sendo: Z função de saída e F função da camada oculta

Perceptron de Múltiplas Camadas

- No modelo totalmente conectado, a função de ativação é igual para todos os neurônios da mesma camada.
- Características das funções Z e F :
 - Deve ser não linear em pelo menos uma camada oculta;
 - Deve ser diferenciável: $Z'(a)$ deve existir.
- A camada oculta implementa a função de base $\phi_k(\underline{x})$;
- A função base não é fixa, sendo então adaptável:
 - Poder de cálculo do MLP.

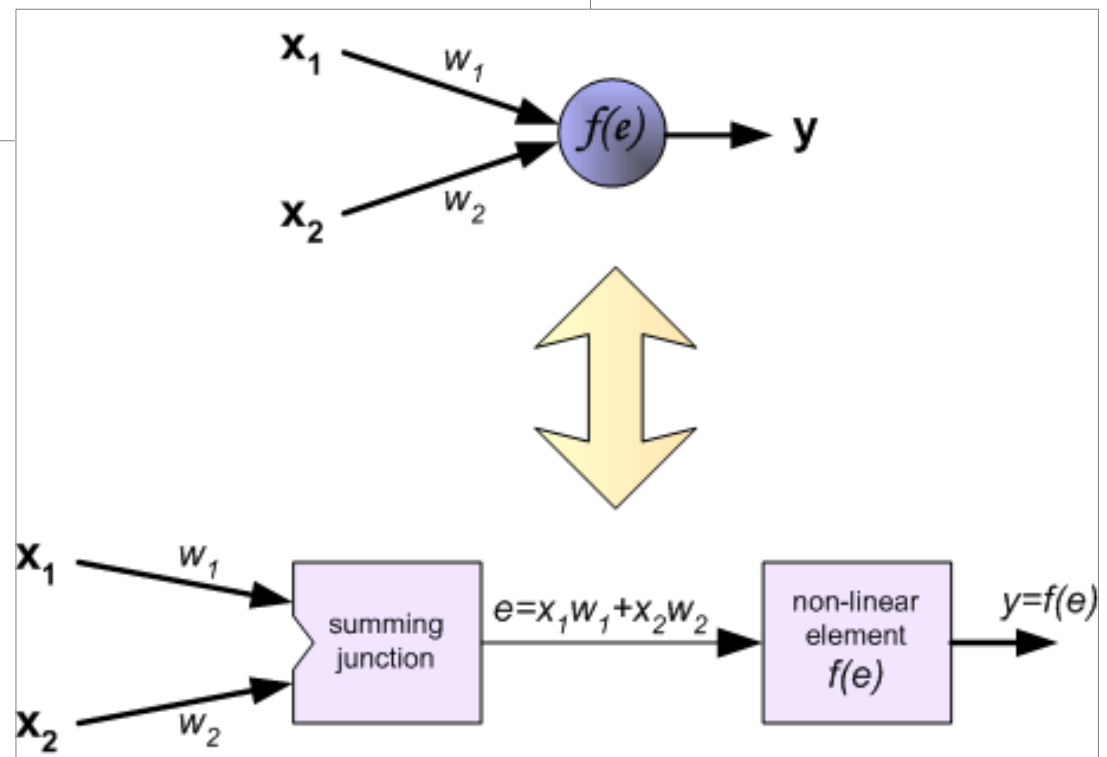

Backpropagation

- Vamos ver o funcionamento iterativo do backpropagation utilizando a referência de




Mariusz Bernacki, Przemysław Włodarczyk, (2005)

http://home.agh.edu.pl/~vlsi/AI/backp_t_en/backprop.html

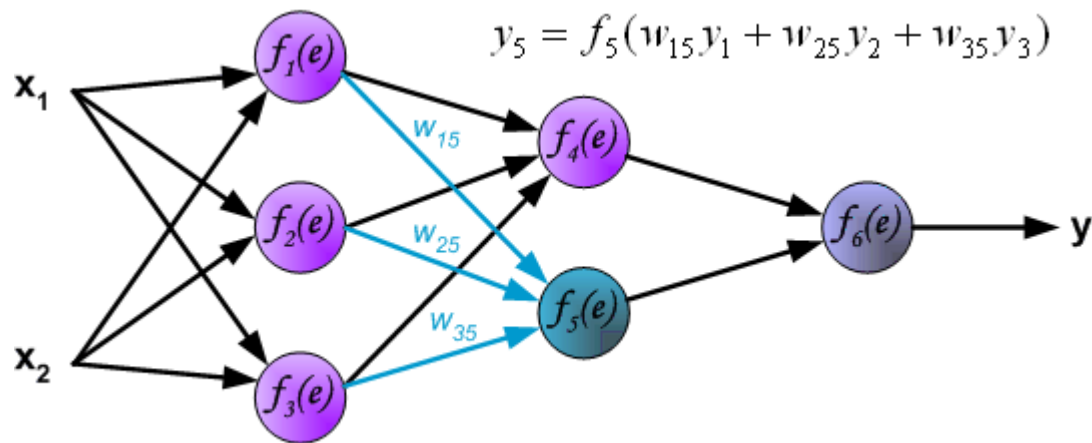
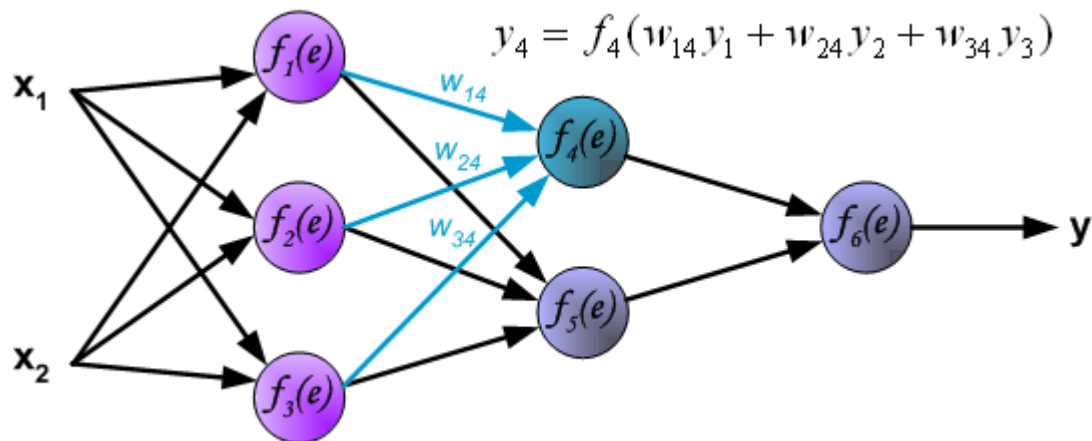
Rede Neural Utilizada




Calculando a saída desejada...




Calculando a saída desejada...





Calculando a saída desejada...






Calculando o erro da saída




Retrocedendo com o Erro...




Retrocedendo com o Erro...




Atualizando os pesos...



$w'_{(x1)2} = w_{(x1)2} + \eta \delta_2 \frac{df_2(e)}{de} x_1$
 $w'_{(x2)2} = w_{(x2)2} + \eta \delta_2 \frac{df_2(e)}{de} x_2$



$w'_{(x1)3} = w_{(x1)3} + \eta \delta_3 \frac{df_3(e)}{de} x_1$
 $w'_{(x2)3} = w_{(x2)3} + \eta \delta_3 \frac{df_3(e)}{de} x_2$




Atualizando os pesos...

$$w'_{14} = w_{14} + \eta \delta_4 \frac{df_4(e)}{de} y_1$$

$$w'_{24} = w_{24} + \eta \delta_4 \frac{df_4(e)}{de} y_2$$


$$w'_{34} = w_{34} + \eta \delta_4 \frac{df_4(e)}{de} y_3$$



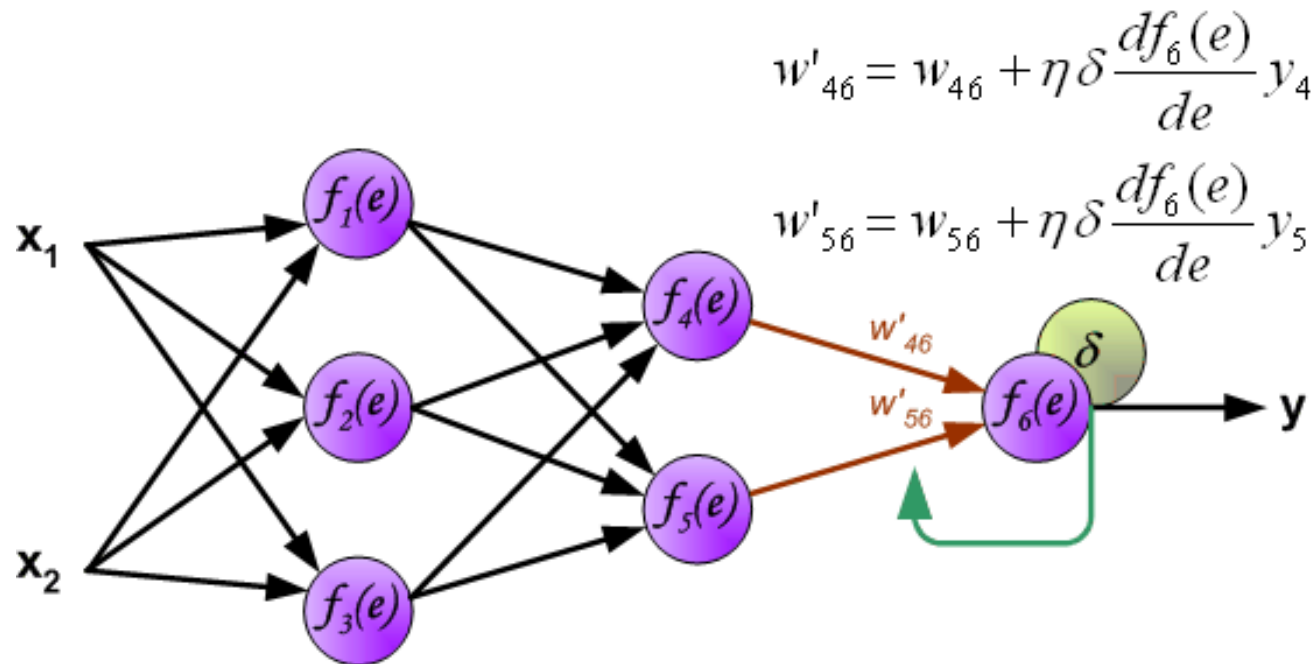
$$w'_{15} = w_{15} + \eta \delta_5 \frac{df_5(e)}{de} y_1$$

$$w'_{25} = w_{25} + \eta \delta_5 \frac{df_5(e)}{de} y_2$$

$$w'_{35} = w_{35} + \eta \delta_5 \frac{df_5(e)}{de} y_3$$



Atualizando os pesos...



Regra de ajuste do peso

- Considere:
 - i, \dots, c : índice dos neurônios da camada de saída;
 - h, \dots, H : índice dos neurônios da camada oculta;
 - j, \dots, d : índice dos neurônios da camada de entrada.
- Sensibilidade:
 - A S (sensibilidade) do neurônio i descreve como o erro global $E(w)$ muda o valor de net_i .
- A regra de ajuste do peso utiliza a sensibilidade de cada neurônio.
- Seu cálculo será adicionado no algoritmo...

Feed Forward: Alimentação Adiante

```
// Entrada para Oculta
Para  $h=0, \dots, H$ 
   $net_h \leftarrow 0$ 
  Para  $j=0, \dots, d$ 
     $net_h \leftarrow net_h + W_{hj} X_j$ 
  Fim Para
   $\Phi_h \leftarrow Z(net_h)$ 
Fim Para
```

```
// Oculta para Saída
Para  $i=0, \dots, c$ 
   $net_i \leftarrow 0$ 
  Para  $h=0, \dots, H$ 
     $net_i \leftarrow net_i + W_{ih} \Phi_h$ 
  Fim Para
   $y_i \leftarrow Z(net_i)$ 
Fim Para
```

Backpropagation

Inicialização aleatória dos pesos W' e W , onde $\|W_i\|=1$ e $\|W_h\|=1$

Para todos os padrões $\underline{X}^{(k)}, k=1, \dots, n$, em ordem aleatória:

Feedforward de $\underline{X}^{(k)}: \hat{y}(x^{(k)})$

Para $i=1, \dots, c$:

$\delta_i^{(k)} = y_i^{(k)} - \hat{y}_i(x^{(k)})$ // Erro na saída i do padrão k

$S_i^{(k)} \leftarrow 2 \cdot \delta_i^{(k)} \cdot Z'(net_i^{(k)})$ // Sensibilidade

Para $h=0, \dots, H$:

$$w_{ih}^{novo} \leftarrow w_{ih}^{velho} + \eta \cdot S_i^{(k)} \cdot Z'(net_h^{(k)})$$

$\Phi_h(X^{(k)})$

// Adaptar os pesos de entrada para a camada oculta W'

Para $h=1, \dots, H$:

$aux \leftarrow 0$

Para $i=0, \dots, c$:

$$aux \leftarrow aux + w_{ih}^{velho} \cdot S_i^{(k)}$$

Para $j=0, \dots, d$:

$$w_{hj}^{novo} \leftarrow w_{hj}^{velho} + \eta \cdot S_h^{(k)} \cdot X_j^{(k)}$$

Metodologia de Treinamento

- Deve-se realizar a divisão do conjunto de dados dos n padrões $X^{(k)}$, $k=1, \dots, n$ em três conjuntos de dados:
 - Treinar com 75% dos exemplos;
 - Validar com 15% dos exemplos;
 - Testar com 15% dos exemplos.

Obs.: Essas porcentagens são as padrões do Matlab, mas podem ser alteradas.

- Antes, os dados devem ser normalizados ou estandardizados:
 - Normalização:
 - $\underline{X} = (X - \min(X)) / (\max(X) - \min(X))$
 - Estandarização:
 - $\underline{X} = (X - \text{média}(X)) / \sigma(X)$.