

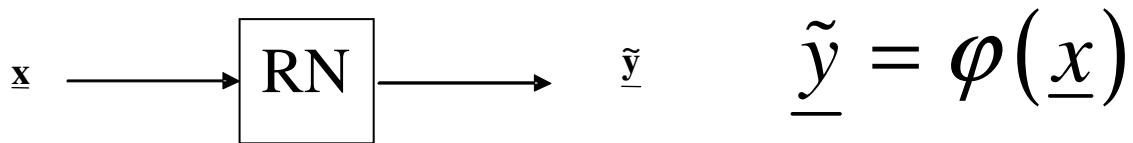
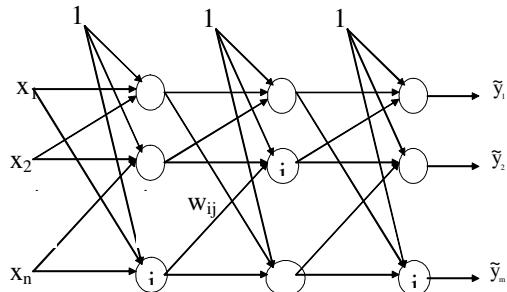
Redes Neurais Feedforward

Aprendizado (Treinamento) Backpropagation

Aproximador Universal

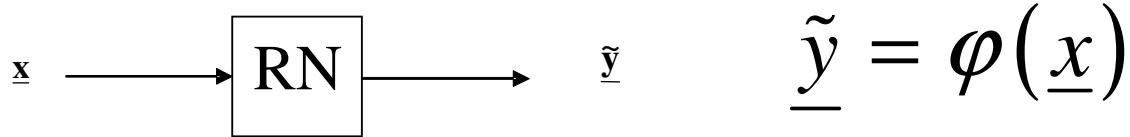
Redes Neurais *FeedForward*

Redes “*Backpropagation*”



Mapeador não linear

Aproximador Universal !



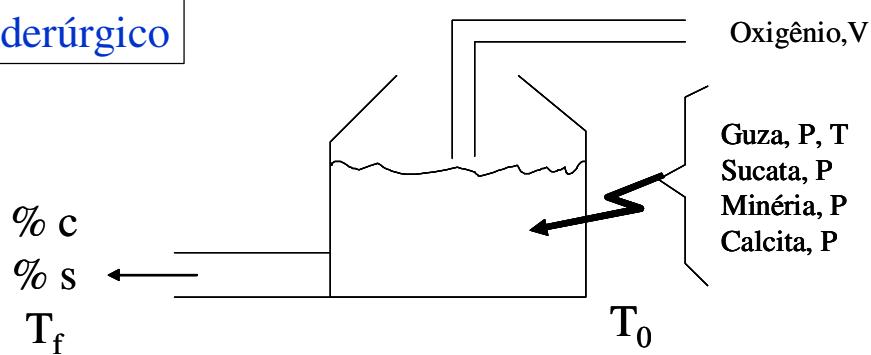
Para que serve ?

Aplicações:

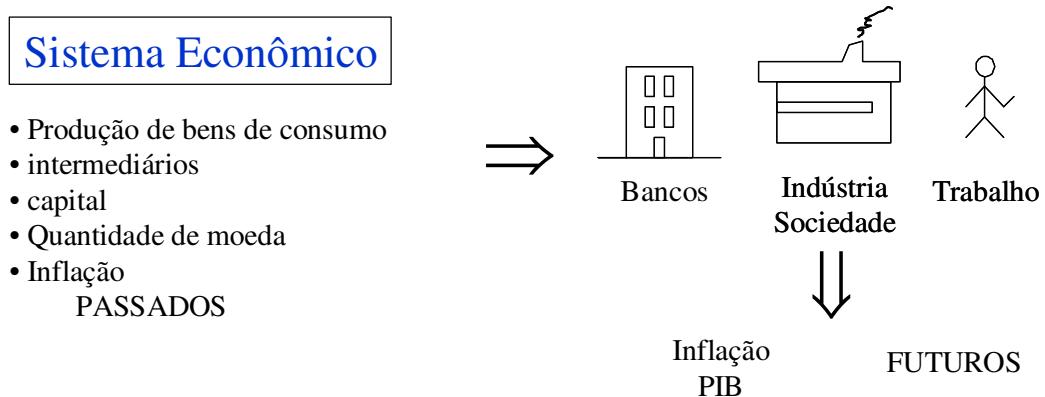
Simuladores;
Controladores;
Classificadores;
Reconhecimento de padrões;
Filtragem não linear;
etc...

Simulação de Sistemas

Conversor Siderúrgico



Simulação de Sistemas



Simulação de Sistemas

Sistema Real, Planta

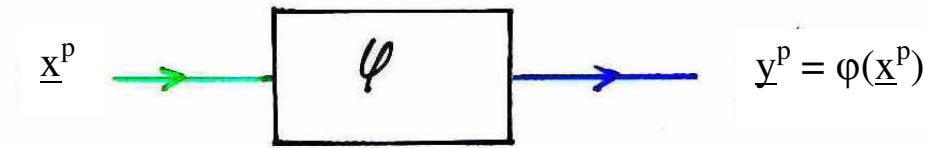
$$(\underline{\mathbf{x}}^p, \underline{\mathbf{y}}^p) \quad p = 1, 2, \dots, P$$



Simulador



Sistema à emular



Conhecimento do Sistema

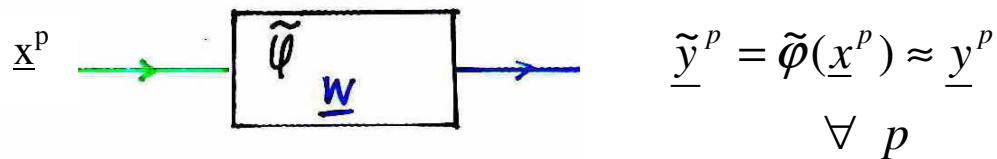
Fenomenológico – equações – modelo caixa branca - NÃO

Funcional – relação entrada/saída – modelo caixa preta

Pares entrada-saída

$$(\underline{x}^p, \underline{y}^p) \quad p = 1, \dots P$$

Modelo Matemático Fenomenológico / Numérico - Simulador



Modelo Fenomenológico – Caixa branca

Modelo Numérico Geral (e.g. rede neural) – Caixa Preta

Ajuste dos parâmetros w ?

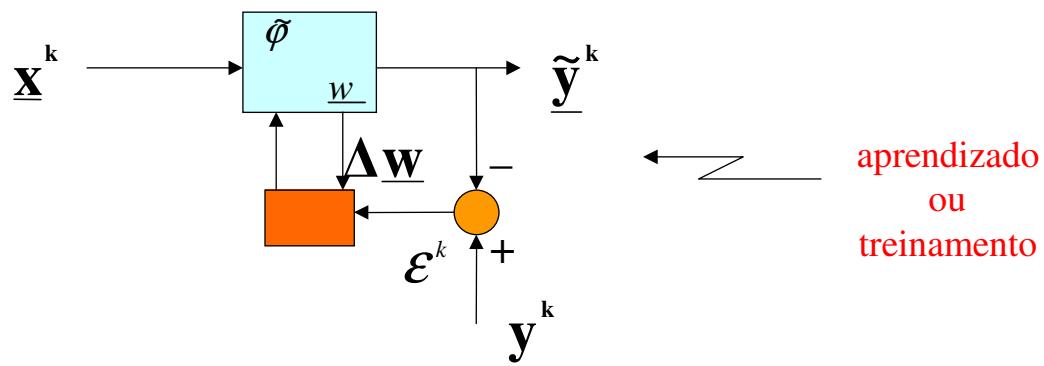
Simulação de Sistemas

Sistema Real, Planta

$$(\underline{\mathbf{x}}^k, \underline{\mathbf{y}}^k) \quad k = 1, 2, \dots, P$$



Simulador



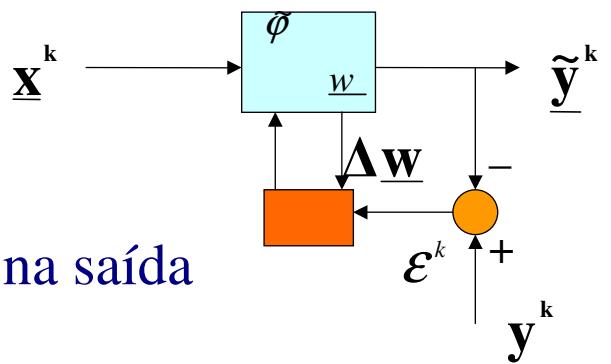
Aprendizado

(ou treinamento, ou ajuste de parâmetros)

como um processo de otimização

(visto em detalhes em CPE 723 - apostila disponível no site)

Aprendizado =
minimização do erro na saída



Erro a minimizar:

$$\varepsilon^{2^k} = \left\| \underline{\mathbf{y}}^k - \tilde{\underline{\mathbf{y}}}^k \right\|^2 = \sum_{l=1}^m (\underline{\mathbf{y}}_l^k - \tilde{\underline{\mathbf{y}}}_l^k)^2$$

Erro médio quadrático:

$$F_0 = E(\varepsilon^{2^k}) = \frac{1}{P} \sum_{k=1}^P \varepsilon^{2^k}$$

$$F_0 = E(\varepsilon^{2^k}) = F_0(\underline{\mathbf{w}}) \geq 0$$

Treinamento, Aprendizado: Minimizar o erro na saída

Função objetivo à minimizar:

$$F_0 = E(\varepsilon^{2^k}) = F_0(\underline{\mathbf{w}}) \geq 0$$

Problema:

Como encontrar o vetor $\underline{\mathbf{w}}_0$ que minimize $F_0(\underline{\mathbf{w}})$?

$$F_0(\underline{\mathbf{w}}_0) \leq F_0(\underline{\mathbf{w}}) \quad \forall \underline{\mathbf{w}} \neq \underline{\mathbf{w}}_0$$

Gradiente:

$$F_0(w_1, w_2, \dots) = F(\underline{w})$$

$$\underline{w} = \begin{bmatrix} w_1 \\ w_2 \\ \vdots \end{bmatrix} \quad \nabla_{\underline{w}} F_0 = \underline{\nabla} = \begin{bmatrix} \frac{\partial F_0}{\partial w_1} \\ \frac{\partial F_0}{\partial w_2} \\ \vdots \end{bmatrix}$$

Propriedades do Gradiente:

1. $\underline{w} \rightarrow \underline{w} + \Delta \underline{w} \Rightarrow F_0 \rightarrow F_0 + \Delta F_0$

se $\Delta \underline{w} = \alpha \underline{\nabla} \Rightarrow \Delta F_0$ é máximo

então se $\Delta \underline{w} = -\alpha \underline{\nabla} \Rightarrow \Delta F_0$ é mínimo

i.e. $\Delta F_0 < 0$ e $|\Delta F_0|$ é máximo

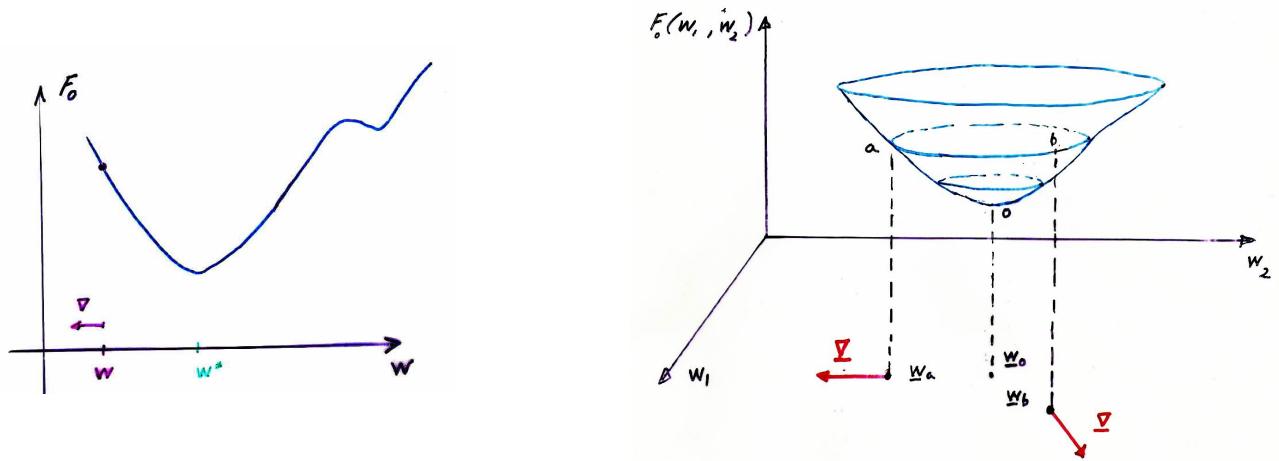
2. $\underline{\nabla}|_{\underline{w}_0} = \underline{0}$

Gradiente descendente

ou descida por gradiente

$$\underline{w} \longrightarrow \Delta \underline{w} = -\alpha \nabla(\underline{w}) \longrightarrow \underline{w} = \underline{w} + \Delta \underline{w}$$

The diagram illustrates the iterative update of weights \underline{w} . It starts with an initial weight \underline{w} (purple arrow), which is updated by subtracting the gradient $\nabla(\underline{w})$ (red arrow) to reach a new point $\underline{w} + \Delta \underline{w}$ (blue arrow). This process is shown as a red loop, indicating the iterative nature of the gradient descent algorithm.



Complexidade de cálculo:

$$\Delta w_{ij} = -\alpha \frac{\partial F}{\partial w_{ij}}$$

Fim do processo:

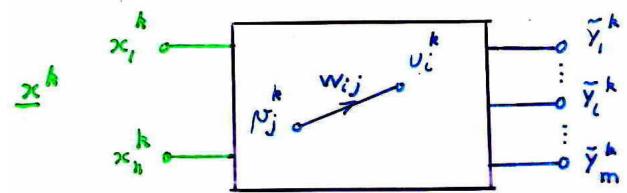
$$\nabla \underline{w}_{otimo} = \underline{0} \quad \rightarrow \quad \Delta \underline{w}_{otimo} = \underline{0}$$

Acréscimo a aplicar em cada sinapse:

$$F_0 = E(\mathcal{E}^{2^p}) = F_0(\underline{\mathbf{w}}) \quad \Delta w_{ij} = -\alpha \frac{\partial F_0(w_{ij})}{\partial w_{ij}}$$

Como calcular

$$\frac{\partial F_0(w_{ij})}{\partial w_{ij}} \quad \text{???$$



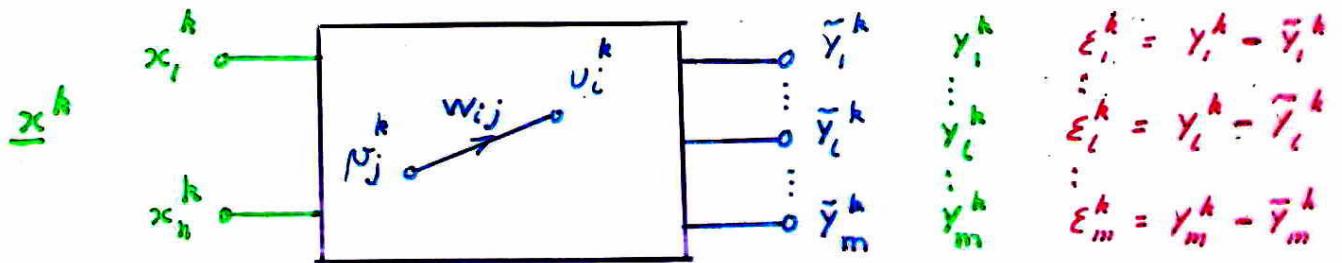
$$1 - F_0(w_{ij}) = E_k \left[(\mathcal{E}^k)^2 \right] = \frac{1}{K} \sum_{k=1}^K (\mathcal{E}^k)^2$$

$$\frac{\partial F_0(w_{ij})}{\partial w_{ij}} = \frac{\partial E_k [(\mathcal{E}^k)^2]}{\partial w_{ij}} = E_k \left[\frac{\partial (\mathcal{E}^k)^2}{\partial w_{ij}} \right]$$

Propriedade importante:

o gradiente do valor esperado do erro quadrático é igual ao valor esperado do gradiente do erro quadrático
cada par entrada-saída é tratado isoladamente.

2 – Cálculo de $\frac{\partial(\varepsilon^k)^2}{\partial w_{ij}}$ para cada par entrada – saída k

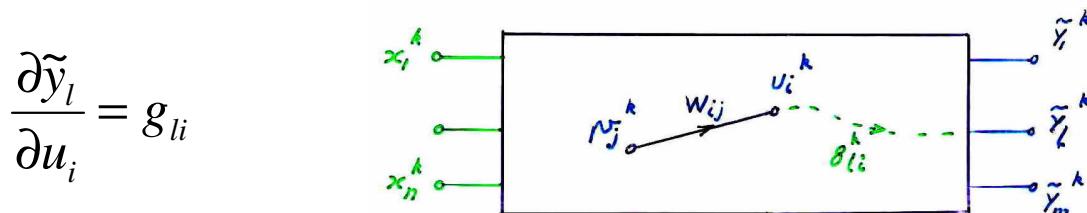


$$(\varepsilon)^2 = \sum_{l=1}^m (\varepsilon_l)^2 = \sum_{l=1}^m (y_l - \tilde{y}_l)^2$$

$$\frac{\partial(\varepsilon)^2}{\partial w_{ij}} \quad ???$$

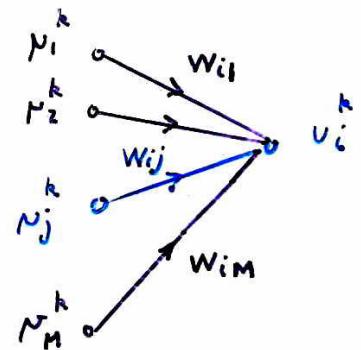
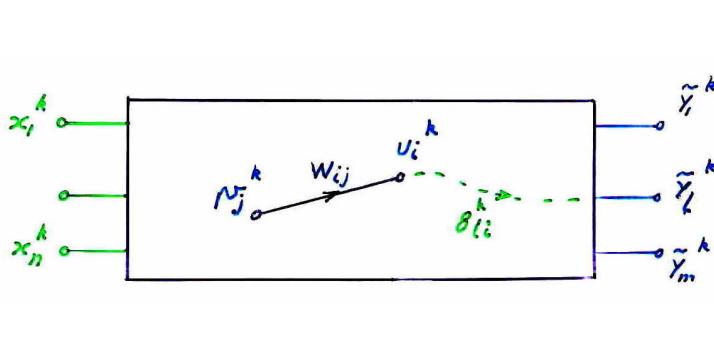
$$\frac{\partial(\varepsilon)^2}{\partial w_{ij}} = \frac{\partial}{\partial w_{ij}} \sum_{l=1}^m \varepsilon_l^2 = \sum_{l=1}^m \frac{\partial \varepsilon_l^2}{\partial w_{ij}} = 2 \sum_{l=1}^m \varepsilon_l \frac{\partial \varepsilon_l}{\partial w_{ij}} =$$

$$= 2 \sum_{l=1}^m \varepsilon_l \frac{\partial (y_l - \tilde{y}_l)}{\partial w_{ij}} = -2 \sum_{l=1}^m \varepsilon_l \frac{\partial \tilde{y}_l}{\partial w_{ij}} = -2 \sum_{l=1}^m \varepsilon_l \frac{\partial \tilde{y}_l}{\partial u_i} \frac{\partial u_i}{\partial w_{ij}}$$



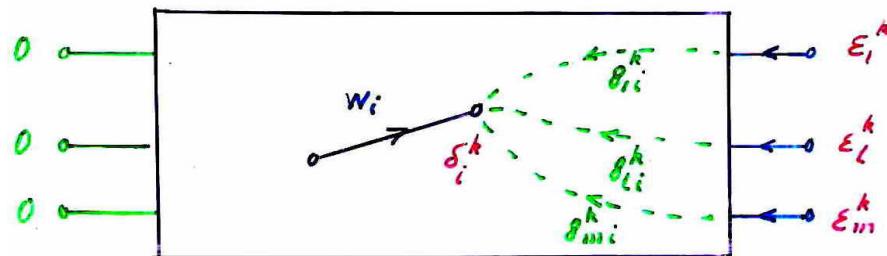
$$\frac{\partial(\varepsilon)^2}{\partial w_{ij}} = -2 \sum_{l=1}^m \varepsilon_l \frac{\partial \tilde{y}_l}{\partial u_i} \frac{\partial u_i}{\partial w_{ij}} = -2 \sum_{l=1}^m \varepsilon_l g_{li} v_j$$

$$\frac{\partial \tilde{y}_l}{\partial u_i} = g_{li} \quad u_i = \sum_{m=1}^M w_{mj} v_j \quad \frac{\partial u_i}{\partial w_{ij}} = v_j$$



$$\frac{\partial(\varepsilon)^2}{\partial w_{ij}} = -2 \sum_{l=1}^m \varepsilon_l g_{li} v_j = -2 v_j \sum_{l=1}^m \varepsilon_l g_{li} = -2 v_j \delta_i$$

$$\delta_i = \sum_{l=1}^m \varepsilon_l \frac{\partial \tilde{y}_l}{\partial u_i} = \sum_{l=1}^m \varepsilon_l g_{li}$$



δ_i é o erro retropropagado da saída até a extremidade da sinapse

3 - como:

$$\Delta w_{ij} = -\alpha \frac{\partial F_0(w_{ij})}{\partial w_{ij}}$$

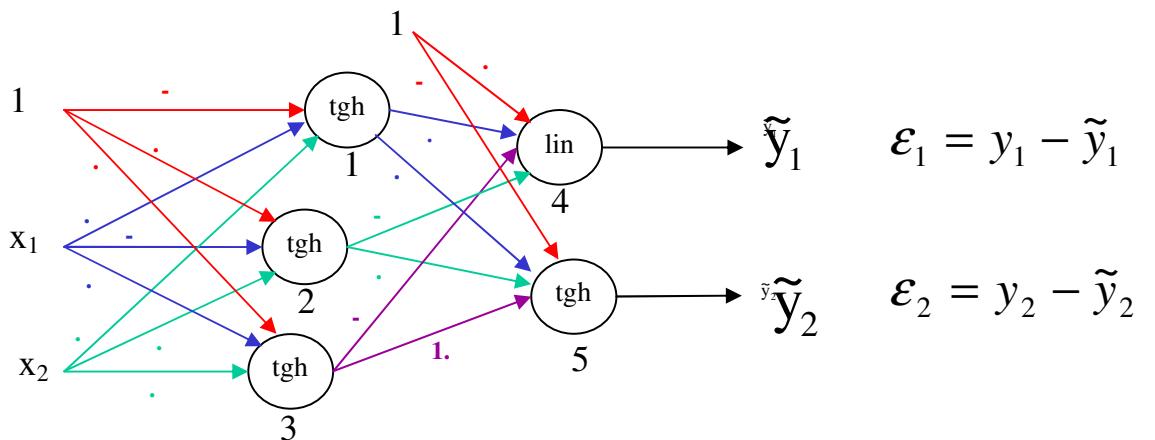
$$\frac{\partial F_0(w_{ij})}{\partial w_{ij}} = \frac{1}{P} \sum_{p=1}^P \frac{\partial}{\partial w_{ij}} (\epsilon^{2^p})$$

$$\frac{\partial (\epsilon)^2}{\partial w_{ij}} = -2 v_j \delta_i$$

$$\Delta w_{ij} = 2 \alpha \frac{1}{P} \sum_{p=1}^P v_j \delta_i \Big|_p$$

Error Backpropagation -Algoritmo:

1 - Rede Original:



Propagar o sinal na rede original e conservar o valor do sinal v_j na entrada de cada sinapse w_{ij} . Calcular o erro em cada saída.

2 – Criar uma “Rede Associada” a partir da Rede Original

mesma arquitetura, mas

2.1 - “Linearizar” (os neurônios) da rede original

Rede original

Neurônio não linear

$$v_0 = \tanh(u_0) \quad >>>$$

Neurônio linear

$$v_0 = u_0 \quad >>>$$

Rede Associada

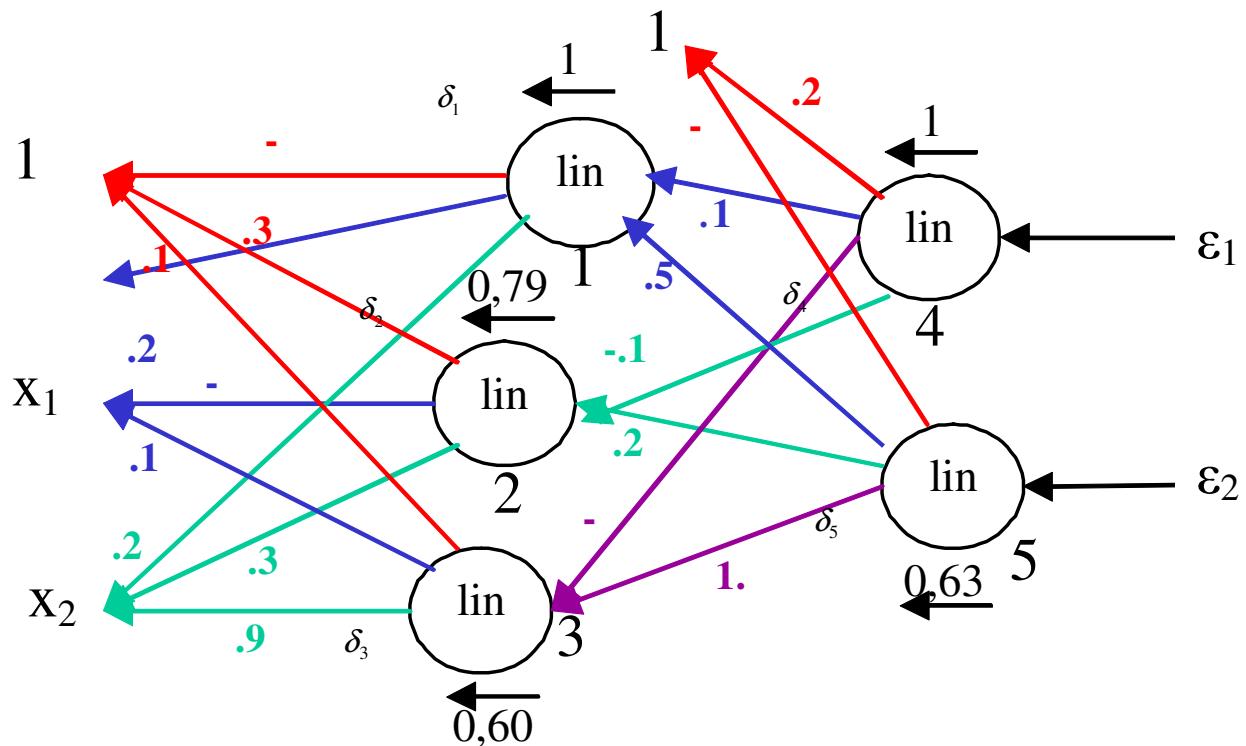
Neurônio linear

$$v = (1-v_0^2) u$$

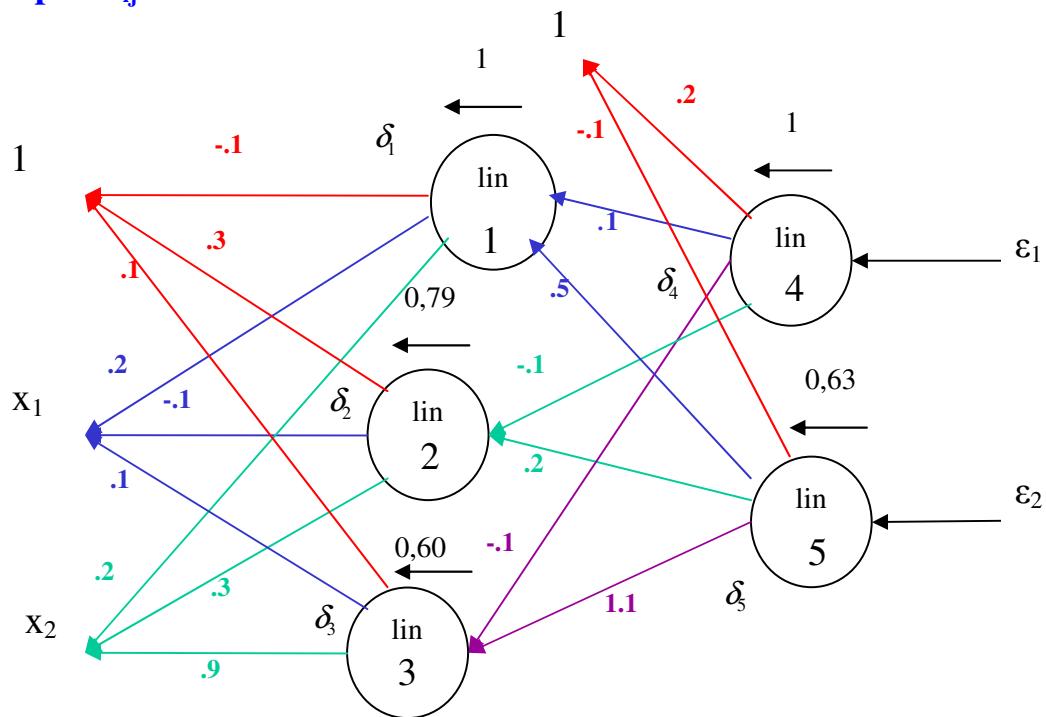
Neurônio linear

$$v = u$$

2.2- Inverter todos os sentidos de transmissão (dos neurônios e sinapses)



3 – (Retro)propagar o erro ε_l em cada saída através da rede “associada” e conservar o valor do sinal δ_i de erro retropropagado que chega na saída (original) de cada sinapse w_{ij} .



4 – O acréscimo para cada sinapse w_{ij} para o par p entrada-saída em operação é dado por:

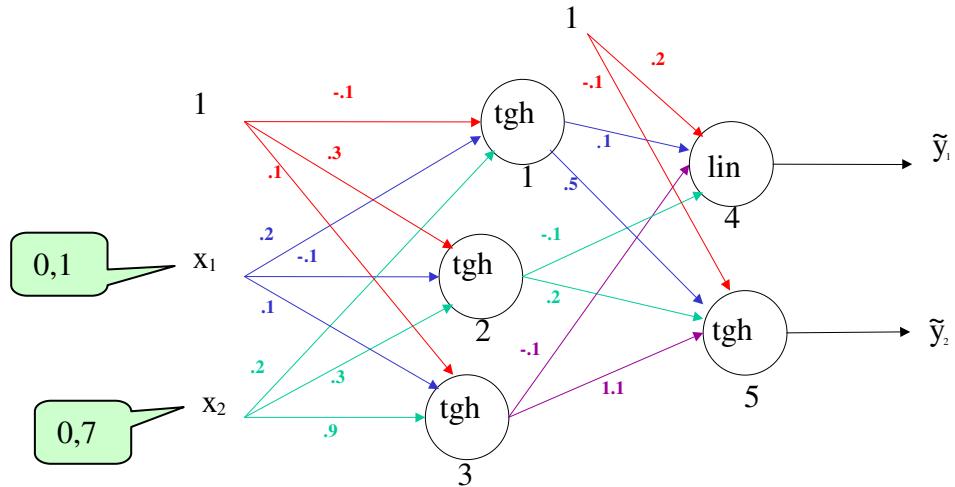
$$\Delta_p w_{ij} = 2 \alpha v_j \delta_i$$

5 – O acréscimo a ser aplicado na sinapse w_{ij} é o valor esperado dos acréscimos calculados para todos os pares entrada-saída.

$$\Delta w_{ij} = E_p (\Delta_p w_{ij}) = 2 \alpha E_p (v_j \delta_i |_p)$$

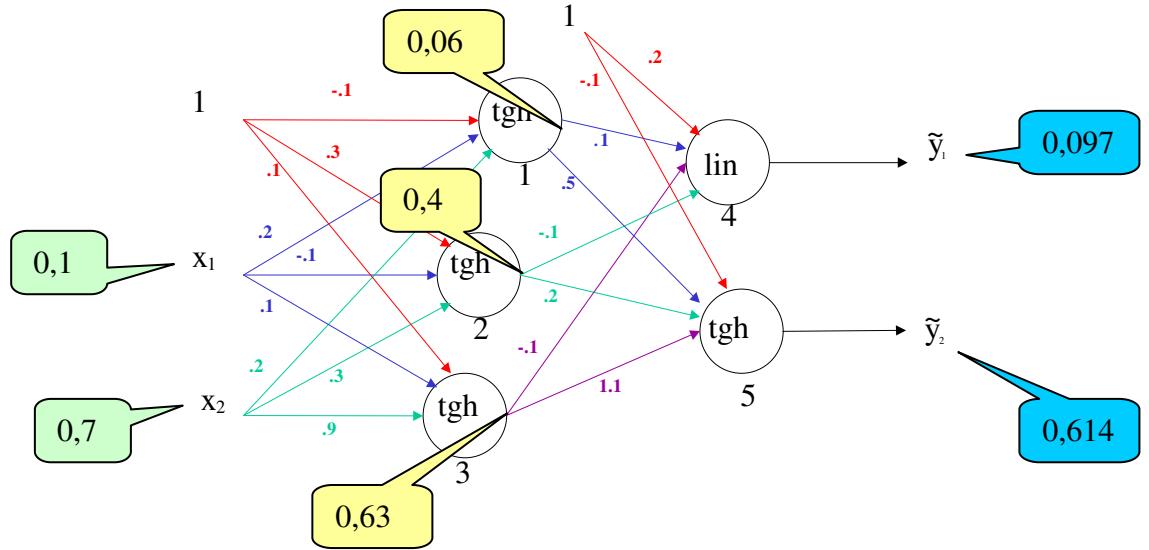
Processo em Batelada – Batch

Exemplo anterior:



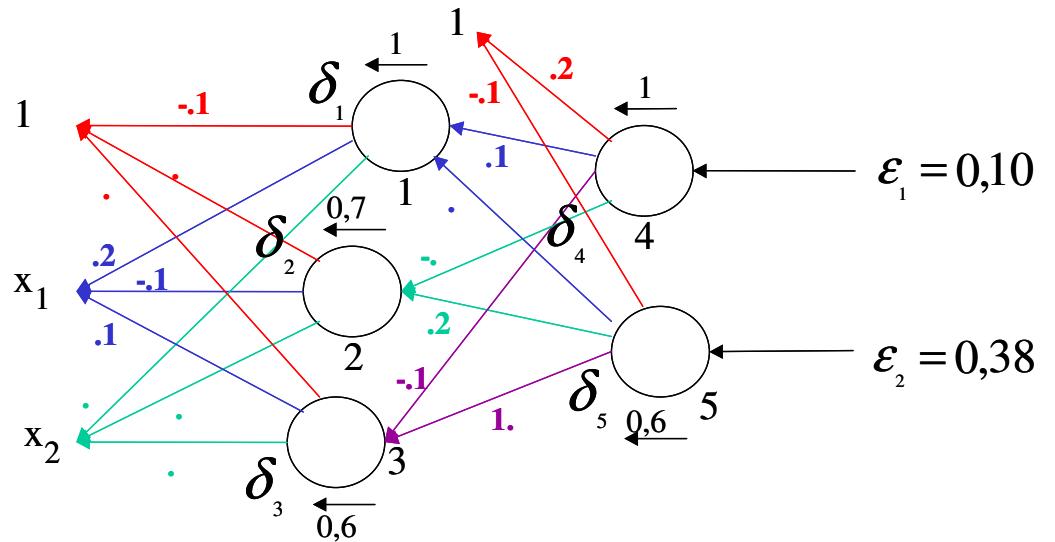
$$\underline{x} = \begin{bmatrix} 0,1 \\ 0,7 \end{bmatrix} \quad \tilde{\mathbf{y}} = ? \quad \mathbf{y} = \begin{bmatrix} 0,2 \\ 0,1 \end{bmatrix}$$

Signal Feedforward



$$\underline{x} = \begin{bmatrix} 0,1 \\ 0,7 \end{bmatrix} \quad \mathbf{y} = \begin{bmatrix} 0,2 \\ 1 \end{bmatrix} \quad \tilde{\mathbf{y}} = \begin{bmatrix} 0,097 \\ 0,614 \end{bmatrix} \quad \boldsymbol{\varepsilon} = \begin{bmatrix} 0,103 \\ 0,386 \end{bmatrix}$$

Rede associada e retropropagação do erro:



$$\delta_5 = (0,386)(0,63) = 0,24$$

$$\delta_4 = (0,103)(1) = 0,103$$

$$\delta_3 = [(0,103)(-0,1) + (0,24)(0,2)](0,60) = 0,152$$

$$\delta_2 = [(0,103)(-0,1) + (0,24)(0,2)](0,79) = 0,030$$

$$\delta_1 = [(0,103)(0,1) + (0,24)(0,5)](1) = 0,130$$

Treinamento Regra Delta

Atualização dos valores das sinapses:

$$\Delta w_{ij} = 2\alpha v_j \delta_i$$

$$\Delta b_4 = (2)(0,1)(1)(0,103) = 0,021$$

$$b_4 \rightarrow 0,2 + 0,021 = 0,221$$

$$\Delta b_1 = (2)(0,1)(1)(0,130) = 0,026$$

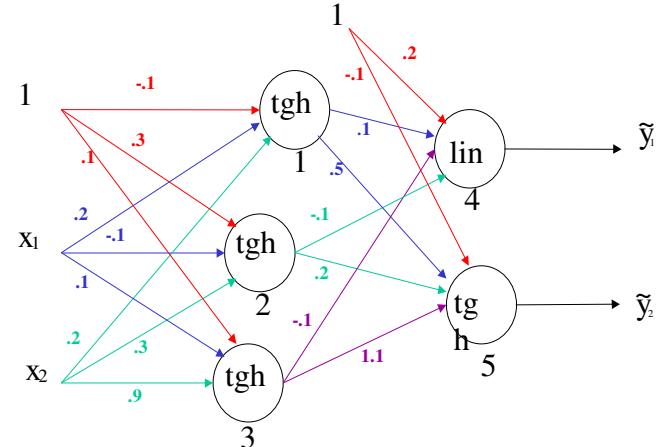
$$b_1 \rightarrow -0,1 + 0,026 = -0,074$$

$$\Delta w_{41} = (2)(0,1)(0,06)(0,103) = 0,001$$

$$w_{41} \rightarrow 0,1 + 0,001 = 0,101$$

$$\Delta w_{3b} = (2)(0,1)(0,7)(0,152) = 0,021$$

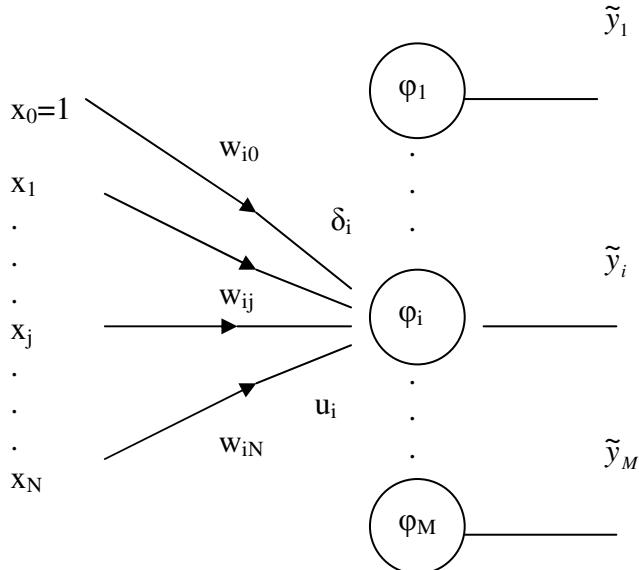
$$w_{3b} \rightarrow 0,9 + 0,021 = 0,921$$



Algorítmos específicos:

Algorítmico para Redes com uma Camada

Formulário para Treinamento Batelada



Para cada par entrada-saída $p = 1, \dots, P$

Para todos os neurônios $i = 1, \dots, M$

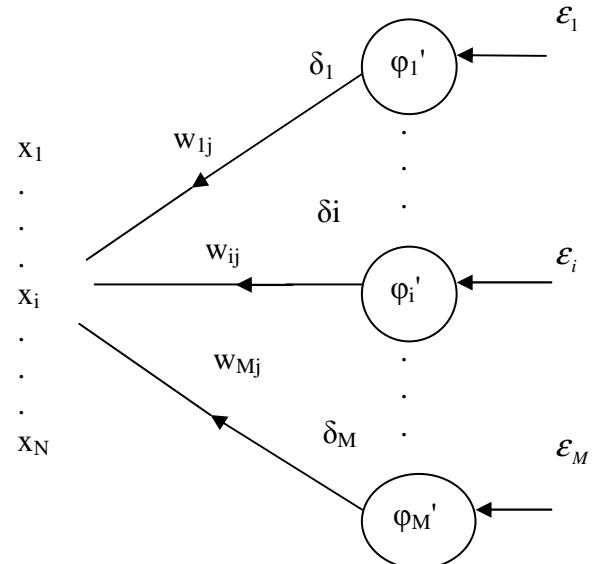
Signal feedforward:

$$u_i = \sum_{j=0}^N w_{ij} x_j$$

$$\tilde{y}_i = \varphi_i(u_i) = \begin{cases} u_i & \text{neurônio linear} \\ \tgh(u_i) & \text{neurônio tgh} \end{cases}$$

Erro na saída:

$$\mathcal{E}_i = y_i - \tilde{y}_i$$

Rede associada:

**Erro retropropagado
até a saída das sinapses:**

$$\delta_i = \begin{cases} \epsilon_i & \text{neurônio linear} \\ (1 - \tilde{y}_i^2) \epsilon_i & \text{neurônio tgh} \end{cases}$$

Acréscimo nas sinapses devido ao par p:

Para todo $i = 1, \dots, M$ e $j = 0, 1, \dots, N$

$$\Delta w_{ij}(p) = 2\alpha x_j \delta_i$$

Outro par

Acréscimo nas sinapses:

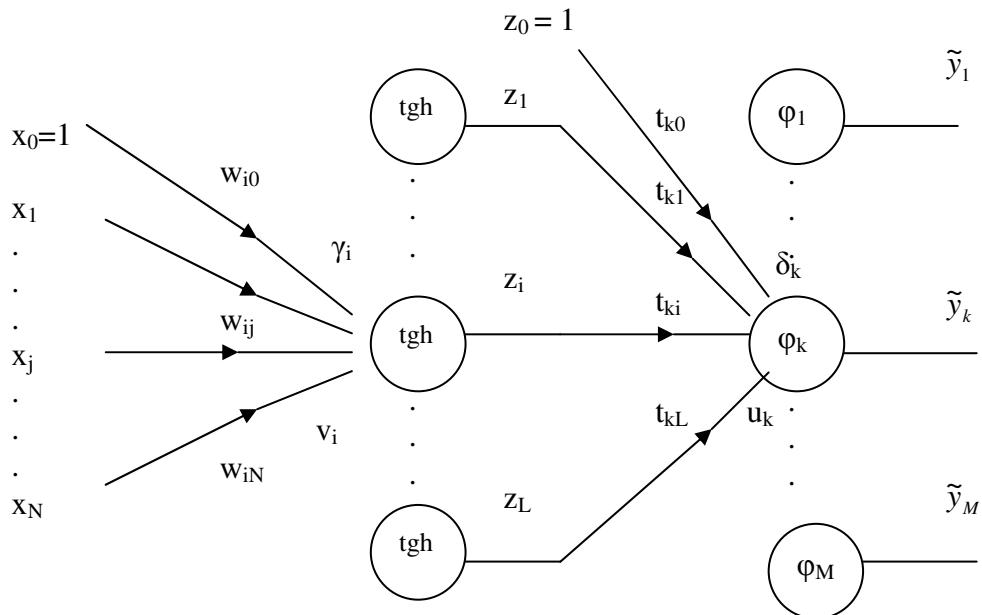
Para todo $i = 1, \dots, M$ e $j = 0, 1, \dots, N$

$$\Delta w_{ij} = E[\Delta w_{ij}(p)] = \frac{1}{P} \sum_{p=1}^P \Delta w_{ij}(p)$$

Reiniciar até que a condição de parada esteja satisfeita

Algorítmo para Redes com duas camadas

Formulário para Treinamento Batelada



Para cada par entrada-saída $p = 1, \dots, P$

Signal feedforward:

Para todos os neurônios da primeira camada $i = 1, \dots, L$

$$v_i = \sum_{j=0}^N w_{ij} x_j \quad x_0 = 1$$

$$z_i = tgh(v_i) \quad z_0 = 1$$

Para todos os neurônios da segunda camada $k = 1, \dots, M$

$$u_k = \sum_{i=0}^L t_{ki} z_i \quad z_0 = 1$$

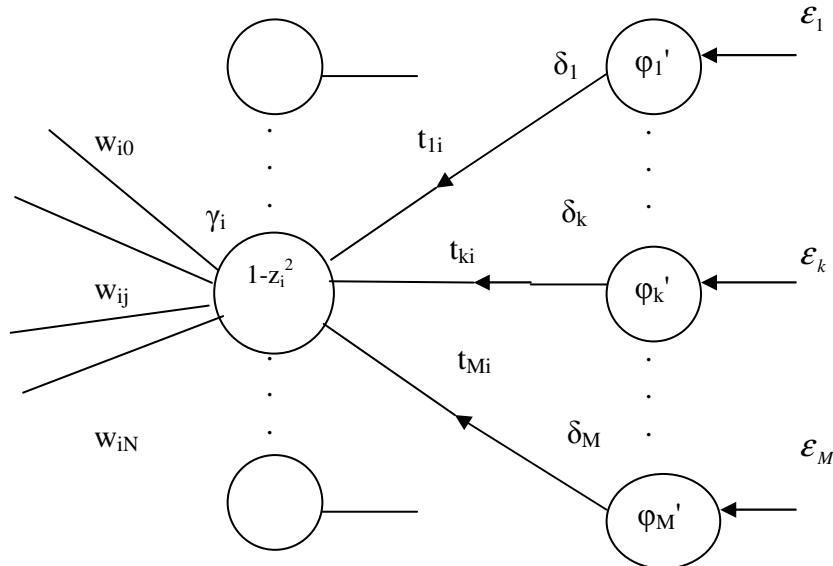
$$\tilde{y}_k = \varphi_k(u_k) = \begin{cases} u_k & \text{neurônio linear} \\ tgh(u_k) & \text{neurônio tgh} \end{cases}$$

Erro na saída:

Para todos os neurônios da segunda camada $k = 1, \dots, M$

$$\epsilon_k = y_k - \tilde{y}_k$$

Rede associada:



Retropropagação do erro

Para todo neurônio da segunda camada, $k = 1, \dots, M$:

$$\delta_k = \begin{cases} \epsilon_k & \text{neurônio linear} \\ (1 - \tilde{y}_k^2) \epsilon_k & \text{neurônio tgh} \end{cases}$$

Para todo neurônio da primeira camada, $i = 1, \dots, L$

$$\gamma_i = (1 - z_i^2) \sum_{k=1}^M t_{ki} \delta_k$$

Acréscimo nas sinapses da primeira camada devido ao par p:

Para todo $j = 0, 1, \dots, N$ e $i = 1, \dots, L$

$$\Delta w_{ij}(p) = 2 \alpha x_j \gamma_i$$

Acréscimo nas sinapses da segunda camada devido ao par p:

Para todo $i = 0, 1, \dots, L$ e $k = 1, \dots, M$

$$\Delta t_{ki}(p) = 2 \alpha z_i \delta_k$$

Outro par

Acréscimo nas sinapses da primeira camada:

Para todo $j = 0, 1, \dots, N$ e $i = 1, \dots, L$

$$\Delta w_{ij} = E[\Delta w_{ij}(p)] = \frac{1}{P} \sum_{p=1}^P \Delta w_{ij}(p)$$

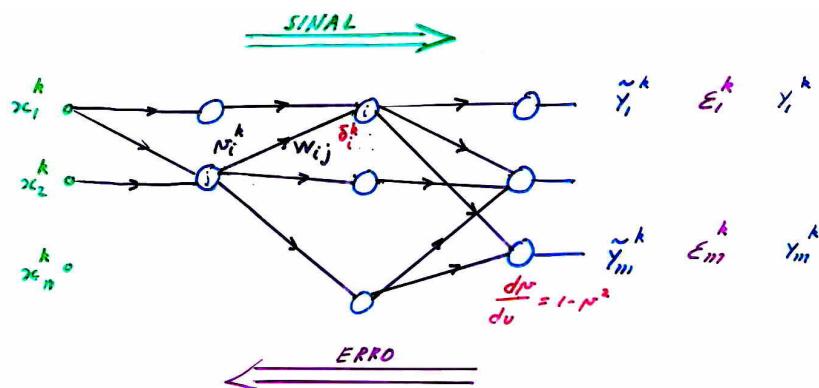
Acréscimo nas sinapses da segunda camada:

Para todo $i = 0, 1, \dots, L$ e $k = 1, \dots, M$

$$\Delta t_{ki} = E[\Delta t_{ki}(p)] = \frac{1}{P} \sum_{p=1}^P \Delta t_{ki}(p)$$

Reiniciar até que a condição de parada esteja satisfeita.

Error Backpropagation - Resumo:



$$\frac{\partial \epsilon^k}{\partial w_{ij}} = -2 \mu_j^k \delta_i^k$$

$$\nabla F_0 = \left[\frac{\partial F_0}{\partial w_{ij}} \right] = -2 E(\mu_j \delta_i) \left[\right]$$

$$\Delta w_{ij} = 2 \alpha E(\mu_j \delta_i)$$