

1.2 - Considerando que a excitação interna do neurônio é uma soma ponderada das entradas adicionada a uma polarização,

$$u_i = \sum_{j=1}^n w_{ij} x_j + w_{i0} ,$$

mostre que redes feedforward (mesmo multicamadas) com neurônios com os dois tipos função de ativação, $L(u)$ ou $tgh(\cdot)$, são equivalentes em capacidade de mapeamento entrada-saída (a menos de uma constante e um fator de escala).

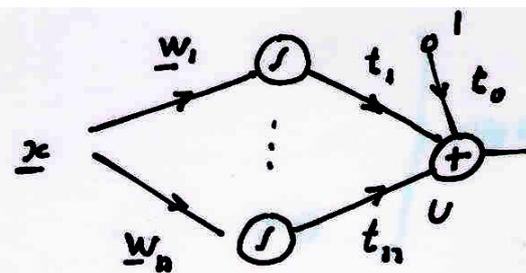


Diagram of a feedforward neuron. An input x is distributed to multiple neurons. Each neuron i receives a weighted input $w_i x$ and a bias t_0 . The outputs t_i are summed to produce the total excitation u .

Handwritten notes for the tgh function:

$$u = t_0 + \sum t_i tgh \underline{w_i^t x}$$

Handwritten notes for the lg function:

$$u = t_0 + \sum t_i lg \underline{w_i^t x}$$

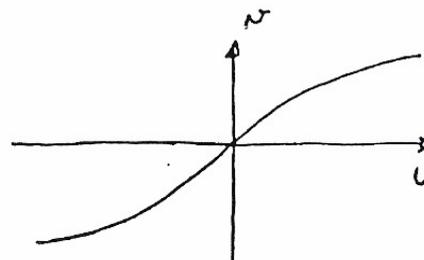
$$= t_0 + \sum \left[\frac{t_i}{2} tgh \underline{w_i^t x} + \frac{t_i}{2} \right]$$

$$= a_0 + \sum a_i tgh \underline{w_i^t x}$$

2 - Um neurônio tipo $\log(\cdot)$ tem função de excitação u e de ativação v dadas por

$$u = \sum_0^n w_i x_i \quad x_0 = 1$$

$$v = \begin{cases} \ln(1+u) & u \geq 0 \\ -\ln(1-u) & u < 0 \end{cases}$$



2.1 - Desenvolva um processo de aprendizado BP para uma rede com duas camadas, usando neurônios tipo log na camada intermediária e neurônios lineares e/ou tipo tgh na camada de saída, como na rede abaixo. A função objetivo a ser minimizada é o e.m.q. na saída. Apresente um algoritmo que determine de forma explícita os acréscimos a serem aplicados nas sinapses da primeira e da segunda camada, w_{ij} e t_{ij} .

$$F = E e$$

Para cada per

$$e = |y - \tilde{y}|^2 = \sum_l (y_l - \tilde{y}_l)^2 = \sum_l \epsilon_l^2$$

$$\frac{\partial \epsilon_l^2}{\partial w_{ij}} = 2 \epsilon_l \frac{\partial \epsilon_l}{\partial w_{ij}} = -2 \epsilon_l \frac{\partial \tilde{y}_l}{\partial w_{ij}}$$

$$= -2 \epsilon_l \frac{\partial \tilde{y}_l}{\partial u_i} \frac{\partial u_i}{\partial w_{ij}} = -2 \rho_j \epsilon_l \theta_{li}$$

$$\frac{\partial e}{\partial w_{ij}} = -2 \rho_j \sum_l \epsilon_l \theta_{li} = -2 \rho_j \delta_i$$

↑ só altera θ_{li}

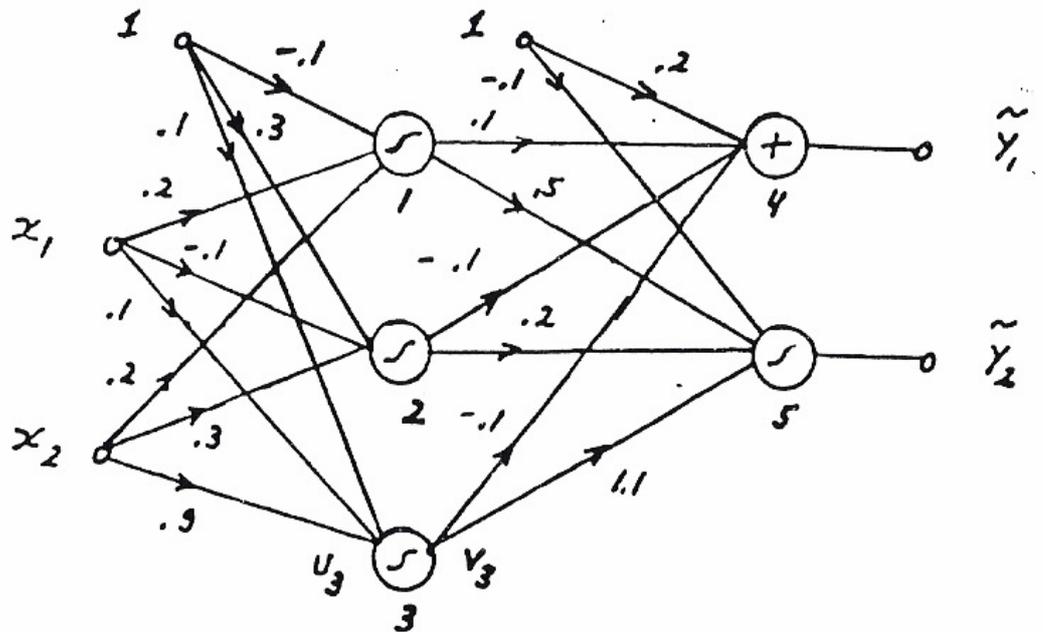
Rede associada

$$\rho = \pm \ln(1 \pm u) \longrightarrow \frac{1}{1 \pm u} = \frac{1}{1 + |u|}$$

$$\rho = u \longrightarrow 1$$

$$\rho = \tanh(u) \longrightarrow 1 - \rho^2$$

2.2 - Na rede abaixo os neurônios 1, 2, 3 são tipo log, o neurônio 4 é linear ($v = u$) e o 5 é tipo tgh. O treinamento é tipo regra delta sem momento com $\alpha = 0,1$. É apresentado o par entrada-saída $\{\underline{x} ; \underline{y}\}$, onde $\underline{x} = [0,1 ; 0,7]^t$ e $\underline{y} = [0,2 ; 1,0]^t$. Quais os novos valores das sinapses após o passo de treinamento ?



Signal feed-forward

$$u_1 = -0.1 + (0.1)(0.2) + (0.7)(0.2) = 0.06$$

$$p_1 = + \ln(1 + 0.06) = 0.058 \quad g_1 = \frac{1}{1 + 0.06} = 0.94$$

$$u_2 = 0.3 + (0.1)(-0.1) + (0.7)(0.2) = 0.43$$

$$p_2 = + \ln(1.43) = 0.358 \quad g_2 = \frac{1}{1.43} = 0.70$$

$$u_3 = 0.1 + (0.1)(0.1) + (0.7)(0.9) = 0.74$$

$$p_3 = + \ln(1.74) = 0.554 \quad g_3 = \frac{1}{1.74} = 0.575$$

$$u_4 = 0.2 + (0.058)(0.1) + (0.358)(-0.1) + (0.554)(-0.1) = 0.115$$

$$p_4 = u_4 = 0.115 \quad g_4 = 1$$

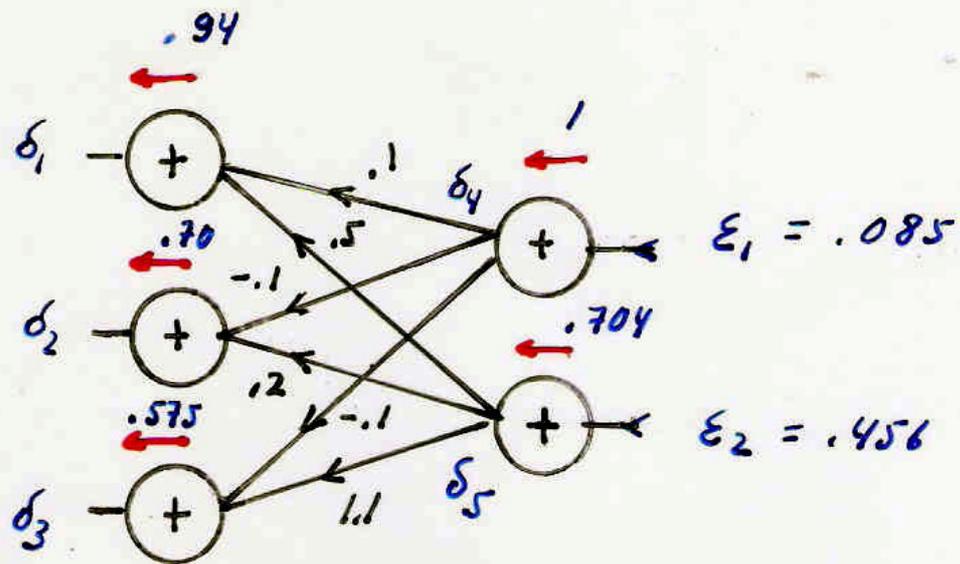
$$u_5 = -0.1 + (0.058)(0.5) + (0.358)(0.2) + (0.554)(1.1) = 0.61$$

$$p_5 = \tanh 0.61 = 0.544 \quad g_5 = 1 - 0.544^2 = 0.704$$

$$e_1 = 0.2 - 0.115 = 0.085$$

$$e_2 = 1 - 0.544 = 0.456$$

Rede associada



Retropropagação do erro

$$\delta_4 = .085 (1) = .085$$

$$\delta_5 = .456 (.704) = .321$$

$$\delta_1 = [.085 (.1) + (.321) (.5)] .94 = .158$$

$$\delta_2 = [.085 (-.1) + (.321) (.2)] .70 = -.015$$

$$\delta_3 = [.085 (-.1) + (.321) (1.1)] .575 = .157$$

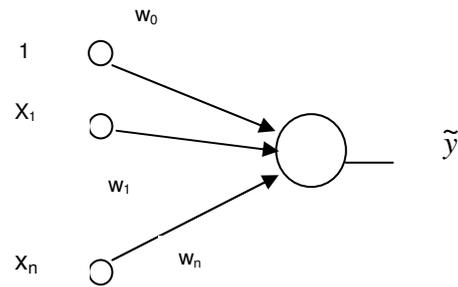
Correção das sinapses

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

3 - Considere uma rede neural que utiliza um único neurônio linear, como na figura abaixo,

$$u = \sum_{i=0}^n w_i x_i = \underline{w}^t \underline{x}$$

e $\tilde{y} = u$,



treinada usando backpropagation regra delta com $\alpha = 0,2$ e sem momento. No início do i -ésimo passo de treinamento o vetor sinapse é $\underline{w}(i-1)$. É então apresentado o par entrada-saída $\{\underline{x}(i), y(i)\}$ e o novo \underline{w} é calculado,

$$\underline{w}(i) = \underline{w}(i-1) + \Delta \underline{w}(i)$$

3a - Deseja-se retroceder este passo. É possível calcular $\underline{w}(i-1)$ conhecendo-se apenas $\underline{w}(i)$ e $\{\underline{x}(i), y(i)\}$? Se sim, apresente uma fórmula explícita $\underline{w}(i-1) = f\{\underline{w}(i), \underline{x}(i), y(i)\}$.

Signal feedforward

$$\underline{x}_i \longrightarrow \tilde{y}_i = \underline{x}_i^t \underline{w}_{i-1}$$

Erro $\epsilon = y_i - \tilde{y}_i = y_i - \underline{x}_i^t \underline{w}_{i-1}$

Correção sinapses

$$\Delta w_k = 2\alpha x_k \epsilon$$

$$\Delta \underline{w} = 2\alpha \underline{x}_i \epsilon$$

$$= 2\alpha \underline{x}_i [y_i - \underline{x}_i^t \underline{w}_{i-1}]$$

Novo valor da sinapse

$$\underline{w}_i = \underline{w}_{i-1} + \Delta \underline{w}$$

$$= \underline{w}_{i-1} + 2\alpha \underline{x}_i \left[y_i - \underline{x}_i^t \underline{w}_{i-1} \right]$$

$$\underline{w}_{i-1} - 2\alpha \underline{x}_i \underline{x}_i^t \underline{w}_{i-1} = \underline{w}_i - 2\alpha y_i \underline{x}_i$$

$$\left[\underline{I} - 2\alpha \underline{x}_i \underline{x}_i^t \right] \underline{w}_{i-1} = \underline{w}_i - 2\alpha y_i \underline{x}_i$$

$$\therefore \underline{w}_{i-1} = \left[\underline{I} - 2\alpha \underline{x}_i \underline{x}_i^t \right]^{-1} \left[\underline{w}_i - 2\alpha y_i \underline{x}_i \right]$$

3b - Repita agora para o caso em que o neurônio é do tipo $\tilde{y} = \tanh(u)$, apresentando a equação a ser resolvida para determinar $\underline{w}(i-1)$. Obs: use formulação matricial.

Caso $\tilde{y} = \tanh u$

$$\tilde{y}_i = \tanh \underline{x}_i^t \underline{w}_{i-1}$$

$$\varepsilon = y_i - \tanh \underline{x}_i^t \underline{w}_{i-1}$$

$$\Delta \underline{w} = 2\alpha \underline{x}_i \varepsilon (1 - \tilde{y}_i^2)$$

$$\underline{w}_i = \underline{w}_{i-1} + \Delta \underline{w}$$

$$= \underline{w}_{i-1} + 2\alpha \underline{x}_i \left[y_i - \tanh \underline{x}_i^t \underline{w}_{i-1} \right]$$

$$\left[1 - \tanh^2 \underline{x}_i^t \underline{w}_{i-1} \right]$$

eq. transcendente em \underline{w}_{i-1}

Soluções:

1 - Linearização (Taylor)

$$\begin{array}{c} \underline{x}^t \underline{w}_{i-1} \\ \uparrow \\ v + \Delta v \end{array} = \begin{array}{c} \underline{x}^t \underline{w}_i \\ \uparrow \\ v \end{array} + \begin{array}{c} \underline{x}^t (-\Delta \underline{w}) \\ \uparrow \\ \Delta v \end{array}$$

$$\text{tgh}(v + \Delta v) = \text{tgh} v + (1 - \text{tgh}^2 v) \Delta v$$

2 - Otimização (gradiente descendente)

4 - Considere uma rede feedforward multicamadas com neurônios do tipo $v = \text{tgh} u$. Estabeleça um algoritmo de treinamento que minimize o erro de saída F_0 abaixo:

$$F_0 = E\left\{ \sum_{i=1}^m \left[3 \left(\frac{y_i - \tilde{y}_i}{y_i} \right)^2 + 5 (y_i - \tilde{y}_i)^2 \right] \right\}$$

Apresente um algoritmo explícito para os acréscimos nas sinapses do tipo:

$$\Delta w_{ij} = f[\alpha, \varepsilon_l, g_{li}] \quad \text{onde } \varepsilon_l = y_l - \tilde{y}_l \quad \text{e} \quad g_{li} = \frac{\partial \tilde{y}_l}{\partial u_i}$$

Observe que na dedução do método backpropagation usamos a regra de cadeia $\frac{\partial F}{\partial w_{ij}} = \sum_k \frac{\partial F}{\partial \tilde{y}_k} \frac{\partial \tilde{y}_k}{\partial w_{ij}}$ onde os primeiros termos, $\frac{\partial F}{\partial \tilde{y}_k}$, dependem apenas da função objetivo a ser minimizada, e os segundos termos, $\frac{\partial \tilde{y}_k}{\partial w_{ij}}$, dependem apenas da rede a ser utilizada.

$$F = E \sum_i e_i$$

$$\frac{\partial}{\partial w_{ij}} \sum_i e_i = \sum_i \frac{\partial}{\partial w_{ij}} \left\{ \frac{3}{Y_i^2} \varepsilon_i^2 + 5 \varepsilon_i^2 \right\}$$

$$\varepsilon_i = Y_i - \tilde{Y}_i$$

$$= \sum_i \frac{\partial e_i}{\partial \varepsilon_i} \frac{\partial \varepsilon_i}{\partial \tilde{Y}_i} \frac{\partial \tilde{Y}_i}{\partial w_{ij}}$$

$$= \sum_i \left\{ \frac{6}{Y_i^2} \varepsilon_i + 10 \varepsilon_i \right\} (-1) \frac{\partial \tilde{Y}_i}{\partial w_{ij}}$$

$$= -2 \sum_i \left\{ \frac{3}{Y_i^2} + 5 \right\} \varepsilon_i \underbrace{\frac{\partial \tilde{Y}_i}{\partial u_i}}_{\delta_{ii}} \underbrace{\frac{\partial u_i}{\partial w_{ij}}}_{\mu_j}$$

$$2 \mu_j \sum_i \left\{ \frac{3}{Y_i^2} + 5 \right\} \varepsilon_i \delta_{ii}$$

$$= 2 \alpha \frac{\partial e}{\partial w_{ij}} =$$

$$= 2 \alpha \mu_j \sum_i \underbrace{\left\{ \frac{3}{Y_i^2} + 5 \right\} \varepsilon_i}_{\varepsilon_i'} \underbrace{\delta_{ii}}_{\delta_i}$$