

## CPE 721 – RNs Feedforward

### 2ª Série de Exercícios - Treinamento BP

**Obs: O objetivo da série de exercícios é a fixação do aprendizado. A série pode ser feita em grupo, mas é importante que cada um tente achar as soluções individualmente antes do trabalho em grupo.**

1 – A função logística  $L(u)$  também é utilizada como função de ativação em redes neurais feedforward. Escreva a relação entre as funções de ativação logística  $L(u)$  e tangente hiperbólica  $tgh(u)$ , e também entre suas derivadas  $dL(u)/du$  e  $d\,tgh(u)/du$  em função de  $u$  e de  $L(u)$  e  $tgh(u)$ , respectivamente.

$$L(u) = \frac{1}{1 + e^{-2u}} \quad tgh(u) = \frac{e^u - e^{-u}}{e^u + e^{-u}} = \frac{1 - e^{-2u}}{1 + e^{-2u}}$$

1.1 - Mostre que o custo computacional de treinar ou operar as duas redes é similar, comparando o número e tipo de operações (somas multiplicações e exponenciações) necessárias para calculá-las.

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. Sugestão: mostre que as séries que representam as saídas são similares.

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


$$u = \sum_{i=0}^n w_i x_i \quad x_0 = 1$$

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




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  $t_{ij}$ .

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 ?



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

$$u = \sum_{i=0}^n w_i x_i = \underline{w}^t \underline{x} \quad \text{e} \quad \tilde{y} = u,$$



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  $\underline{w}(i-1) = f\{\underline{w}(i), \underline{x}(i), y(i)\}$ .

3b - Repita agora para o caso em que o neurônio é do tipo  $\tilde{y} = \text{tgh}(u)$  apresentando a equação a ser resolvida para determinar  $\underline{w}(i-1)$ .

Sugestão: use formulação matricial.

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:

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

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.