


## 12 -Outros critérios de erro

### Composição de F como erro



$$F(\underline{y}, \underline{\tilde{y}}) \quad \underline{\tilde{y}}(\underline{w}) \quad \frac{\partial F}{\partial w_i} = \frac{\partial F}{\partial \tilde{y}} \frac{\partial \tilde{y}}{\partial w_i}$$

onde  $\frac{\partial F}{\partial \tilde{y}}$  depende da função erro utilizada e  
 $\frac{\partial \tilde{y}}{\partial w_i}$  depende das equações da rede

no caso de saídas múltiplas  $\frac{\partial F}{\partial w_i} = \sum_{l=1}^m \frac{\partial F}{\partial \tilde{y}_l} \frac{\partial \tilde{y}_l}{\partial w_i}$

### Caso geral: Erro médio quadrático ponderado

$$F = \mathbf{E}_k \left\{ \sum_l a(k, l) \varepsilon_l^2 \right\}$$

onde  $a(l)$  peso variável por saída  $l$

$a(k)$  peso variável por par  $k$

como  $\varepsilon_l = y_l - \tilde{y}_l$

$$\frac{\partial F}{\partial \tilde{y}} = -2 \mathbf{E}_k \left\{ \sum_l a(k, l) \varepsilon_l \right\}$$

No treinamento tipo regra delta o acréscimo na sinapse  $w_{ij}$  será dado por

$$\Delta w_{ij} = 2\alpha v_j \delta_i \quad \text{onde} \quad \delta_i = \sum_{l=1}^m a(k,l) \epsilon_l g_{li}$$

onde

$v_j$  é o sinal na entrada da sinapse na fase de propagação do sinal para a frente e


$g_{li} = \frac{\partial \tilde{y}_l}{\partial u_i}$  é o ganho linearizado da saída da sinapse  $w_{ij}$  à saída  $l$  da rede

### Ex 1 : Ponderando diferentemente saídas diferentes

A rede tem duas saídas, mas o erro em  $y_1$  é 3 vezes mais importante que o erro em  $y_2$

$$a(k,1) = 3$$

$$a(k,2) = 1$$



$$F = E_k (3\epsilon_1^2 + \epsilon_2^2)$$

$$\Delta w_{ij} = 2\alpha v_j \delta_i \quad \text{onde} \quad \delta_i = 3\epsilon_1 g_{1i} + \epsilon_2 g_{2i}$$

**Ex 2 : Ponderando diferentemente em função da saída desejada**

Falsos negativos x falsos positivos com pesos diferentes

$$F = \frac{1}{4P} \sum_{\forall p} a(y) \varepsilon^2 = \frac{1}{4P} \sum_{\forall p} [(M-1)y + (M+1)](y - \tilde{y})^2 =$$

$$= \frac{1}{4P} \left[ \sum_{\substack{\forall p|y=1 \\ \forall \text{ pares positivos}}} 2M(y - \tilde{y})^2 + \sum_{\substack{\forall p|y=-1 \\ \forall \text{ pares negativos}}} (y - \tilde{y})^2 \right]$$

Tipo	y	$\tilde{y}$	contribuição para F
verdadeiros positivos	1	1	0
verdadeiros negativos	-1	-1	0
falsos positivos	-1	1	1
falsos negativos	1	-1	2M

casos:  
doenças humanas,  
tuberculose bovina,  
etc.

**Ex 3: Erro relativo médio quadrático****Erro relativo médio quadrático nas variáveis originais, não escaladas**

$$F(\underline{w}) = E \left\{ \sum_l \left[ \frac{Y_l - \tilde{Y}_l}{Y_l} \right]^2 \right\}$$

$$y_l = \frac{1}{\sigma_{Y_l}} (Y_l - \mu_{Y_l})$$

$$Y_l = \sigma_{Y_l} y_l + \mu_{Y_l}$$

$$\tilde{Y}_l = \sigma_{Y_l} \tilde{y}_l + \mu_{Y_l}$$

$$F(\underline{w}) = E \left\{ \sum_l \left[ \frac{Y_l - \tilde{Y}_l}{Y_l} \right]^2 \right\} = E \left\{ \sum_l \frac{1}{\left( y_l + \frac{\mu_{Y_l}}{\sigma_{Y_l}} \right)^2} (y_l - \tilde{y}_l)^2 \right\}$$

$$a(k, l) = \frac{1}{\left( y_l + \frac{\mu_{Y_l}}{\sigma_{Y_l}} \right)^2}$$

No treinamento tipo BP o acréscimo na sinapse  $w_{ij}$  é dado por


$$\Delta w_{ij} = 2\alpha v_j \delta_i \quad \text{onde} \quad \delta_i = \sum_{l=1}^m \frac{1}{\left(y_l + \frac{\mu_{Y_l}}{\sigma_{Y_l}}\right)^2} \varepsilon_l g_{li}$$

#### Ex 4: Correção do efeito da população local

Cada par pertence a uma região  $R_i$

Cada região  $R_i$  tem uma população  $n_i$

A população total é  $n = \sum_{\forall i} n_i$



$$F = \sum_{\forall \text{ região } R_i} \sum_{\forall \text{ par} \in R_i} f(y, \tilde{y}) \quad \text{peso: } n_i \text{ pares}$$

$$F = \sum_{\forall \text{ região } R_i} \frac{1}{n_i} \sum_{\forall \text{ par} \in R_i} f(y, \tilde{y}) \quad \text{peso: 1 par, independe de } n_i$$

$$a(i, l) = a(i) = 1/n_i$$

$n_i$  – população da região onde o par pertence.

## 12.2 Erros não quadráticos

### 12.2.1 Erros em potências maiores

$$F(\underline{w}) = E \left\{ \sum_l (y_l - \tilde{y}_l)^{2n+2} \right\} \quad n = 1, 2, \dots$$

prioriza a redução dos maiores erros, mas  $F(\underline{w})$  é mais abrupta.

### 12.2.2 Erro absoluto

$$F(\underline{w}) = E \left\{ \left| \bar{y} - \tilde{\bar{y}} \right| \right\} = E \left\{ \sqrt{\sum_l (y_l - \tilde{y}_l)^2} \right\}$$

não prioriza a redução dos maiores erros como o emq

- não derivável na origem, necessita procedimentos especiais

### 12.2.3 Erro MAPE – Mean Absolute Percentual Error

$$F(\underline{w}) = E \left\{ \frac{\left| \bar{Y} - \tilde{\bar{Y}} \right|}{\left| \bar{Y} \right|} \right\} = E \left\{ \sqrt{\frac{\sum_l (Y_l - \tilde{Y}_l)^2}{\sum_l (Y_l)^2}} \right\}$$

variáveis não escaladas

não prioriza a redução dos maiores erros percentuais, como o epmq.


- não derivável na origem, necessita procedimentos especiais

## 12.3 Entropia

O objetivo na minimização do erro  $\varepsilon$  é

obter o histograma de  $p(\varepsilon)$  com média nula (fácil) e o mais estreito possível

ideal:  $p(\varepsilon) = \delta(0)$  (delta de Dirac, erro nulo)



Se a distribuição do erro  $p(\varepsilon)$  for Gaussiana, o objetivo é alcançado minimizando o erro médio quadrático (a variância de  $p(\varepsilon)$ )

Se a distribuição do erro  $p(\varepsilon)$  não for Gaussiana, o objetivo é alcançado minimizando a entropia (ver os trabalhos de J.C. Príncipe)

## 12.4 - Erro lógico (já visto em classificadores)

$$y \in \{-1, +1\} \quad \tilde{y} = \text{tgh}(u) \in (-1, +1)$$

$$\tilde{y}_{\text{lógico}} = \text{sign}(\tilde{y})$$

**Erro médio quadrático**

$$\frac{1}{N} \sum_i (y_i - \tilde{y}_i)^2$$

**Erro de classificação**

$$\frac{1}{4N} \sum_{i=1}^N (y_i - \tilde{y}_{i \text{ lógico}})^2$$

**% de classificações erradas em  $y_i$**