

## Processo de aproximações sucessivas ao Eqm mínimo:

- Chute um vetor W inicial, e chame-o de “Wcorrente”, ou “W melhor até agora”
- Em loop EXTERNO, repita 1, 2 e 3 a seguir, até obter Eqm zero, ou Eqm baixo o suficiente, ou Eqm estável, ou estourar um número de adaptações  $\Delta W$  limite:
  - 1) Determine o vetor gradiente do Eqm, nesse espaço de Ws. Essa determinação é feita através de um loop varrendo todos os M exemplos  $(\bar{X}^\mu; y^\mu)$ . Cada passo desse loop INTERNO envolve 1.1, 1.2 e 1.3 como segue:
    - 1.1) Calcule o gradiente de  $Eq^\mu$  associado a apenas um exemplo  $\mu$ :
    - 1.2) Cada cálculo desses, associado a um  $\mu$  apenas, envolve calcular tantas derivadas parciais de  $Eq^\mu$  quantos pesos existam na rede. Isso exige primeiro calcular o valor do argumento de cada tangente hiperbólica e depois usar esses valores dos argumentos nas derivadas da regra da cadeia, necessárias ao cálculo das derivadas parciais de  $Eq^\mu$  com relação aos vários pesos da rede;
    - 1.3) Vá varrendo  $\mu$  (lembre que  $\mu$  vai de 1 até M), e somando os gradientes obtidos para cada  $Eq^\mu$ , para ir compondo o vetor gradiente de Eqm, que na verdade é a soma de todos os gradientes coletados para os diversos  $\mu$ ; saia deste loop INTERNO somente quando passar por todos os  $\mu$ .
  - 2) Ao sair do Loop INTERNO acima, estamos prontos para dar um pequeno passo vetorial  $\Delta W$  no espaço de pesos, com a direção e magnitude dados por  $-\eta \cdot$  vetor gradiente de Eqm. Com isso, atualizamos / melhoramos o vetor Wcorrente
  - 3) Em seguida a dar tal passo  $\Delta W$ , avalie se Eqm é pequeno / estável / decrescente, etc, e se não decidir parar o processo, prepare-se para um novo pequeno passo  $\Delta W$  (volte ao passo do cálculo do gradiente – passo 1)

Prof. Emilio Del Moral – 2012 – PSI2533 – EPUSP ·

### ... Relação entre gradiente descendente do erro e as derivadas parciais de $y_{rede}$ com relação aos pesos sinápticos e com relação aos $y_{nó}$

$$\Delta \vec{W} = -\eta \cdot \vec{\nabla} Eqm = -\eta \cdot \left( \frac{\partial Eqm}{\partial w_1}, \frac{\partial Eqm}{\partial w_2}, \frac{\partial Eqm}{\partial w_3} \dots \right)$$

$$\begin{aligned} \frac{\partial Eqm}{\partial w_{específico}} &= \\ &= \frac{1}{M} \sum_{\mu=1}^M \frac{\partial Eq^\mu}{\partial w_{específico}} = \frac{1}{M} \sum_{\mu=1}^M \left[ \frac{\partial Eq^\mu}{\partial y_{rede}(\bar{X}^\mu, W)} \cdot \left[ \frac{\partial y_{rede}(\bar{X}^\mu, W)}{\partial w_{específico}} \right] \right] \\ &= \frac{1}{M} \sum_{\mu=1}^M \left[ 2 \cdot (y_{rede}(\bar{X}^\mu, W) - y^\mu) \cdot \left[ \frac{\partial y_{rede}(\bar{X}^\mu, W)}{\partial w_{específico}} \right] \right] \\ &= \frac{1}{M} \sum_{\mu=1}^M \left[ 2 \cdot (y_{rede}(\bar{X}^\mu, W) - y^\mu) \cdot \left[ \frac{\partial y_{rede}(\bar{X}^\mu, W)}{\partial y_{nó}} \right] \cdot \left[ \frac{\partial y_{nó}(\bar{X}^\mu, W)}{\partial w_{específico}} \right] \right] \end{aligned}$$

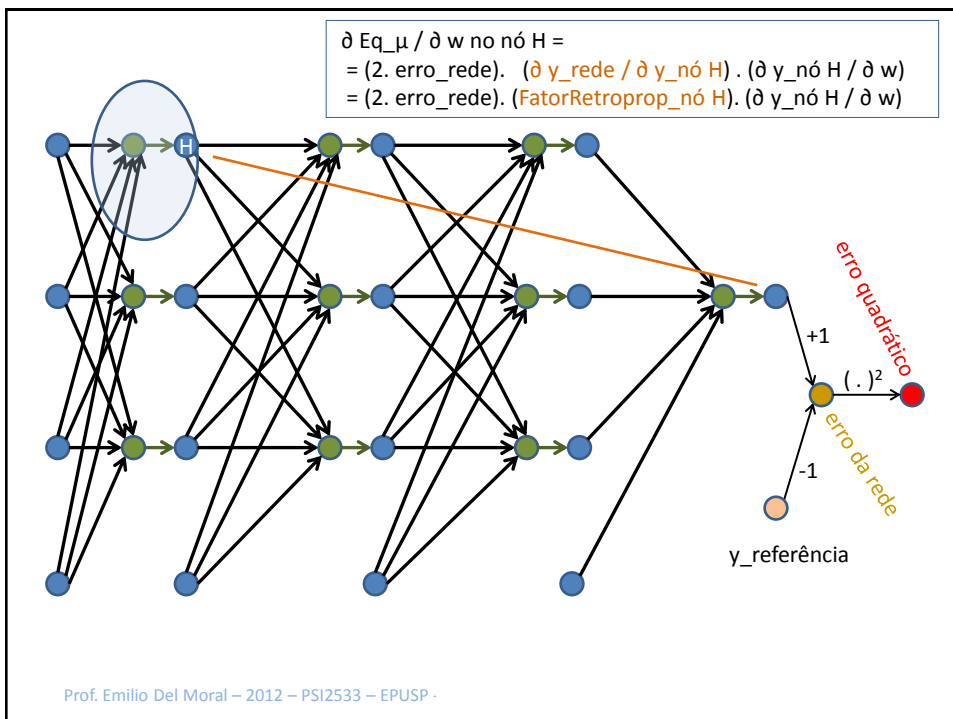
Prof. Emilio Del Moral – 2012 – PSI2533 – EPUSP ·

## Definição, e uma das interpretações do Retropropagador ( $\partial y_{rede} / \partial y_{nó}$ )

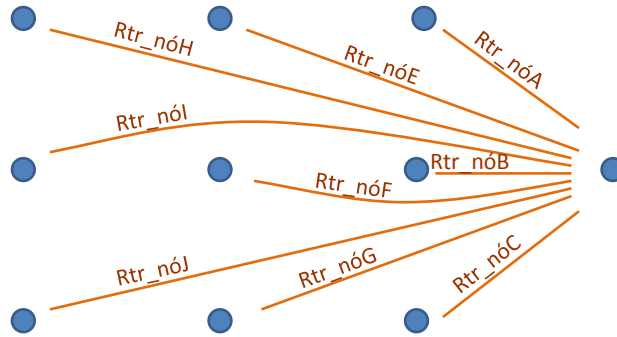
- Definição: ( $\partial y_{rede} / \partial y_{nó}$ )
- Uma interpretação: ele nada mais é que o segundo “1/3” de uma cadeia de 3 passos, no cálculo de ( $\partial Eq_{\mu} / \partial w$ ):

$$\begin{aligned} \partial Eq_{\mu} / \partial w &= \\ &= (\partial Eq_{\mu} / \partial y_{rede}) \cdot (\partial y_{rede} / \partial y_{nó}) \cdot (\partial y_{nó} / \partial w) \\ &= (2 \cdot erro_{rede}) \cdot (\partial y_{rede} / \partial y_{nó}) \cdot (\partial y_{nó} / \partial w) \\ &= (2 \cdot erro_{rede}) \cdot (\text{FatorRetroprop}_{nó}) \cdot (\partial y_{nó} / \partial w) \end{aligned}$$

Prof. Emilio Del Moral – 2012 – PSI2533 – EPUSP



*Temos um retropropagador para cada nó da rede, a excessão do nó de saída*



Prof. Emilio Del Moral – 2012 – PSI2533 – EPUSP ·

# ERROR BACK PROPAGATION

Prof. Emilio Del Moral – 2012 – PSI2533 – EPUSP ·

## Algumas interpretações alternativas para o fator de retro-propagação de cada nó

- 1) Ele nada mais é que o segundo “1/3” de uma cadeia de 3 passos, no cálculo de  $(\partial \text{Eq}_\mu / \partial w)$ :
 
$$\begin{aligned} \partial \text{Eq}_\mu / \partial w &= (\partial \text{Eq}_\mu / \partial y_{\text{rede}}) \cdot (\partial y_{\text{rede}} / \partial y_{\text{nó}}) \cdot (\partial y_{\text{nó}} / \partial w) \\ &= (2 \cdot \text{erro\_rede}) \cdot (\partial y_{\text{rede}} / \partial y_{\text{nó}}) \cdot (\partial y_{\text{nó}} / \partial w) \\ &= (2 \cdot \text{erro\_rede}) \cdot (\text{FatorRetroprop\_nó}) \cdot (\partial y_{\text{nó}} / \partial w) \end{aligned}$$
- 2) Ele nada mais é que a derivada da saída da rede com relação a cada nó. Indica portanto, quando em produto juntamente com o fator  $(2 \cdot \text{erro\_rede})$ , como uma variação na saída do nó afeta o decréscimo do erro quadrático. Essa indicação do produto  $[\text{FatorRetro\_nó} \cdot 2 \cdot (\text{erro})]$  se dá tanto em direção (sinal) quanto em magnitude, já que é uma derivada  $(\partial \text{Eq}_\mu / \partial y_{\text{nó}})$ . O vetor de todos os retropropagadores portanto define a importância relativa (em magnitude e em sinal) de cada nó na formação do gradiente do erro e portanto a importância relativa entre nós na diminuição do  $\text{Eq}_\mu$ , quando seus pesos são alterados
- 3) ... Esta fica clara adiante: Ele é um fator multiplicativo que permite transformar o erro da saída da rede num “erro local” de cada nó, sobre o qual a regra Delta local (regra do gradiente descendente para um nó) pode ser aplicada individualmente a cada nó, com erros diferenciados de maneira a manter adaptação concatenada na mesma direção do gradiente descendente conjunto. Isto ocorre porque  $\partial \text{Eq}_\mu / \partial w \dots$ 

$$\begin{aligned} &= (2 \cdot \text{erro\_rede}) \cdot (\text{FatorRetroprop\_nó}) \cdot (\partial y_{\text{nó}} / \partial w) \\ &= (2 \cdot [\text{erro\_rede} \cdot \text{FatorRetroprop\_nó}] \cdot (\partial y_{\text{nó}} / \partial w)) \end{aligned}$$

Prof. Emilio Del Moral – 2012 – PS12533 – EPUSP

## Alternativa à retro-propagação de 1 passo: retro-propagação camada a camada

- Até o momento vimos como implementar o gradiente descendente com o conceito de retro-propagadores, que são calculados para cada nó individualmente e usados na seguinte expressão:

$$\begin{aligned} \partial \text{Eq}_\mu / \partial w &= (\partial \text{Eq}_\mu / \partial y_{\text{rede}}) \cdot (\partial y_{\text{rede}} / \partial y_{\text{nó}}) \cdot (\partial y_{\text{nó}} / \partial w) \\ &= (2 \cdot \text{erro\_rede}) \cdot (\partial y_{\text{rede}} / \partial y_{\text{nó}}) \cdot (\partial y_{\text{nó}} / \partial w) \\ &= (2 \cdot \text{erro\_rede}) \cdot (\text{FatorRetroprop\_nó}) \cdot (\partial y_{\text{nó}} / \partial w) \end{aligned}$$

- Veremos agora uma forma alternativa, com cálculos recursivos e apoio no conceito de erro retro-propagado em cada nó, com base na seguinte revisita a  $\partial \text{Eq}_\mu / \partial w \dots$

$$= (2 \cdot \text{erro\_rede}) \cdot (\text{FatorRetroprop\_nó}) \cdot (\partial y_{\text{nó}} / \partial w)$$

$$= (2 \cdot [\text{erro\_rede} \cdot \text{FatorRetroprop\_nó}] \cdot (\partial y_{\text{nó}} / \partial w))$$


  
 Definição de erro de nó


Prof. Emilio Del Moral – 2012 – PS12533 – EPUSP

Definindo novas variáveis: uma nova variável auxiliar associada a cada nó, chamada **erro do nó**

$$\text{erro do nó} = [(\text{erro da rede}) \times (\text{retropagador do nó})]$$

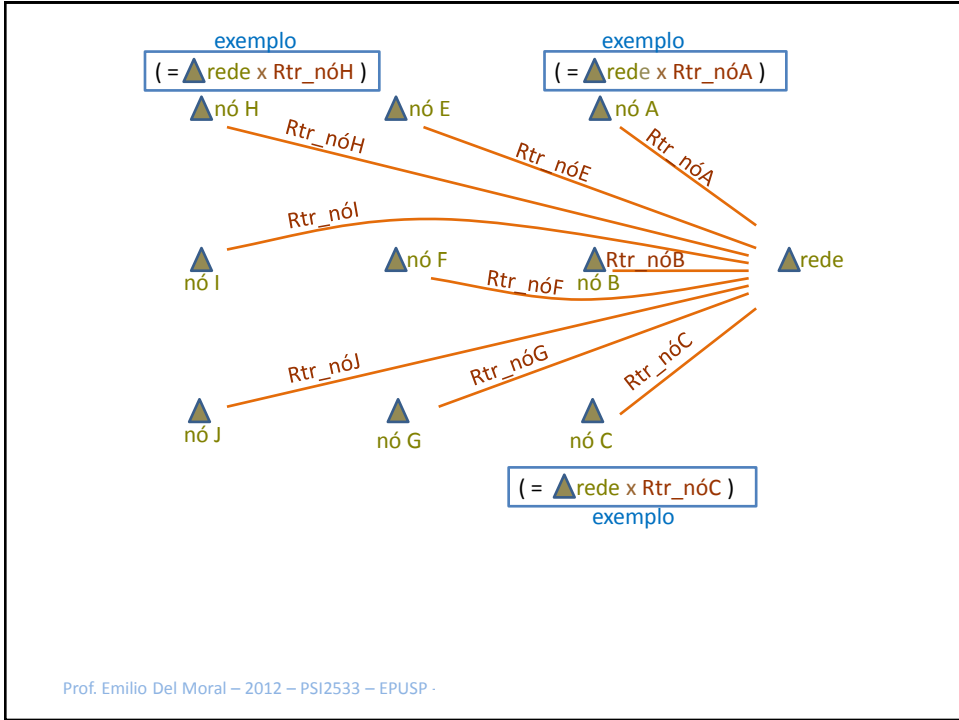
$$= [(y_{\text{rede}} - y_{\mu}) \times (\text{del yrede} / \text{del y nó})]$$

Prof. Emilio Del Moral – 2012 – PSI2533 – EPUSP ·





Os triângulos representam os erros associados a cada nó

Prof. Emilio Del Moral – 2012 – PSI2533 – EPUSP ·

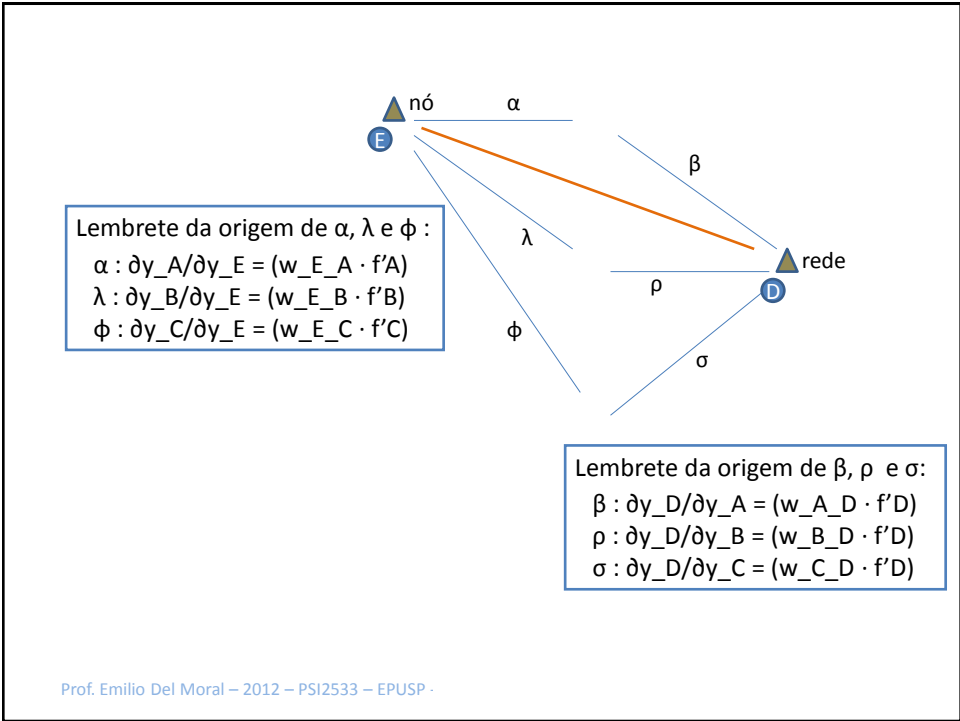


*De aula anterior, ficou claro que os trechos “w.f(v)” em azul calculados antecipadamente são re-usados varias vezes na composição dos diversos retropropagadores de nós genericos*


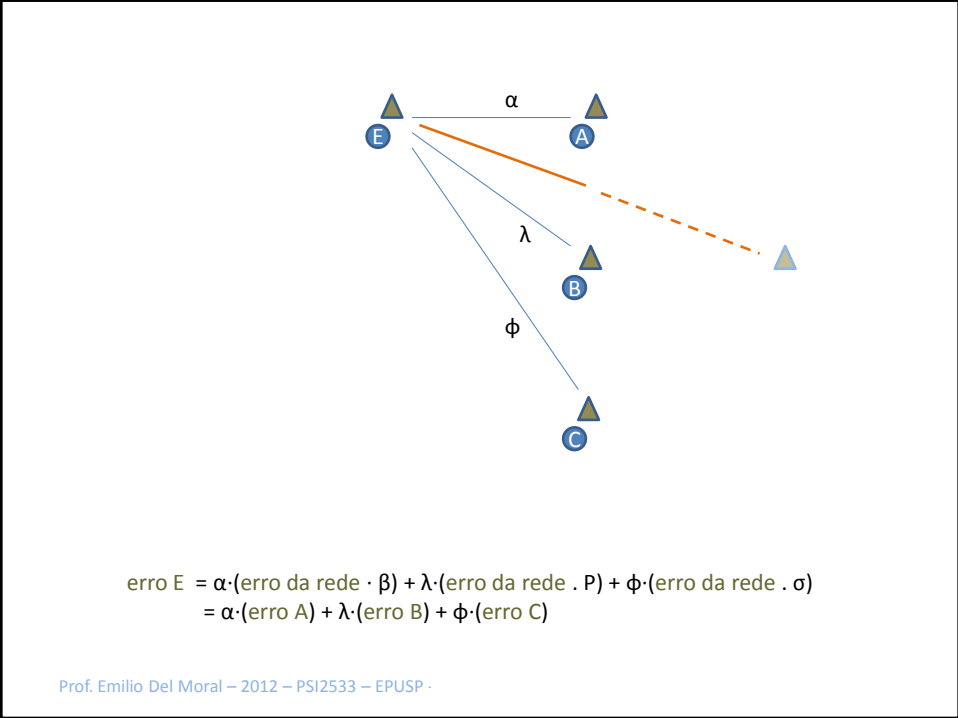




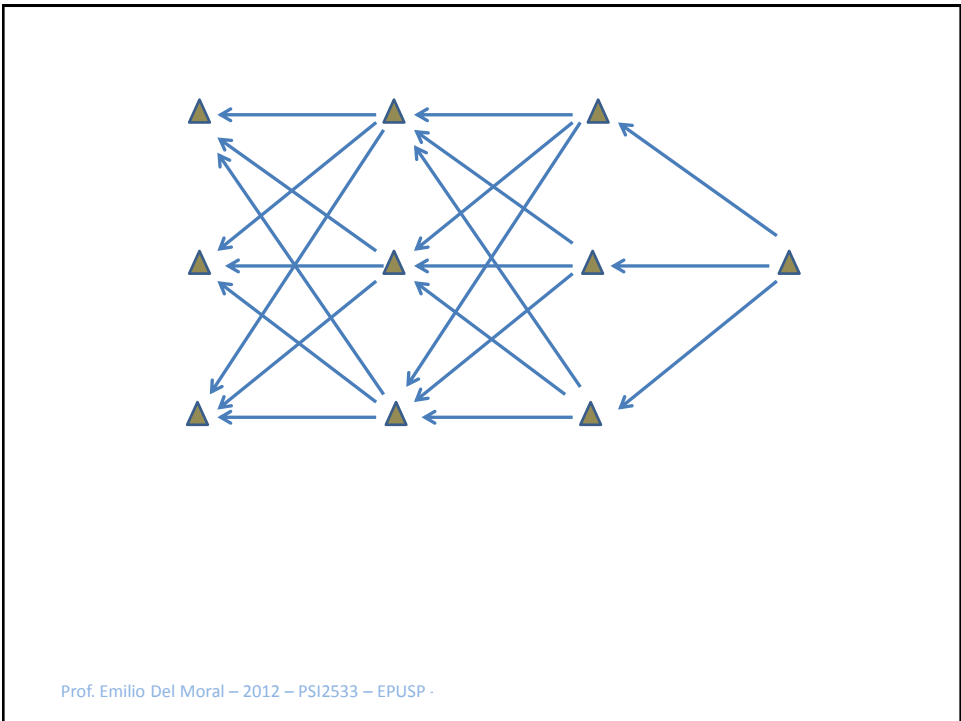

Prof. Emilio Del Moral – 2012 – PSI2533 – EPUSP ·



Prof. Emilio Del Moral – 2012 – PSI2533 – EPUSP ·







## Resumo do EBP em 3 passos

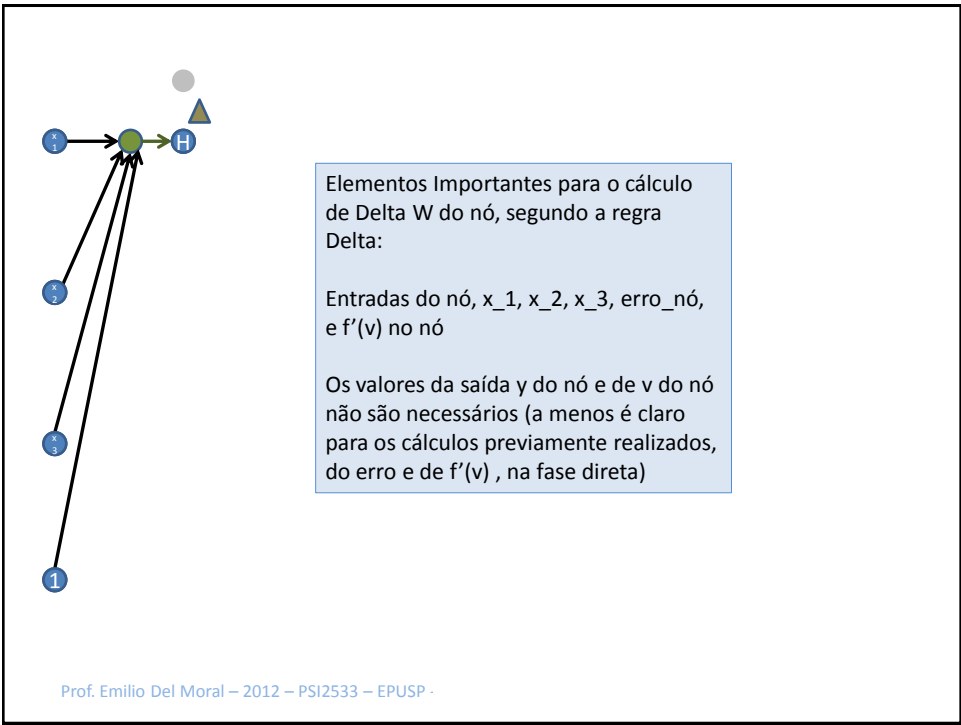

- Passo 1 - de Fluxo Direto:
  - Cálculo de  $V, Y, Y'$ , camada a camada, da 1ª à última
  - Cálculo de erro da rede,  $y(X_{\mu}) - y_{\mu}$
  - Cálculos das “derivadas de trecho”:  $[w_{\text{nó1}_\text{nó2}} \times f'_{\text{nó2}}(v)]$
- Passo 2 - de Fluxo Reverso:
  - Cálculo dos erros de nós (“deltas”), camada a camada, da última para a primeira, com o uso da técnica de retro-propagação em passos, camada a camada
- Passo 3 - de Cálculo de Adaptação de Pesos para o exemplar  $\mu$ 
  - Aplicar a regra Delta Clássica (de 1 nó), em paralelo = calculando simultaneamente as adaptações de todos os nós
  - Cada aplicação local da regra clássica envolve: saídas  $Y$  da camada anterior, erro no nó (delta retro-propagado) e  $f'(v)$  do nó
  - Guarde em memória o Delta  $W_{\mu}$  “recomendado pelo exemplar  $\mu$  sendo analisado”, sem adaptar pesos ainda!!! A adaptação só ocorrerá com a média total das recomendações individuais dadas por todos os  $M$  exemplares de treino.

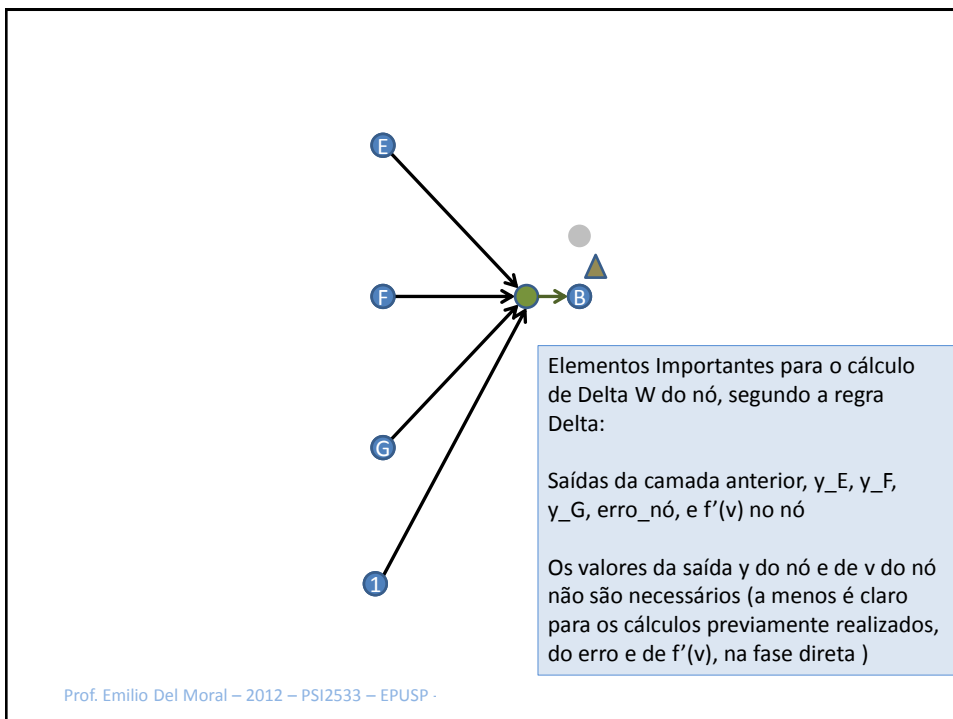
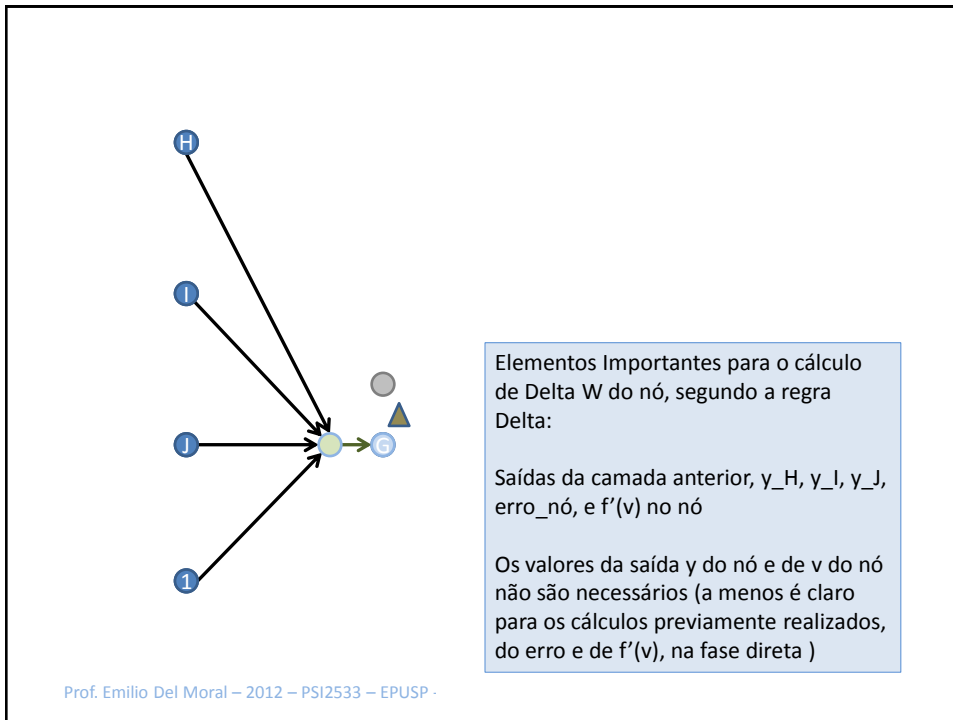
Prof. Emilio Del Moral – 2012 – PSI2533 – EPUSP

## Passo 3 (tambem reverso, complementando o passo 2)

### Regra Delta Clássica, aplicada nó a nó, em toda a rede

Prof. Emilio Del Moral – 2012 – PSI2533 – EPUSP





Elementos importantes para o cálculo de Delta W do nó, segundo a regra Delta:

Saídas da camada anterior,  $y_A, y_B, y_C$ , erro\_nó, e  $f'(v)$  no nó.

Neste nó específico, por ser o nó de saída, temos que o erro do nó coincide com o erro da rede (não se trata de erro retro-propagado)

Os valores da saída  $y$  do nó e de  $v$  do nó não são necessários (a menos é claro para os cálculos previamente realizados, do erro e de  $f'(v)$ , na fase direta)

Prof. Emilio Del Moral – 2012 – PS12533 – EPUSP ·

*Retornando às nossas motivações iniciais no cálculo de adaptações de pesos ...*

**Conjunto de treino em arquiteturas supervisionadas (ex. clássico: MLP com Error Back Propagation)**

A computação desejada da rede pode ser definida simplesmente através de amostras / exemplos do comportamento requerido

$$Eqm = \frac{1}{M} \sum_{\mu=1}^M (y_{rede}(\vec{X}^{\mu}, W) - y^{\mu})^2$$

$$\vec{\Delta W} = -\eta \cdot \vec{\nabla} Eqm$$

Aprendizado: Espaço de pesos  $W$  é explorado visando aproximar ao máximo a computação da rede da computação desejada

Prof. Emilio Del Moral – 2012 – PS12533 – EPUSP ·