

Temas da 3ª semana – PSI3471-2020 – Prof Emilio

170

#5 (16/março – 2#f) Foco da semana: aprendizado da Rede Neural MLP – O Gradiente descendente e a otimização de pesos sinápticos com base no conjunto de treino e EBP; dedução das fórmulas do EBP, em sala de aula em conjunto com os alunos: trabalho focado num peso sináptico específico de cada conexão, pelo professor, para o fim de exemplificar a dedução.

#6 (18/março – 4#f) ... Discussão das extensões das deduções já feitas (para um peso no EBP) para os demais pesos sinápticos; redundâncias nos cálculos dos diversos pesos da rede neural e otimização do esforço computacional. Regra “Delta” de aprendizado de Widrow, para neurônio isolado; Aprendizado por EBP recursivo, camada a camada.

© Prof. Emilio Del Moral Hernandez

170

170

Ao comparamos as expressões das derivadas parciais de TODOS pesos da rede (Ex6 de treino), encontramos notáveis redundâncias:

171

Redundâncias do tipo 1: A cadeia de cálculos que é relevante ao cálculo da derivada parcial de Eqm com relação ao peso w_{1A} é muito semelhante à cadeia de cálculos que é relevante ao cálculo da derivada parcial de Eqm com relação ao peso w_{2A} . E o mesmo pode ser dito para a cadeia relevante para w_{3A} , e o mesmo também vale para w_{0A} .

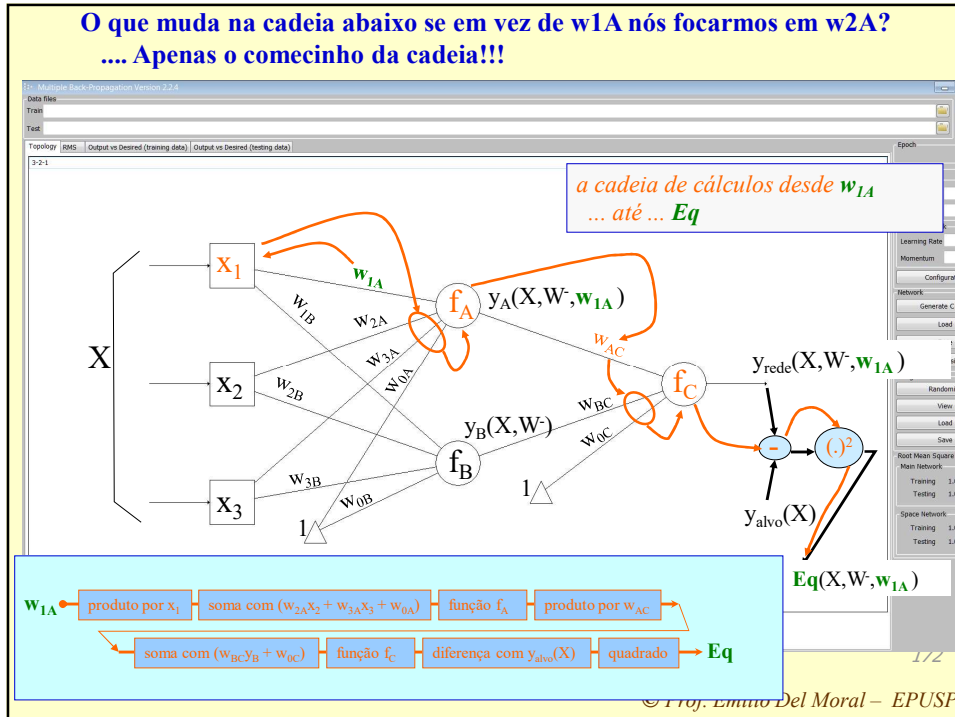
Isto faz que as fórmulas de todas essas derivadas parciais sejam muito parecidas, e que seja possível reduzir computação na fase de aprendizado de pesos, aproveitando que boa parte dos cálculos são comum a todas essas cadeias. Temos redundância portanto, quando comparamos fórmulas para aqueles pesos que compõem a somatória ponderada de um dado nó neural.

© Prof. Emilio Del Moral Hernandez

171

171

O que muda na cadeia abaixo se em vez de w_{1A} nós focarmos em w_{2A} ?
 Apenas o comecinho da cadeia!!!



172

Ao compararmos as expressões das derivadas parciais de TODOS pesos da rede (Ex6 de treino), encontramos notáveis redundâncias:

“Temos redundância portanto, quando comparamos fórmulas para aqueles pesos que compõem a somatória ponderada de um dado nó neural.”

E note que essa redundância é similar à redundância já detectada nos inícios das redes neurais, no aprendizado de um neurônio isolado pela “regra delta” de Widrow ...

173

"Regra Delta" (Widrow) para o aprendizado em nó simples:

Gradiente Descendente = Regra Δp / aprendizado de um nó:

$$\Delta w_i = -x_i \cdot f'(v) \cdot 2 \cdot \text{erro}$$

... ou, vetorialmente:

$$\Delta W = -X \cdot f'(v) \cdot 2 \cdot \text{erro}$$

(ΔW = correções de W)

... em loop ...

W ... inclui w_1 a w_3 e também o viés (w_0)

$$v = X \cdot W = \sum w_i x_i$$

$$y = f(v)$$

Grafo de cálculos para um único nó neural ...

Prof. Emilio Del Moral Hernandez

174

Ao compararmos as expressões das derivadas parciais de TODOS pesos da rede (Ex6 de treino), encontramos notáveis redundâncias:

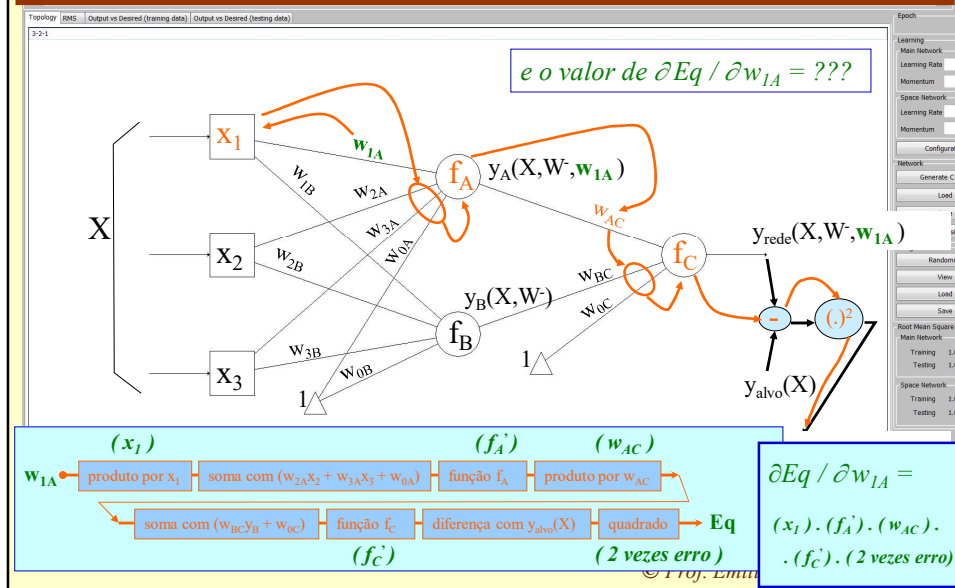
Redundâncias do tipo 2) A cadeia de cálculos que é relevante ao cálculo da derivada parcial de Eqm com relação ao peso w_{1A} tem uma parcela muito semelhante à cadeia de cálculos que é relevante ao cálculo da derivada parcial de Eqm com relação ao peso w_{AC} .

Temos aqui redundância de cálculos quando vamos de uma cama para outra.

© Prof. Emilio Del Moral Hernandez

175

A expressão p/ $\partial E_q / \partial w_{AC}$ (peso da 2ª camada) é similar a boa parte da expressão adiante, obtida para $\partial E_q / \partial w_{1A}$



176

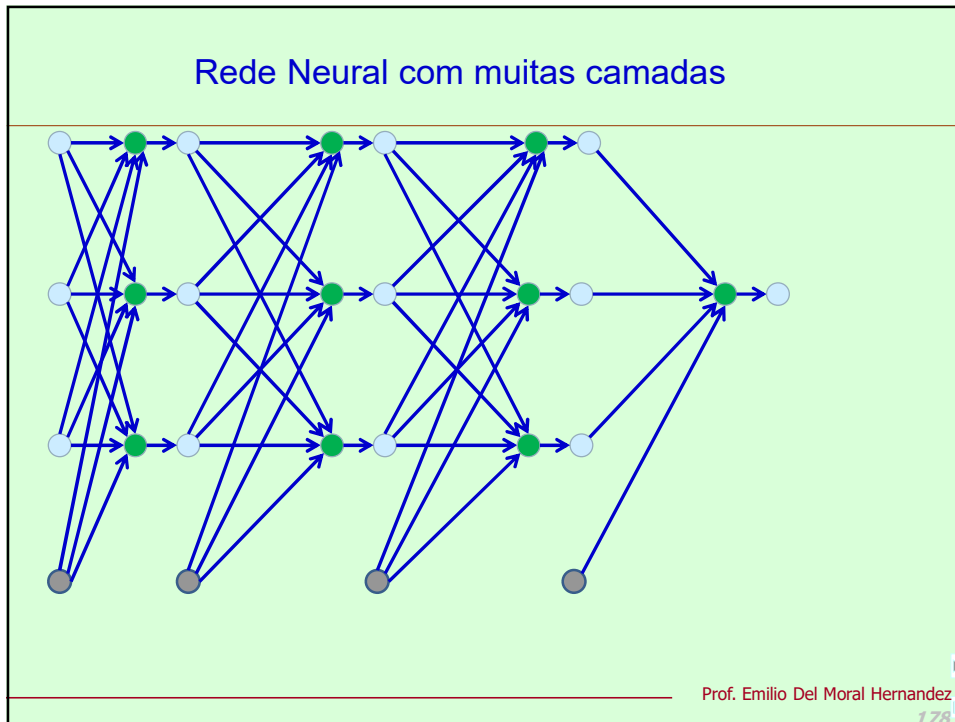
Ao compararmos as expressões das derivadas parciais de TODOS pesos da rede (Ex6 de treino), encontramos notáveis redundâncias:

Os dois tipos de redundâncias nos cálculos das adaptações de pesos sinápticos destacadas nos slides anteriores, são as bases para a estratégia de cálculo recursivo do Error Back Propagation, conforme detalhado nos slides mais adiante

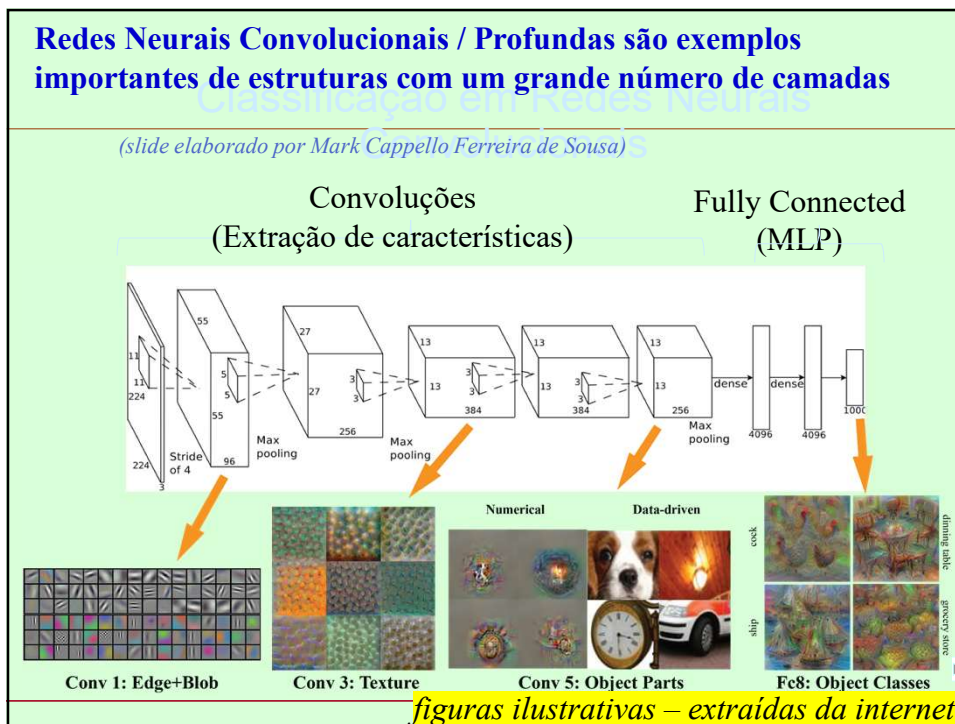
Tal estratégia de cálculo é extremamente importante em redes neurais com muitas camadas: Os cálculos das adaptações dos pesos sinápticos são feitos de forma recursiva, primeiro realizando-se os cálculos para os pesos da camada de saída, depois são feitos os cálculos para os pesos da camada anterior (com reaproveitamento parcial de cálculos já feitos anteriormente), e assim sucessivamente, até chegarmos aos cálculos para os pesos da primeira camada.

© Prof. Emilio Del Moral Hernandez

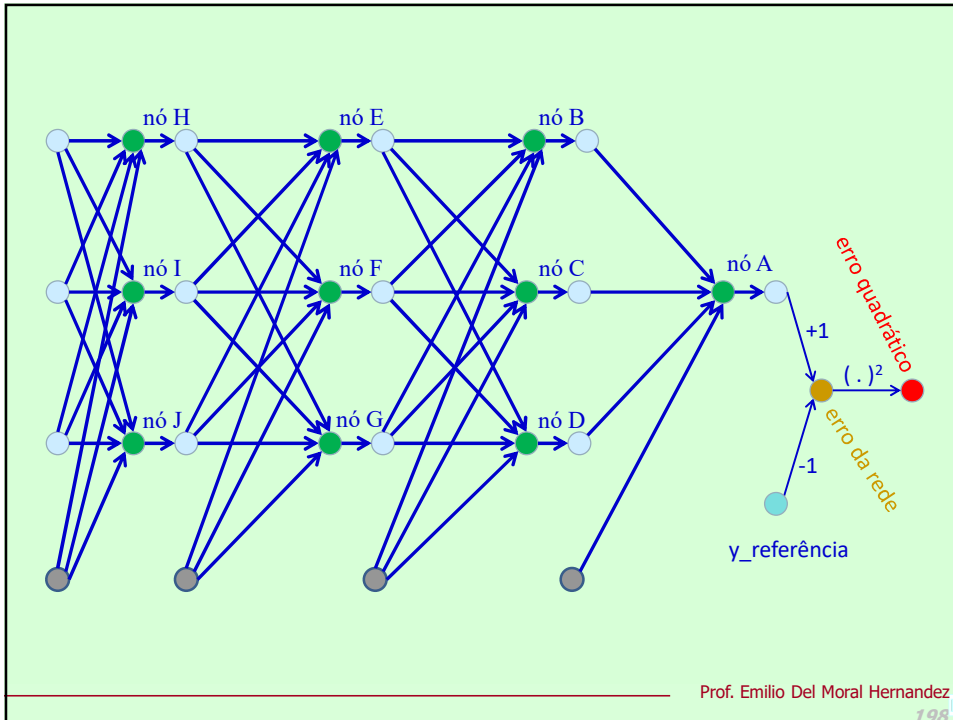
177



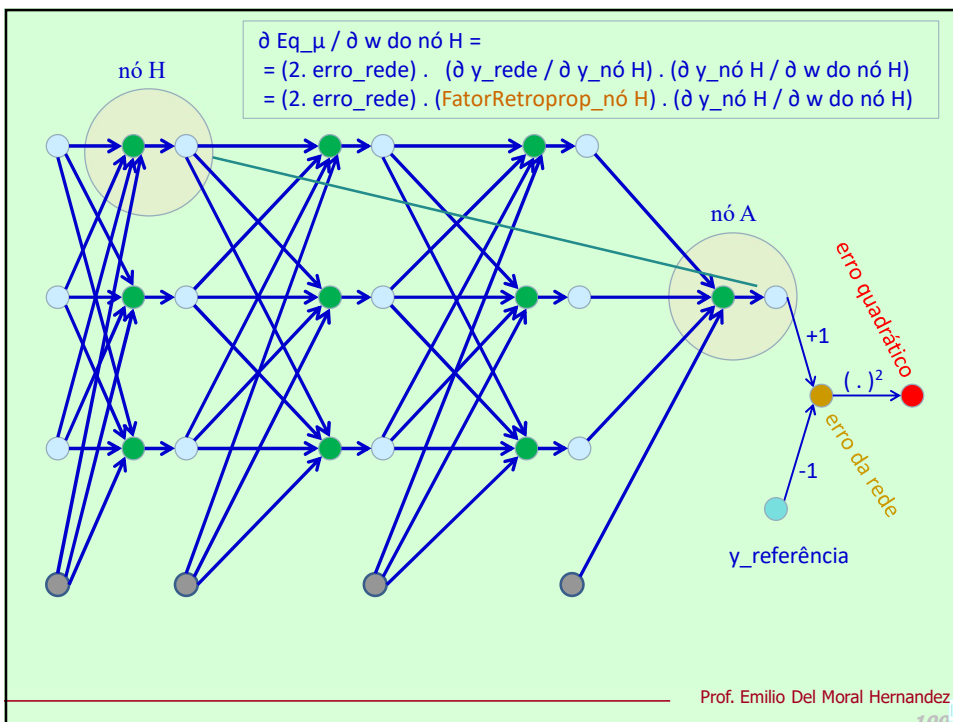
178



181




198



199

Temos um retropropagador para cada nó da rede, a excessão do nó de saída "nó A": o nó de saída não necessita do retropropagador, já que o erro da saída da rede é o próprio erro desse nó; aliás, se tentar calcular $(\partial y_{rede} / \partial y_{nó})$ para ele, chega-se obviamente a $Rtr_{nóA} = 1$.



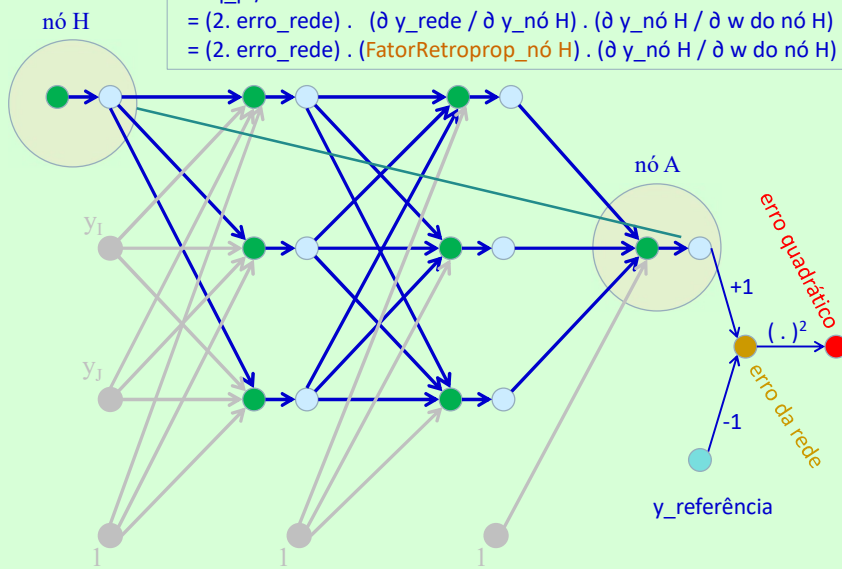
$$\begin{aligned} \partial Eq_{\mu} / \partial w \text{ para } w \text{ nó } KK &= \\ &= (2 \cdot \text{erro_rede}) \cdot (\partial y_{rede} / \partial y_{nó} KK) \cdot (\partial y_{nó} KK / \partial w) \\ &= (2 \cdot \text{erro_rede}) \cdot (\text{FatorRetroprop_nó } KK) \cdot (\partial y_{nó} KK / \partial w) \end{aligned}$$

Prof. Emilio Del Moral Hernandez

200

200

$$\begin{aligned} \partial Eq_{\mu} / \partial w \text{ do nó } H &= \\ &= (2 \cdot \text{erro_rede}) \cdot (\partial y_{rede} / \partial y_{nó} H) \cdot (\partial y_{nó} H / \partial w \text{ do nó } H) \\ &= (2 \cdot \text{erro_rede}) \cdot (\text{FatorRetroprop_nó } H) \cdot (\partial y_{nó} H / \partial w \text{ do nó } H) \end{aligned}$$



Prof. Emilio Del Moral Hernandez

201

201

$\frac{\partial Eq_{\mu}}{\partial w \text{ do nó H}} =$
 $= (2 \cdot erro_rede) \cdot (\frac{\partial y_rede}{\partial y_nó H}) \cdot (\frac{\partial y_nó H}{\partial w \text{ do nó H}})$
 $= (2 \cdot erro_rede) \cdot (\text{FatorRetroprop_nó H}) \cdot (\frac{\partial y_nó H}{\partial w \text{ do nó H}})$

Prof. Emilio Del Moral Hernandez

202

Temos um retropropagador para cada nó da rede, a excessão do nó de saída "nó D": o nó de saída não necessita do retropropagador, já que o erro da saída da rede é o próprio erro desse nó; aliás, se tentar calcular $(\frac{\partial y_rede}{\partial y_nó})$ para ele, chega-se obviamente a $Rtr_nóD = 1$.

$\frac{\partial Eq_{\mu}}{\partial w \text{ para } w \text{ nó NN}} =$
 $= (2 \cdot erro_rede) \cdot (\frac{\partial y_rede}{\partial y_nó NN}) \cdot (\frac{\partial y_nó NN}{\partial w})$
 $= (2 \cdot erro_rede) \cdot (\text{FatorRetroprop_nó NN}) \cdot (\frac{\partial y_nó NN}{\partial w})$

Prof. Emilio Del Moral Hernandez

203

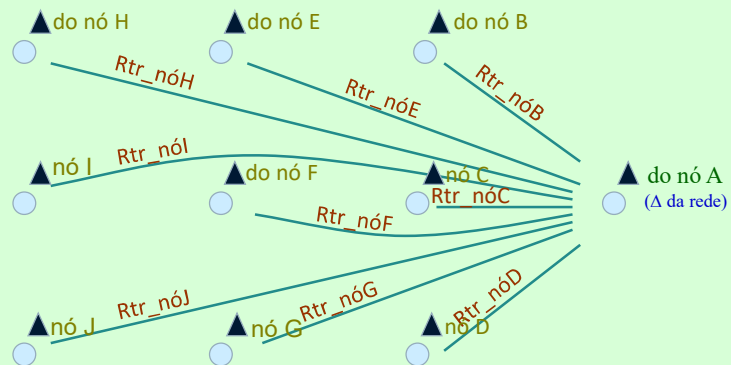
Definindo novas variáveis: uma nova variável auxiliar associada a cada nó, chamada **erro do nó**

... Revisitemos a expressão para $\partial Eq_{\mu} / \partial w$, reagrupando termos

$$\begin{aligned} \partial Eq_{\mu} / \partial w &= \\ &= (2 \cdot erro_rede) \cdot (\partial y_rede / \partial y_nó) \cdot (\partial y_nó / \partial w) \\ &= (2 \cdot erro_rede) \cdot \overset{\text{definição}}{\uparrow} (FatorRetroprop_nó) \cdot (\partial y_nó / \partial w) \\ &= (2 \cdot [erro_rede \cdot FatorRetroprop_nó]) \cdot (\partial y_nó / \partial w) \end{aligned}$$

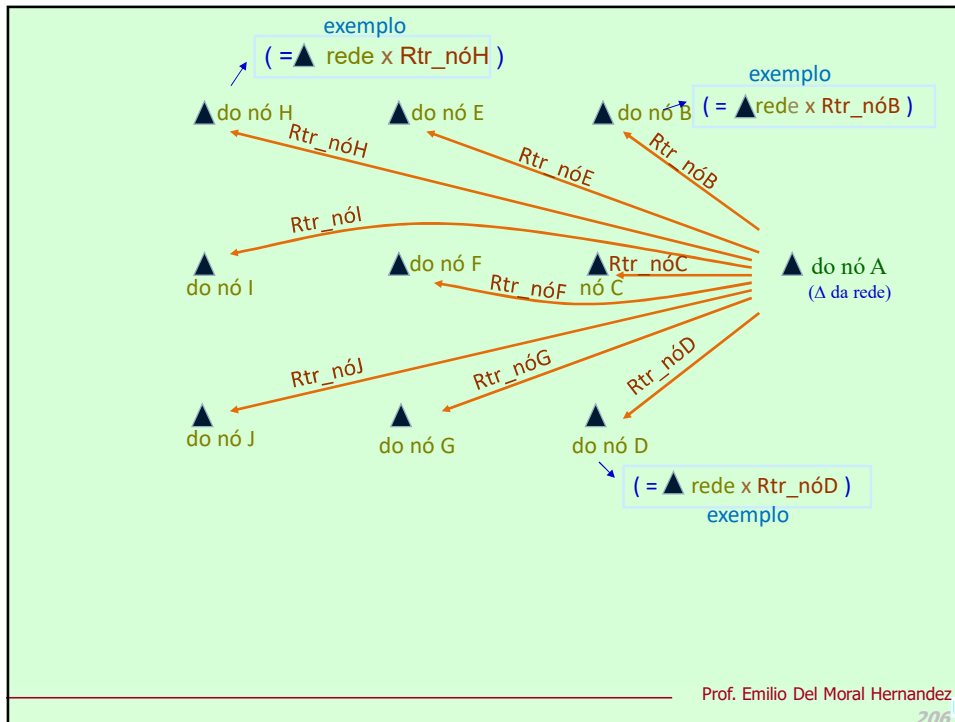
↑ Definição de **erro de nó**
(= erro de rede retropropgado ao nó)

204

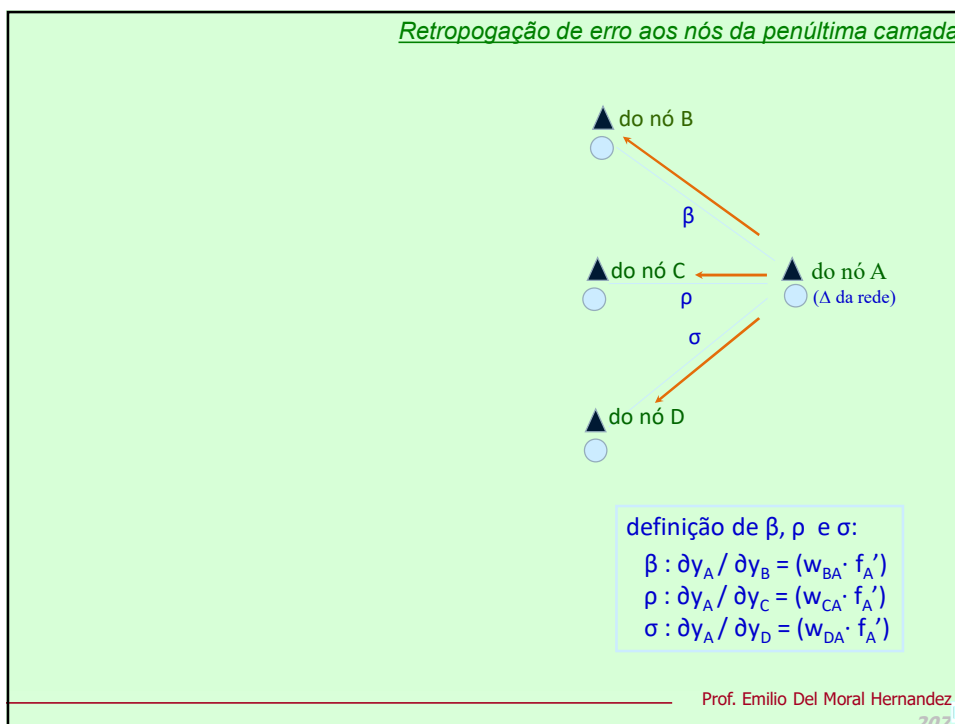


Os triângulos representam os erros associados a cada nó

205

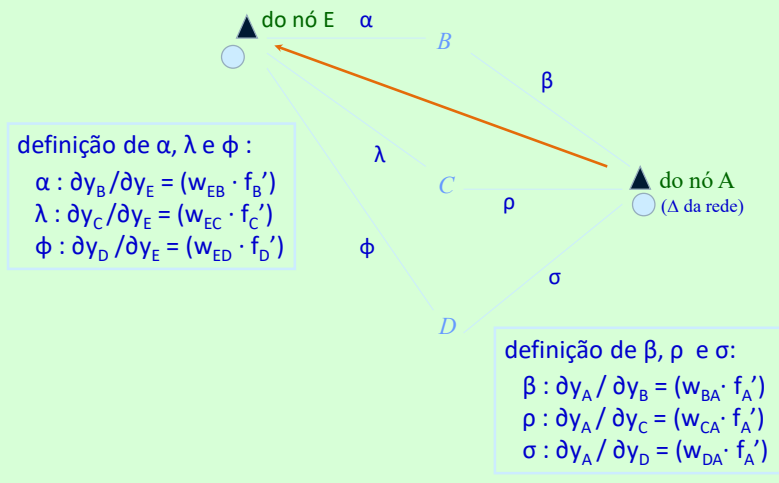


206



207

Retropropagação de erro envolvendo cadeia com trifurcação

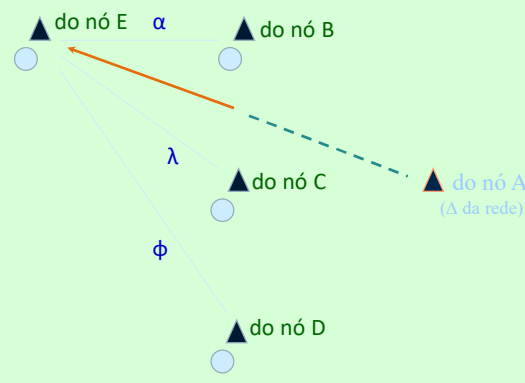


erro E = $(\alpha \cdot \text{erro da rede} \cdot \beta) + (\lambda \cdot \text{erro da rede} \cdot \rho) + (\phi \cdot \text{erro da rede} \cdot \sigma)$

Prof. Emilio Del Moral Hernandez

208

Retropropagação de erro explorando recursão




erro E = $\alpha \cdot (\text{erro da rede} \cdot \beta) + \lambda \cdot (\text{erro da rede} \cdot \rho) + \phi \cdot (\text{erro da rede} \cdot \sigma)$
 $= \alpha \cdot (\text{erro B}) + \lambda \cdot (\text{erro C}) + \phi \cdot (\text{erro D})$

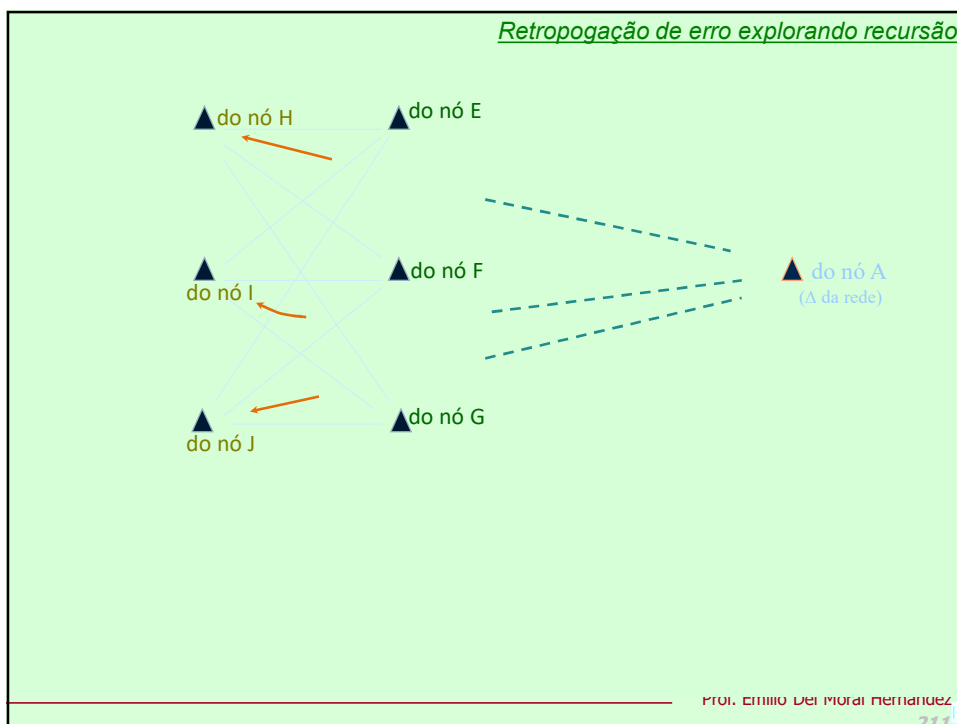
erro E = $(\alpha \cdot \text{erro da rede} \cdot \beta) + (\lambda \cdot \text{erro da rede} \cdot \rho) + (\phi \cdot \text{erro da rede} \cdot \sigma)$

Prof. Emilio Del Moral Hernandez

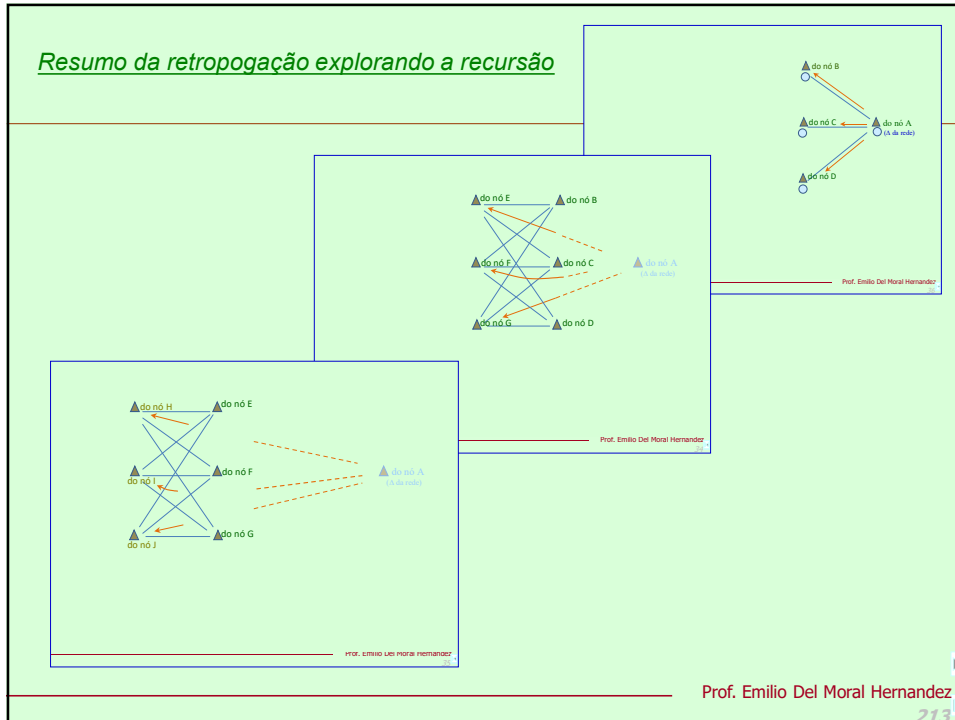
209



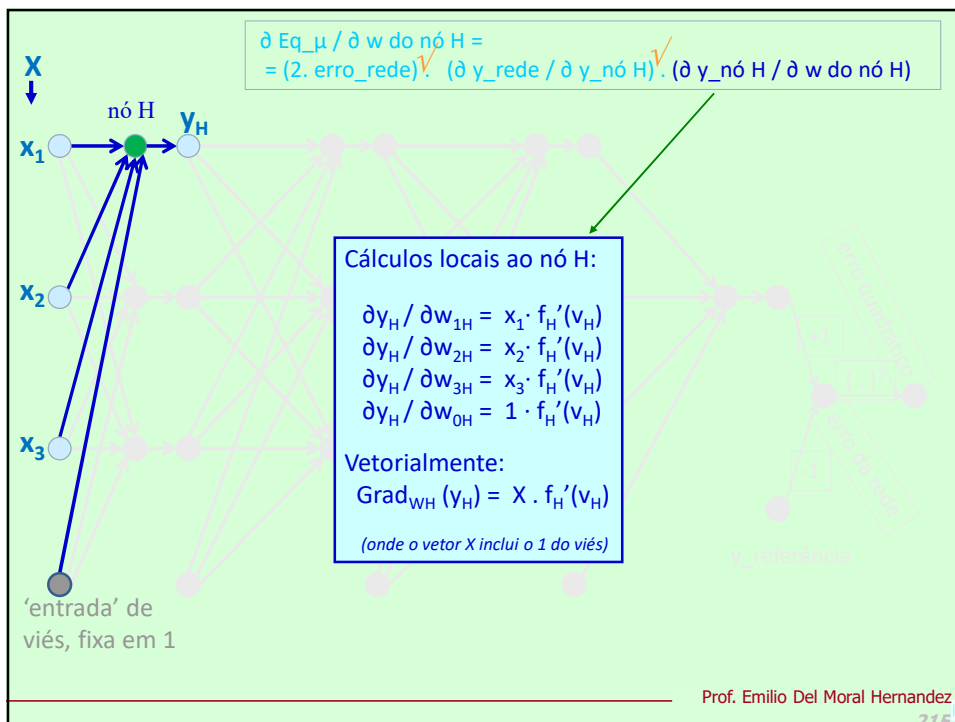
210



211



213



215

