


1

© Prof. Emilio Del Moral – EPUSP

1

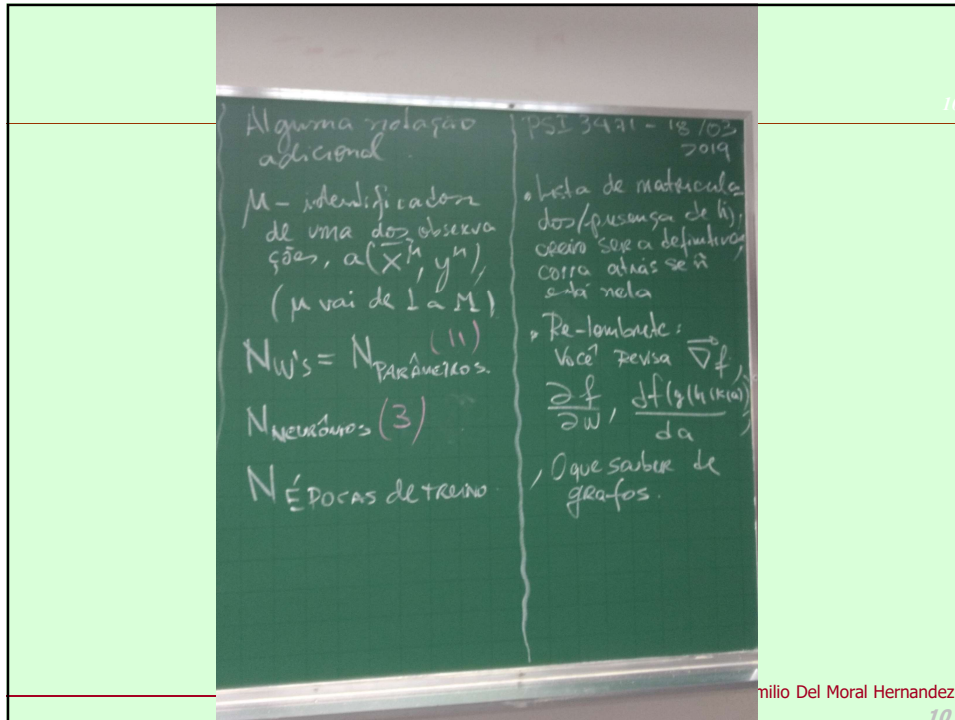


recordando

### Notação

7





10

### Conexão de RNAs com elementos de “Aprendizado de Máquina” / “Machine Learning”

O “aprendizado do modelo” é feito de maneira automática a partir de casos / de exemplos concretos: a definição matemática do modelo é feita a partir de um conjunto rico de exemplos numéricos empíricos de pares  $(X, y)$

Conhecimento rico de exemplares / casos  $(X^\mu; y^\mu)$ :  
 Temos  $M$  observações empíricas  $(X^\mu; y^\mu)$ , onde  $\mu$  identifica cada observação, e varia entre 1 a  $M$

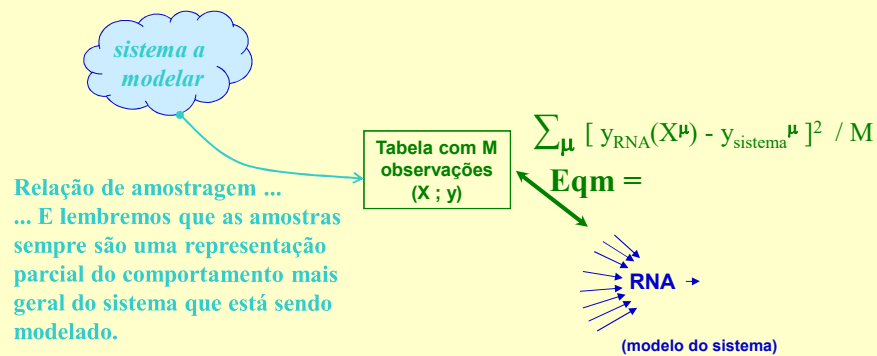


$y_{\text{modelo}}$  = cálculo neural (ou seja, somas ponderadas e com tgh's) que opera sobre as componentes do vetor  $X$  ( $x_1, x_2, x_3 \dots$ ); Esse cálculo neural é calibrado (via escolha dos valores dos ponderadores  $w$ 's) a partir de  $M$  pares empíricos  $(X^\mu; y^\mu)$

EGF-006 – Métodos Numéricos e Reconhecimento de Padrões – Prof. Emilio Del Moral – EPUSP

11

O treinamento mira minimizar o **Eqm** das amostras (X ; y) de treino. (exclusivamente!)



12

© Prof. Emilio Del Moral – EPUSP

12

**Um Exemplo Ilustrativo  
para o Conceito de  
Conjunto de  
Treinamento e dos M  
pares (X,y)...**

13

© Prof. Emilio Del Moral – EPUSP

13

## Exemplo de regressão multivariada para estimação contínua usando MLP

- O valor do  $y$  contínuo ... neste exemplo corresponde ao volume de consumo futuro num dado tipo de produto "A" a ser ofertado pela empresa a um cliente corrente já consumidor de outros produtos da empresa ("B" e "C"), volume esse previsto com base em várias medidas quantitativas que caracterizam tal indivíduo. ... Assim,  $y = \text{Consumo do Produto A} = F(x_1, x_2, x_3, x_4, x_5)$ .
- Consideremos 4 variáveis de entrada no modelo preditivo neural, ou seja, temos 5 medidas em  $X$ :
  - $x_1$ : Idade do indivíduo
  - $x_2$ : Renda mensal do indivíduo
  - $x_3$ : Volume de clicks do indivíduo no website de exibição de produtos oferecidos pela empresa
  - $x_4$ : Volume de consumo desse cliente observado para outro Produto B da mesma empresa
  - $x_5$ : Volume de consumo desse cliente Produto C da mesma empresa
- Problema: desenvolver uma MLP para regressão contínua multivariada que permita estimar esse volume de consumo futuro  $y$  com base no conhecimento dos  $X$  e numa base de dados de aprendizado com esses dados  $X$  e  $y$  para 350 já clientes de universo populacional similar ao do novo consumidor potencial. 14

© Prof. Emilio Del Moral – EPUSP

14

## Exemplo de dados empíricos tabulados em Excel ...

Cliente ( $\mu$ )	Idade ( $x_1$ )	Renda ( $x_2$ )	Clics ( $x_3$ )	Consumo do Produto B ( $x_4$ )	Consumo do Produto C ( $x_5$ )	Consumo do Produto A ( $y$ )
1	50	78	302	958	136	9800
2	65	128	186	985	196	8760
3	57	150	221	1093	35	520
.....	.....	.....	.....	.....	.....	.....
M-2	16	19	51	707	131	11640
M-1	30	75	7	29	78	9640
M	19	47	116	285	124	5320

15

© Prof. Emilio Del Moral – EPUSP

15

78% Times New Roman 24

Tools Slide Show Window Help

**Equivalent em .txt, em formato apropriado para o ambiente Multiple Back Propagation ...**

Cliente ( $\mu$ )	Idade ( $x_1$ )	Renda ( $x_2$ )	Clics ( $x_3$ )	Consumo do Produto B ( $x_4$ )	Consumo do Produto C ( $x_5$ )	Consumo do Produto A ( $y$ )
			302	958	136	9800
			186	985	196	8760
						520
						11640
						9640
						5320

*Equivalente em txt*  
*Para uso do MBP*

Arquivo Editar Formatar Exibir Ajuda

Idade	Renda	Clics	ConsumoA	ConsumoB	ConsumoA
50	78	302	958	136	9800
65	128	186	985	196	8760
57	150	221	1093	35	520
(...)					
16	19	51	707	131	11640
30	75	7	29	78	9640
19	47	116	285	124	5320

75  
Moral - EPUSP

Capsulas

16

18

*Como escolhemos os valores dos diversos  $w$ 's ?*

© Prof. Emilio Del Moral Hernandez

18

18

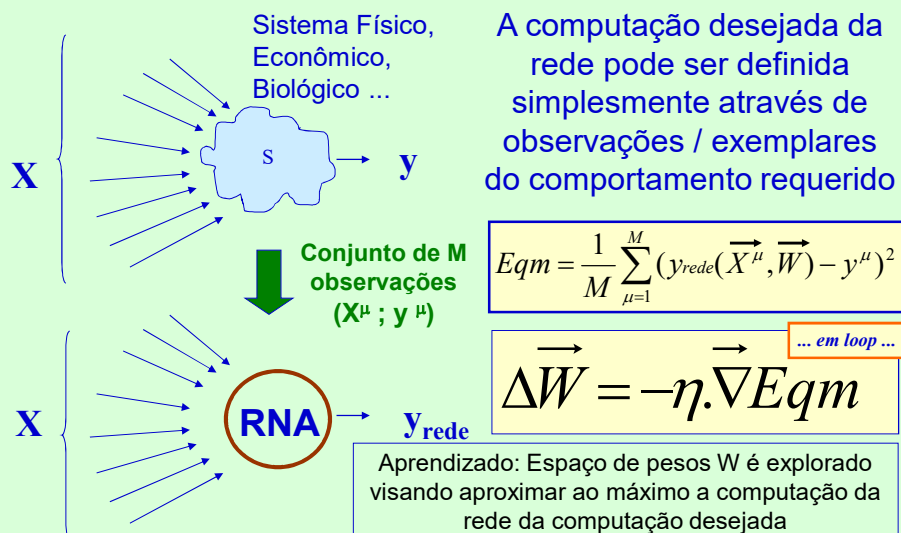
# Aprendizado em RNAs do tipo MLP – Multi Layer Perceptron – através do algoritmo Error Back Propagation

© Prof. Emilio Del Moral – EPUSP

19

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

22



© Prof. Emilio Del Moral Hernandez

22


22

O que devemos buscar quando exploramos o espaço de pesos  $W$  buscando que a RNA seja um bom modelo?

23

*Devemos buscar Maximização da aderência = Mínimo Eqm possível*

**As Setas Verdes Indicam Situações que Devem ser Procuradas**



23


23

O que devemos mirar quando exploramos o espaço de pesos  $W$  buscando que a RNA seja um bom modelo?

*Devemos mirar Maximização da aderência = Mínimo Eqm possível*

**As Setas Verdes Indicam Situações que Devem ser Procuradas**

Será que temos apenas um mínimo??



24

© Prof. Emilio Del Moral – EPUSP

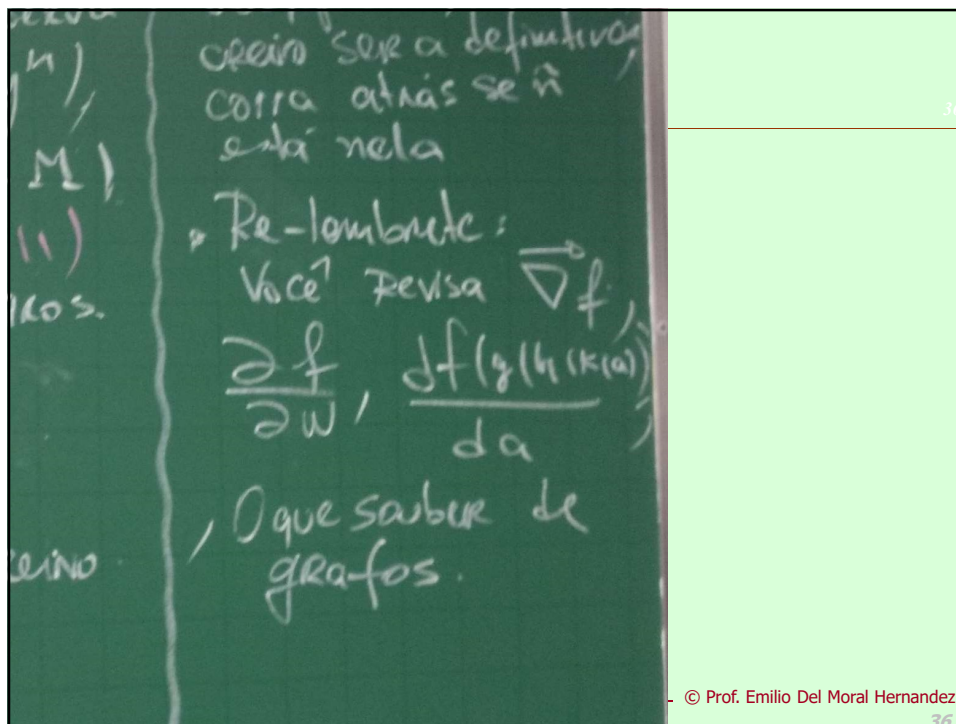
24



*Deduzindo as Equações do  
Aprendizado em RNAs do  
tipo MLP – Multi Layer  
Perceptron – com o algoritmo  
Error Back Propagation  
(Gradiente Descendente)*

© Prof. Emilio Del Moral – EPUSP

29



36

Chamada oral sobre a lição de casa: estudar / reestudar os conceitos e a parte operacional de derivadas parciais, do vetor Gradiente, e da regra da cadeia ...

- Derivadas parciais (que são as componentes do gradiente):

$$\partial f(a,b,c)/\partial a \quad \partial f(a,b,c)/\partial b \quad \partial f(a,b,c)/\partial c$$

- Vetor Gradiente, útil ao método do máximo declive:

$$(\partial E_{qm}(W)/\partial w_1, \partial E_{qm}(W)/\partial w_2, \partial E_{qm}(W)/\partial w_3, \dots)$$

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

- Regra da cadeia, necessária ao cálculo de derivadas quando há encadeamento de funções:

$$\partial f( g( h(a) ) ) / \partial a = \partial f / \partial g \cdot \partial g / \partial h \cdot \partial h / \partial a$$

© Prof. Emilio Del Moral – EPUSP

37

*A estratégia de Aprendizado para o MLP mais conhecida:*

## **Error Back Propagation (EBP)**

*= Propagação Reversa de Erro*

*= Método do Gradiente personalizado ao  $E_{qm}(W)$  do MLP*

38

© Prof. Emilio Del Moral – EPUSP

38


*Entendamos PRIMEIRO  
o que é o método numérico do  
gradiente ascendente /  
gradiente descendente  
genérico (o EBP é um caso particular),  
que pode ser aplicado tanto para se  
chegar paulatinamente ao máximo de  
uma função quanto para se chegar ao  
mínimo de uma função  
(ascendente / descendente)*

39

© Prof. Emilio Del Moral – EPUSP

39

**Derivada parcial- ilustração p/ função de 2 variáveis apenas**




**A visual model of the partial derivative**

40

© Prof. Emilio Del Moral – EPUSP

40

**Derivada parcial- ilustração p/ função de 2 variáveis apenas**




**A visual model of the partial derivative**

41

© Prof. Emilio Del Moral – EPUSP

41

*mais ilustrações p/ a derivada parcial em função de 2 variáveis*




**A visual model of the partial derivative with respect to y.**

42

© Prof. Emilio Del Moral – EPUSP

42

**Formação do vetor gradiente a partir de duas derivadas parciais**



**A visual model of the partial derivative**


43

© Prof. Emilio Del Moral – EPUSP

43

**<http://en.wikipedia.org/wiki/Gradient>**

**... O vetor gradiente indica a direção ascendente e seu módulo a magnitude de crescimento da função escalar – ilustração p/ função de 2 variáveis apenas**




44

© Prof. Emilio Del Moral – EPUSP

44

## A estratégia do EBP / Gradiente Descendente no aprendizado do MLP



© Prof. Emilio Del Moral – EPUSP

45


***Este gráfico é denso e toca em muitos aspectos interrelacionados ... revisitemos alguns desses aspectos isoladamente com focos específicos nessas revisitas, assim teremos gráficos algo mais simples de interpretar ...***

47

© Prof. Emilio Del Moral – EPUSP

47

## A estratégia do EBP / Gradiente Descendente no aprendizado do MLP




48

© Prof. Emilio Del Moral – EPUSP

48

## Foco na evolução dos $w$ 's com as iterações ...




49

© Prof. Emilio Del Moral – EPUSP

49

## Foco nos diferentes DeltaW de cada iteração ...




50

© Prof. Emilio Del Moral – EPUSP

50

## Foco na evolução do Eqm com as iterações ...



51

© Prof. Emilio Del Moral – EPUSP


51



## Plotando a evolução do Eqm com as iterações ...

**Eqm(#)**

*Por construção, Eqm decresce a cada iteração, até estabilização em ponto de mínimo*

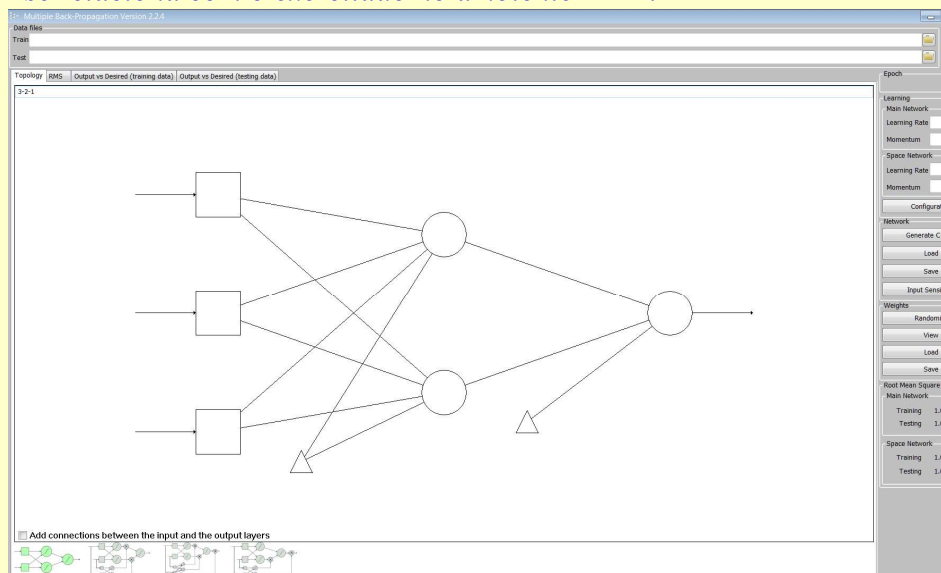


52

© Prof. Emilio Del Moral – EPUSP

52

## Como o que estamos aprendendo no domínio de equações analíticas se relaciona com o exercitado no ambiente MBP?

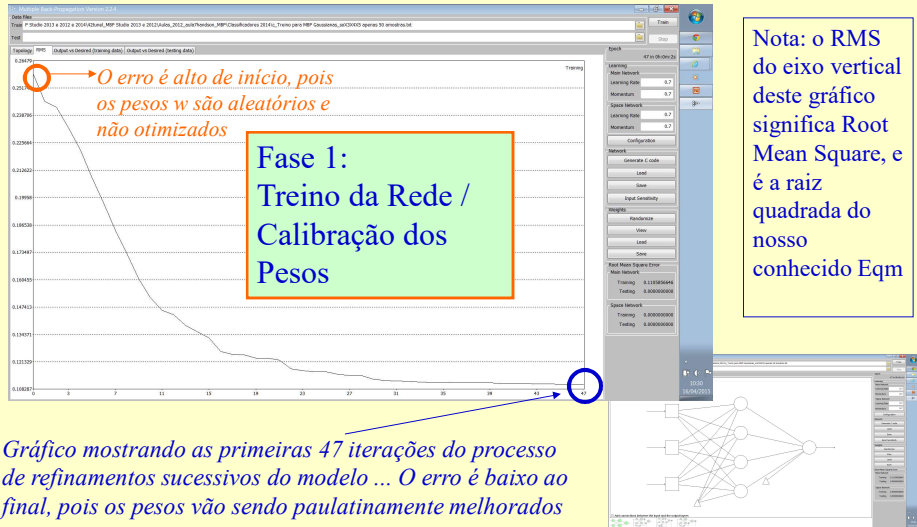


53

© Prof. Emilio Del Moral – EPUSP

53

**Gráfico fornecido pelo ambiente MBP da evolução do Eqm com o número de repetidos usos da “bússola do gradiente descendente”:**  
isto conecta o MBP com o gráfico apresentado no slide anterior



© Prof. Emilio Del Moral – EPUSP

55

## O Ciclo completo da modelagem:

0) **Formalização do problema, mapeamento quantitativo em um modelo neural inicial e ... 0b) coleta de pares empíricos (X,y)**

1) **Fase de TREINO da RNA (MLP): com conhecimento dos X e dos y, que são ambos usados na calibração do modelo**

2) **Fase de TESTE / Caracterização da qualidade da RNA para generalizar: temos novos pares X e y, com y guardado “na gaveta”, usado apenas para avaliação, não para re-calibração. É como um ensaio de uso final do modelo, com possibilidade de medir a sua qualidade com o y que foi guardado na gaveta.**

[Fase de refinamentos da RNA, dados e modelo, em ciclos, desde 0]

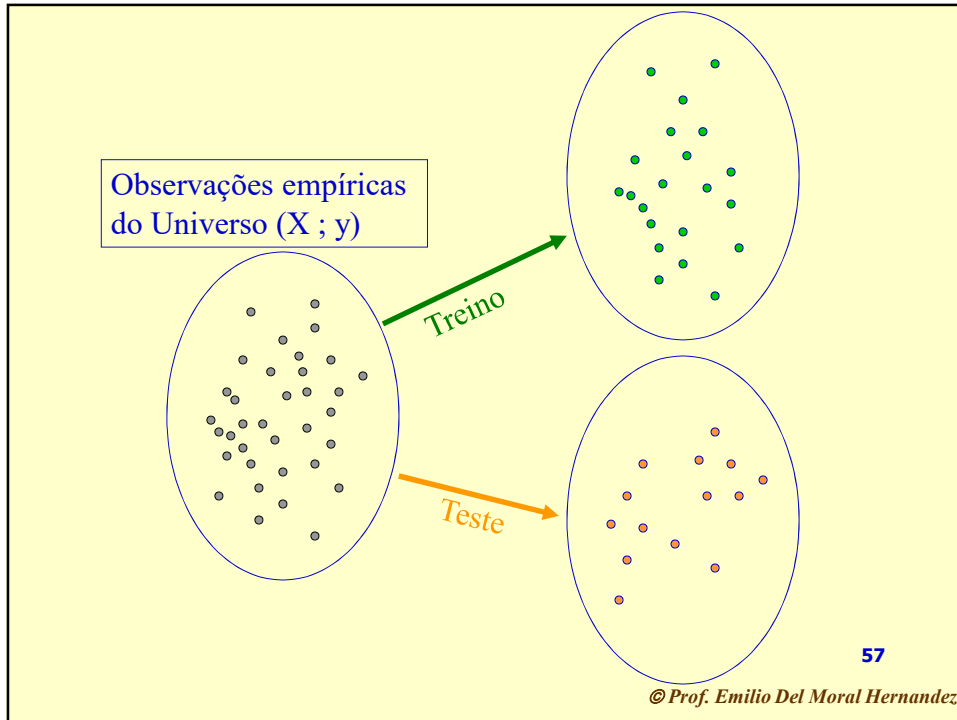
3) **Fase de USO FINAL da RNA, com y efetivamente não conhecido, e estimado com conhecimento dos X + uso do modelo calibrado.**

.... Diferenças e semelhanças entre 1, 2 e 3

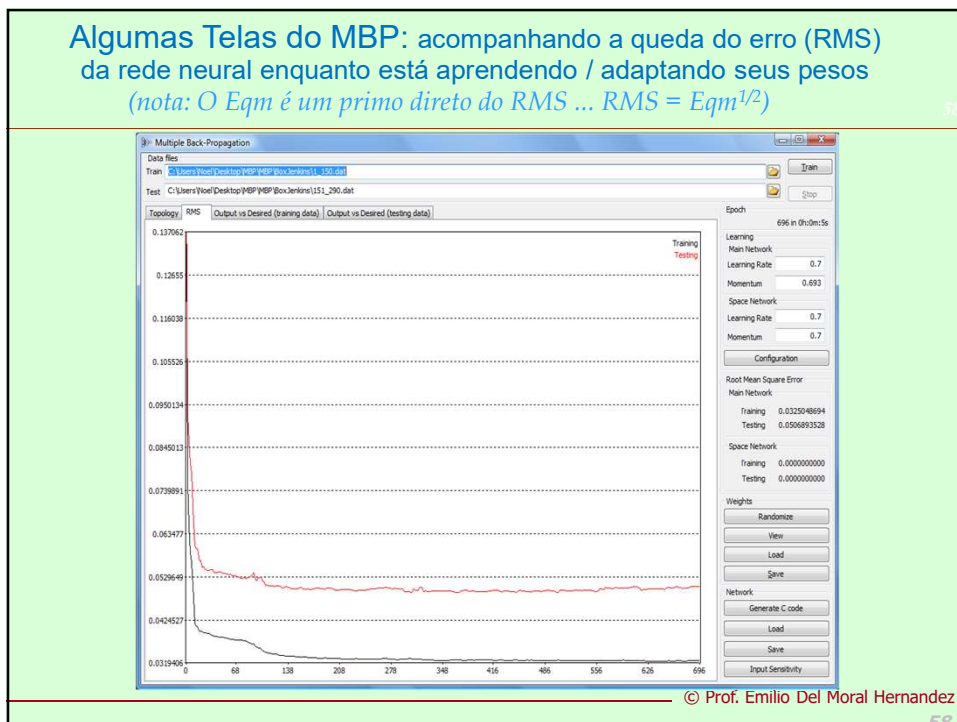
56

© Prof. Emilio Del Moral – EPUSP

56



57



58

## Aprendizado do MLP por Error Back Propagation ...

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

Gradiente de Eqm no espaço de pesos =  $(\partial E_{qm}(W)/\partial w_1, \partial E_{qm}(W)/\partial w_2, \partial E_{qm}(W)/\partial w_3, \dots)$

**Chegando às fórmulas das  
derivadas parciais, necessárias  
à Bússola do Gradiente**

83

© Prof. Emilio Del Moral – EPUSP

83

Processo de refinamentos graduais a cada iteração ...

<b>W#0</b>	<b>Eqm#0</b>	<b>GradEqm(W#0)</b>	<b>DeltaW#0 =</b> - n.GradEqm(W#0)
<b>W#1</b> ( = W#0 + DeltaW#0 )	<b>Eqm#1</b> ( < Eqm#0 )	<b>GradEqm(W#1)</b>	<b>DeltaW#1 =</b> - n.GradEqm(W#1)
<b>W#2</b> ( = W#1 + DeltaW#1 )	<b>Eqm#2</b> ( < Eqm#1 )	<b>GradEqm(W#2)</b>	<b>DeltaW#2 =</b> - n.GradEqm(W#2)
<b>W#3</b> ( = W#2 + DeltaW#2 )	<b>Eqm#3</b> ( < Eqm#2 )	<b>GradEqm(W#3)</b>	<b>DeltaW#3 =</b> - n.GradEqm(W#3)
<b>W#4</b> ( = W#3 + DeltaW#3 )	<b>Eqm#4</b> ( < Eqm#3 )	<b>GradEqm(W#4)</b>	<b>DeltaW#4 =</b> - n.GradEqm(W#4)
...	...	...	...
<b>W#k</b> ( = W#k-1 + DeltaW#k-1 )	<b>Eqm#k</b> ( < Eqm#k-1 )	<b>GradEqm(W#k)</b>	<b>DeltaW#k =</b> - n.GradEqm(W#k)
...	...	...	...

85

© Prof. Emilio Del Moral – EPUSP

85

*Relembrando o que está por trás de um desenho como o que segue ...*

The screenshot shows the 'Multiple Back-Propagation Version 2.2.4' software interface. The main window displays a neural network diagram with 3 input nodes (squares), 2 hidden nodes (circles), and 1 output node (circle). The network is fully connected. The interface includes a menu bar (Data files, Train, Test), a toolbar, and a right-hand panel with various settings like Learning Rate, Momentum, and Network configuration options. The status bar at the bottom right shows '80'.

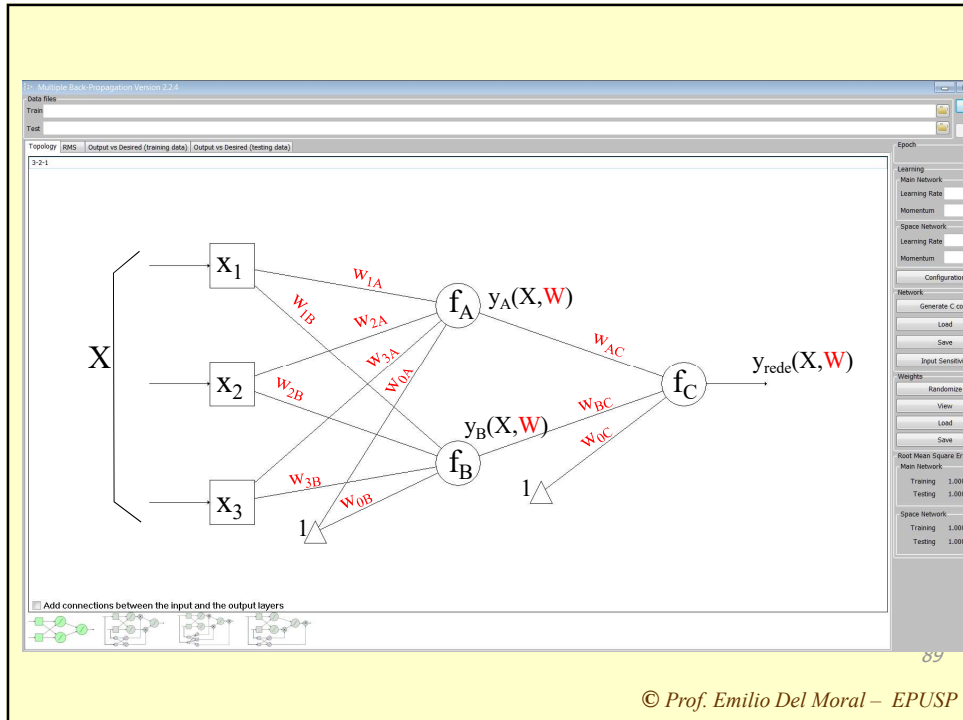
© Prof. Emilio Del Moral – EPUSP

86


The screenshot shows the same software interface as slide 86, but with a more detailed neural network diagram. The input layer has three nodes labeled  $X_1$ ,  $X_2$ , and  $X_3$ . The hidden layer has two nodes labeled  $f_A$  and  $f_B$ . The output layer has one node labeled  $f_C$ . The output of the hidden layer is labeled  $y_A(X)$  and  $y_B(X)$ , and the final output is labeled  $y_{rede}(X)$ . The diagram also shows bias nodes (triangles) with a value of 1. The interface elements are the same as in slide 86.

© Prof. Emilio Del Moral – EPUSP

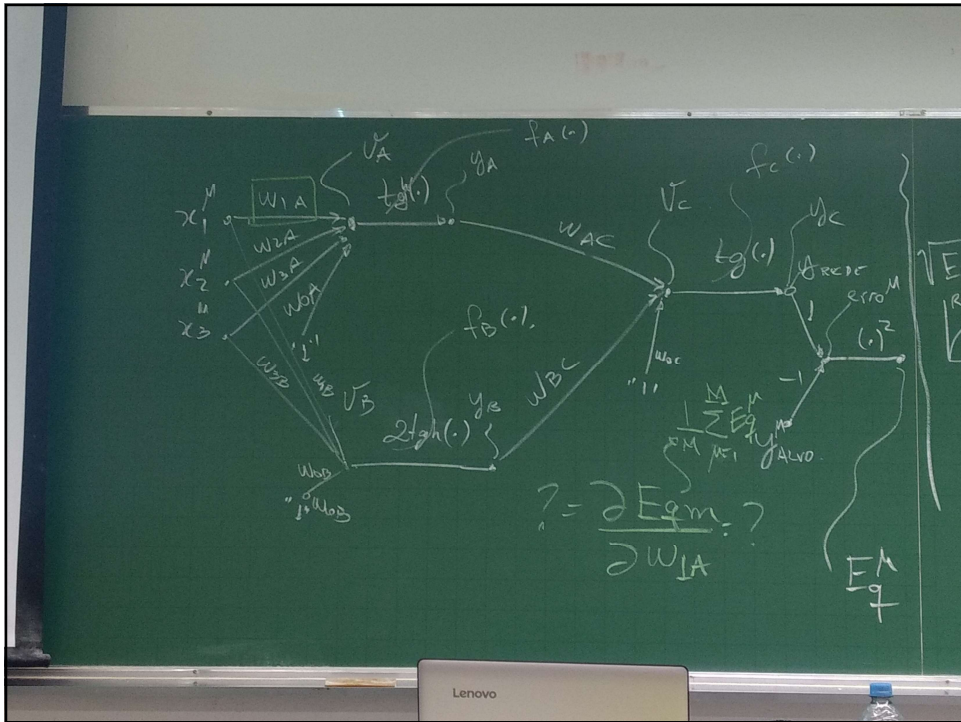
88



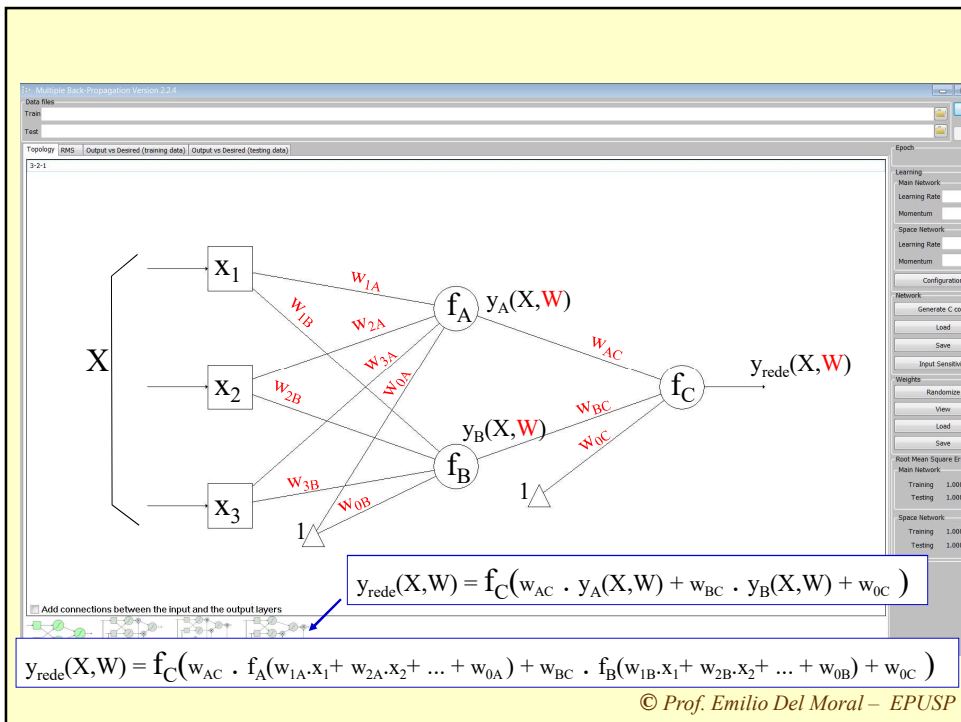
89



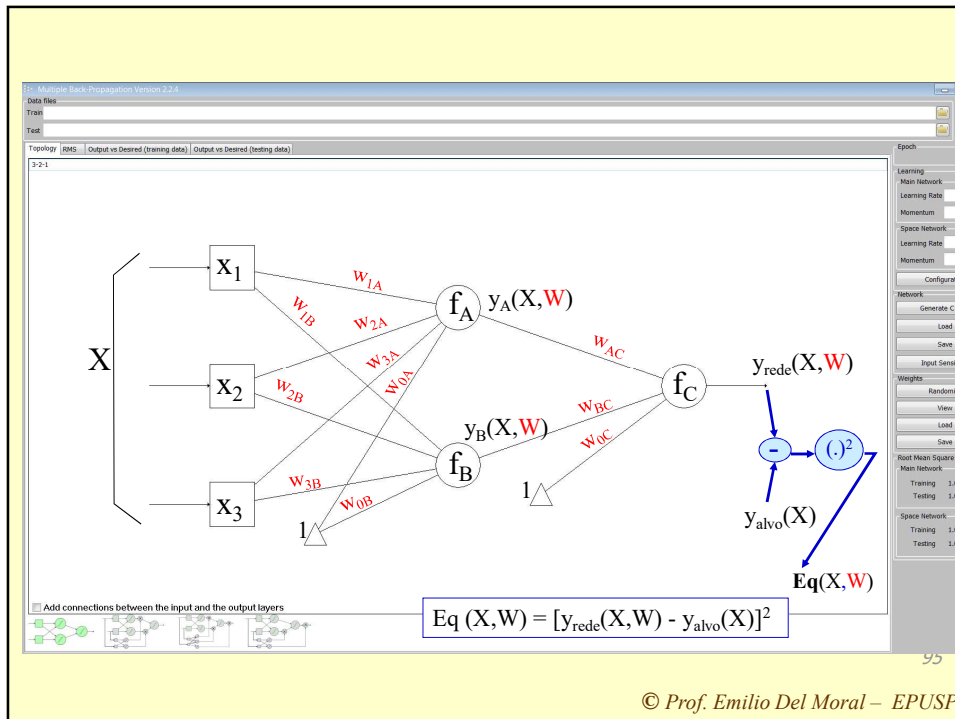
90



91



94



95

© Prof. Emilio Del Moral – EPUSP

**Chamada oral sobre a lição de casa: estudar / reestudar os conceitos e a parte operacional de derivadas parciais, do vetor Gradiente ...**

- **Derivadas parciais (que são as componentes do gradiente):**

$$\frac{\partial f(a,b,c)}{\partial a} \quad \frac{\partial f(a,b,c)}{\partial b} \quad \frac{\partial f(a,b,c)}{\partial c}$$

- **Vetor Gradiente, útil ao método do máximo declive:**

$$(\frac{\partial Eqm(W)}{\partial w_1}, \frac{\partial Eqm(W)}{\partial w_2}, \frac{\partial Eqm(W)}{\partial w_3}, \dots)$$

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

96

© Prof. Emilio Del Moral – EPUSP

96



## Invertamos o operador gradiente e a somatória

.. afinal, gradiente é uma derivada, e a derivada de um soma de várias funções é igual à soma das derivadas individuais de cada componente da soma:

$$\begin{aligned} \mathbf{Grad}(Eqm) &= \\ \mathbf{Grad}(\sum_{\mu} Eq^{\mu}) / M & \\ \sum_{\mu} \mathbf{Grad}(Eq^{\mu}) / M & \end{aligned}$$

97

© Prof. Emilio Del Moral – EPUSP

97

Note que a inversão do gradiente com a somatória nada mais é que usar de forma repetida – e em separado para cada dimensão

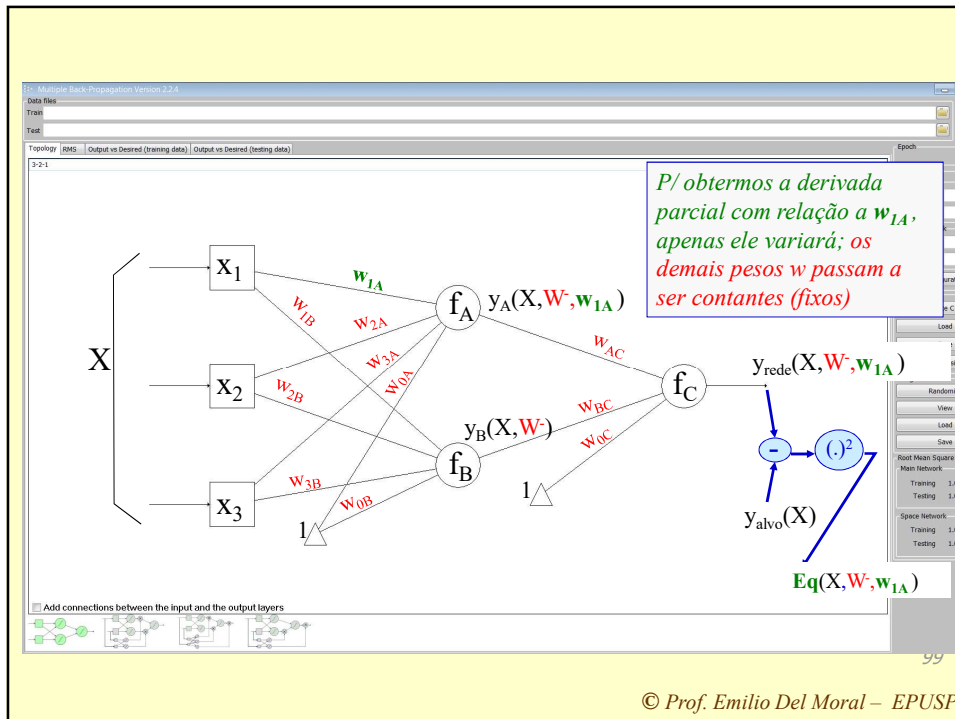
do vetor  $\mathbf{Grad}(\sum_{\mu} Eq^{\mu})$  – a seguinte propriedade simples e sua velha conhecida ...

$$d(f_1(x)+f_2(x)) / dx = df_1(x)/dx + df_2(x)/dx$$

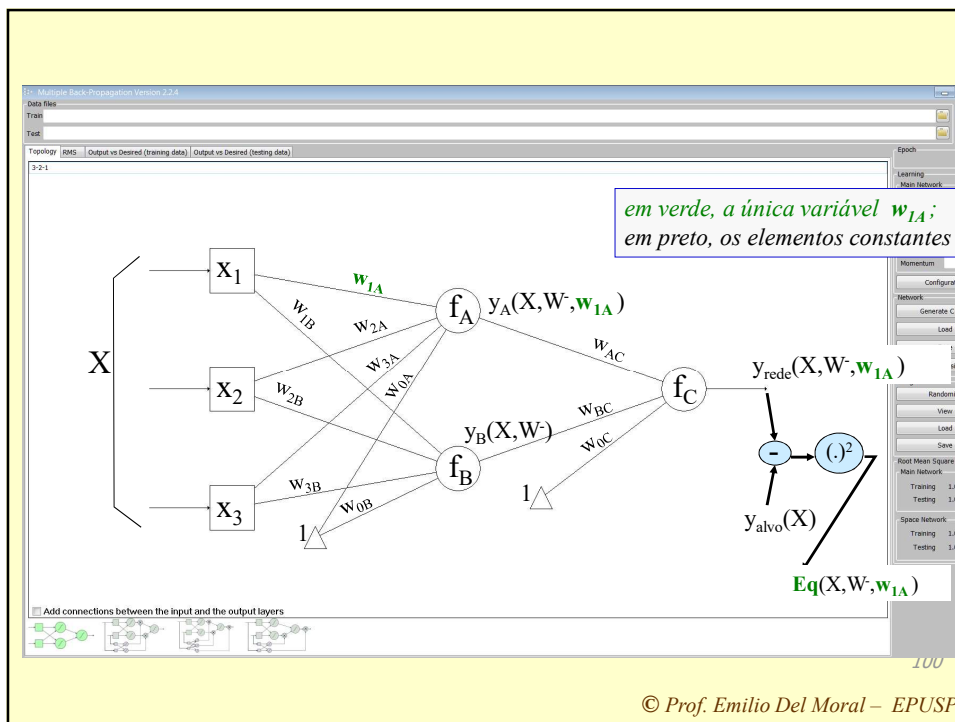
98

© Prof. Emilio Del Moral – EPUSP

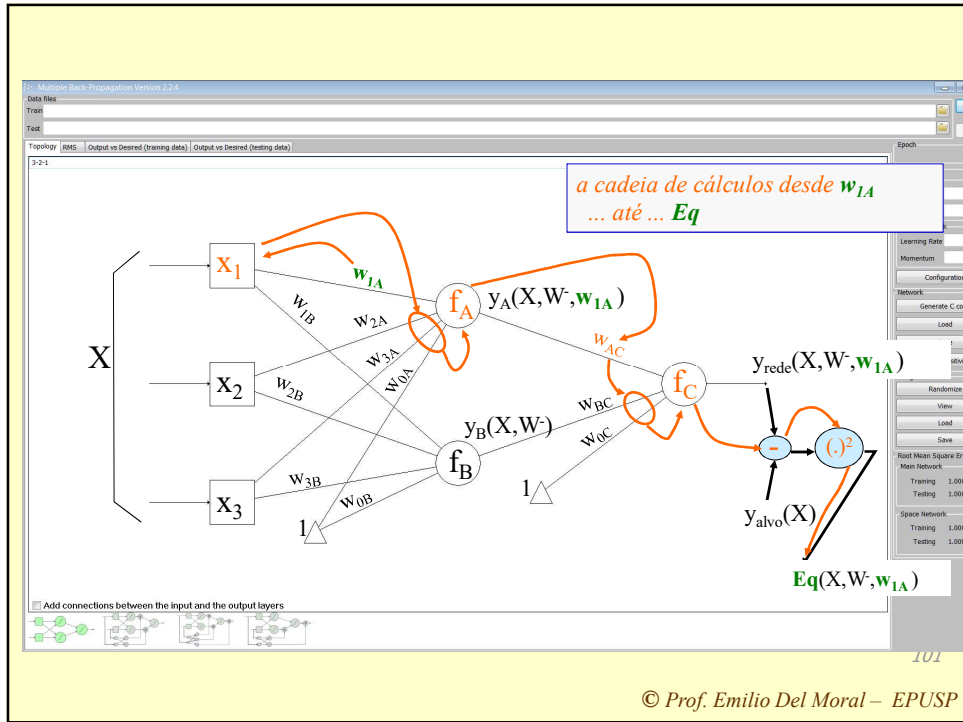
98



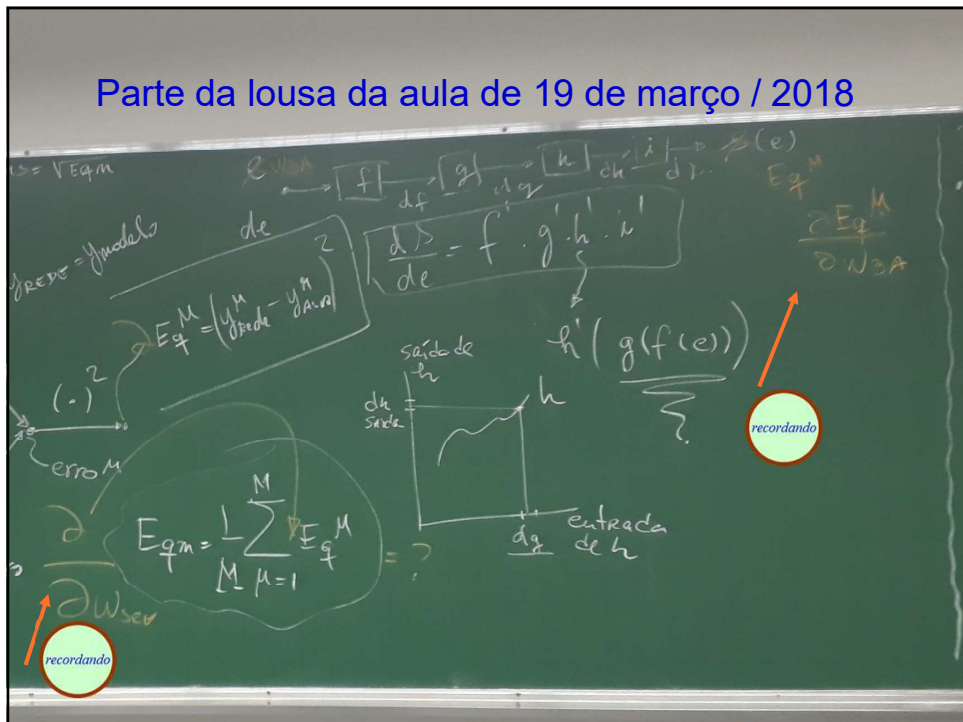
99



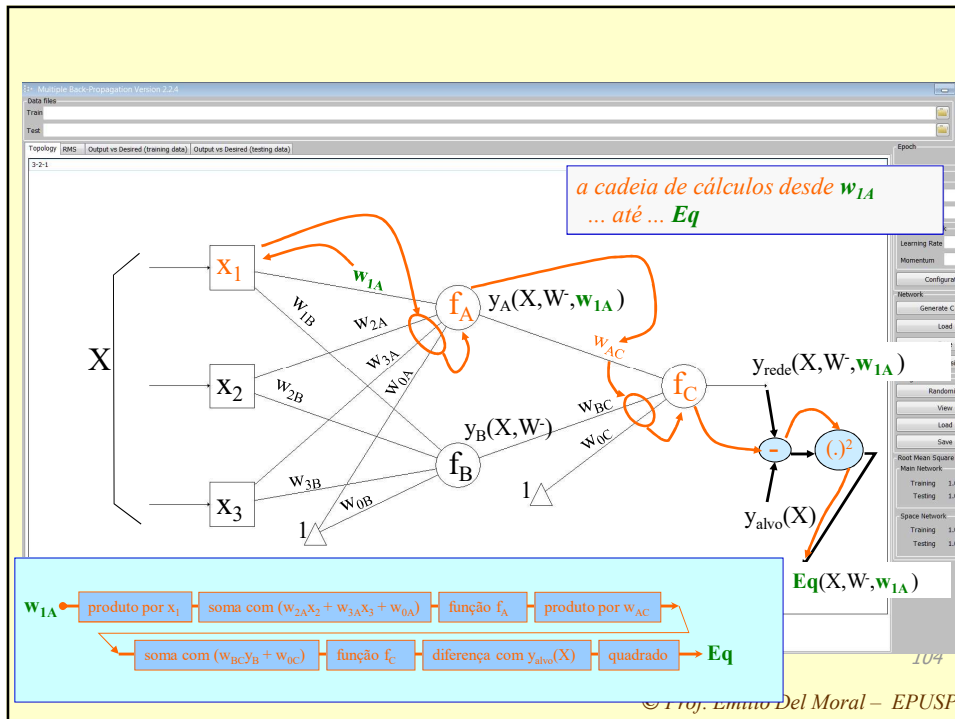
100



101



103



104

Note que aqui temos uma cadeia com muitos estágios que levam da variável  $w_{1A}$ , à variável  $Eq^u$ , e para a qual podemos calcular a derivada da saída ( $Eq^u$ ) com relação à entrada ( $w_{1A}$ ) aplicando de forma repetida a seguinte propriedade simples e sua velha conhecida ...

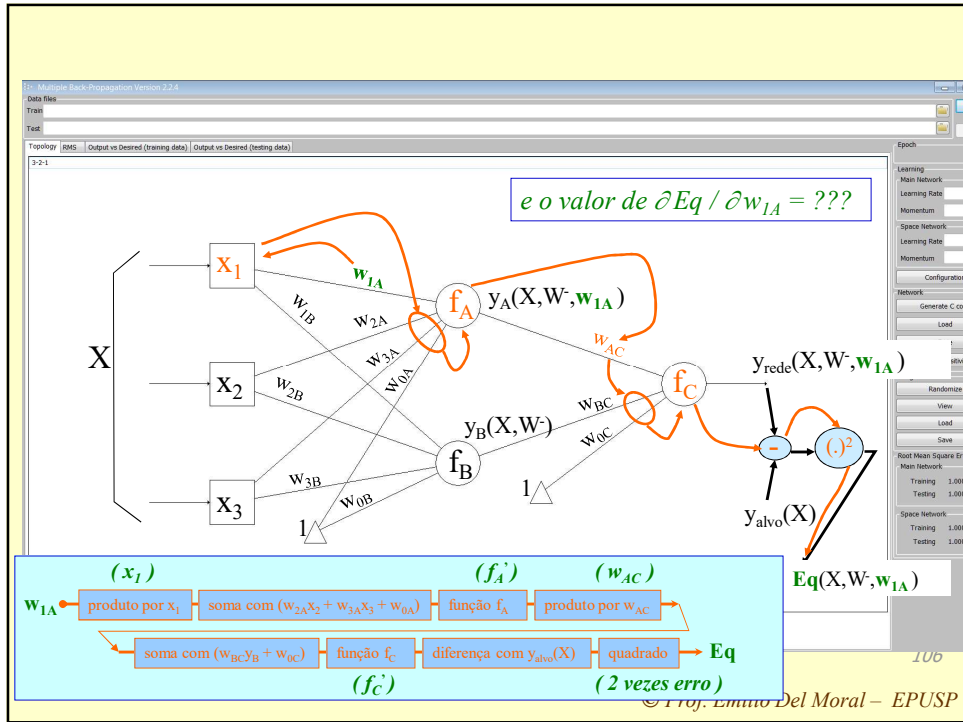
$$d(f_1(f_2(x))) / dx = df_1(x)/df_2 \cdot df_2(x)/dx$$

..., ou seja, calculando isoladamente o valor da derivada para cada estágio da cadeia, e finalizando o cálculo de derivada de ponta a ponta nessa cadeia toda através do produto dos diversos valores de cada estágio.

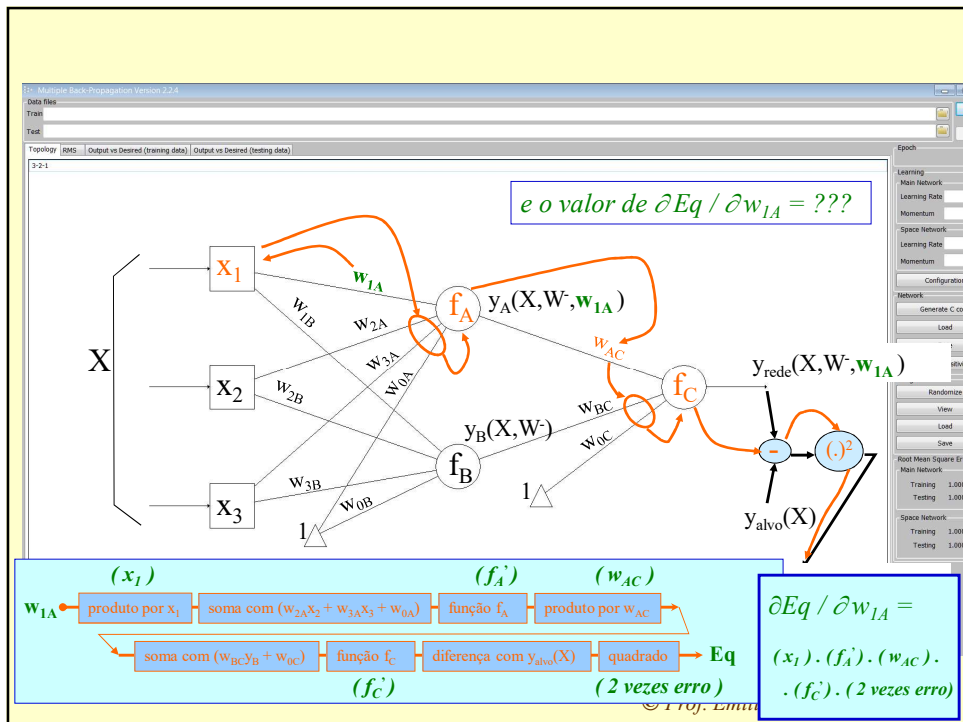
105

© Prof. Emilio Del Moral – EPUSP

105



106



107

## Lembretes ....

- Na maioria dos slides anteriores, onde aparece  $X$ , leia-se  $X^\mu$ , não incluído para não complicar demais os desenhos
- ... similarmente, onde aparece  $y_{\text{alvo}}$ , leia-se  $y_{\text{alvo}}^\mu$ . Idem para os Eq, leia-se Eq $^\mu$
- Nos itens de cadeia de derivadas ( $f'_A$ ) e ( $f'_C$ ), atenção para os valores dos argumentos, que devem ser os mesmos de  $f_A$  e  $f_C$  na cadeia original que leva  $w_{IA}$  a Eq.
- ... lembrando ... na cadeia original tínhamos ...
  - para  $f'_C$ :  $f'_C(w_{AC} \cdot f'_A(w_{1A} \cdot x_1 + w_{2A} \cdot x_2 + \dots + w_{0A}) + w_{BC} \cdot f'_B(w_{1B} \cdot x_1 + w_{2B} \cdot x_2 + \dots + w_{0B}) + w_{0C})$
  - para  $f'_A$ :  $f'_A(w_{1A} \cdot x_1 + w_{2A} \cdot x_2 + \dots + w_{0A})$
- Similarmente, para o bloco “quadrado”, cuja derivada é a função “2 vezes erro”, o argumento é  $[y_{\text{rede}}(X, W) - y_{\text{alvo}}(X)]$

112

© Prof. Emilio Del Moral – EPUSP

112

## Lembretes ....

- O mesmo que foi feito para  $w_{IA}$  deve ser feito agora para os demais 10 pesos:  $w_{2A}$ ,  $w_{3A}$ ,  $w_{0A}$ ,  $w_{1B}$ ,  $w_{2B}$ ,  $w_{3B}$ ,  $w_{0B}$ ,  $w_{AC}$ ,  $w_{BC}$ , e  $w_{0C}$  !
- Assim compomos um gradiente de 11 dimensões, com as derivadas de Eq $^\mu$  com relação aos 11 diferentes pesos  $w$ :  $\text{Grad}_w(\text{Eq}^\mu)$
- Essas 11 fórmulas devem ser aplicadas repetidamente aos  $M$  exemplares numéricos de  $X^\mu$  e  $y_{\text{alvo}}^\mu$ , calculando  $M$  gradientes!
- Com eles, se obtém o gradiente médio dos  $M$  pares empíricos:  $\text{Grad}_w(\text{Eqm}) = [\sum_\mu \text{Grad}_w(\text{Eq}^\mu)] / M$
- Esse gradiente médio é a Bussola do Gradiente!

113

© Prof. Emilio Del Moral – EPUSP

113

Método do Gradiente Aplicado aos nossos MLPs: a partir de um  $W \neq 0$ , temos aproximações sucessivas ao Eqm mínimo, por repetidos pequenos passos  $\Delta W$ , sempre contrários ao gradiente ...

- “Chute” um  $W$  inicial para o “Wcorrente”, ou “ $W$  melhor até agora”
- Em loop até obter Eqm zero, ou baixo o suficiente, ou estável:
  - Determine o vetor gradiente do Eqm, nesse espaço de  $W$ s
  - Em loop varrendo todos os  $M$  exemplos  $(X^\mu; y^\mu)$ ,
    - Calcule o gradiente de  $Eq^\mu$  associado a um exemplo  $\mu$ , e vá varrendo  $\mu$  e somando os gradientes de cada  $Eq^\mu$ , para compor o vetor gradiente de Eqm, assim que sair deste loop em  $\mu$  ;
    - Cada cálculo como esse, envolve primeiro calcular os argumentos de cada tangente hiperbólica e depois usar esses argumentos na regra da cadeia das derivadas necessárias
  - Dê um passo Delta  $\Delta W$  nesse espaço, com direção e magnitude dados por  $-\eta \cdot$ vetor gradiente médio para os  $M$  Exemplos  $(X^\mu; y^\mu)$  de treino

114

© Prof. Emilio Del Moral – EPUSP


114

O que devemos mirar quando exploramos o espaço de pesos  $W$  buscando que a RNA seja um bom modelo?

*Devemos mirar Maximização da aderência = Mínimo Eqm possível*

**As Setas Verdes Indicam Situações que Devem ser Procuradas**

Será que temos apenas um mínimo??



**Atacando a possibilidade de múltiplos mínimos locais:**

... Executamos o gradiente descendente repetidamente, com a mesma arquitetura neural e os mesmos dados empíricos de treino, mas com os pesos iniciais randômicos sendo distintos em cada rodada; anotamos todos os pesos otimizados e valores de Eqm final de todas as rodadas; mantemos os  $w$ 's do melhor dos resultados de treino entre eles (aquele ensaio com menor valor do Eqm)!

115