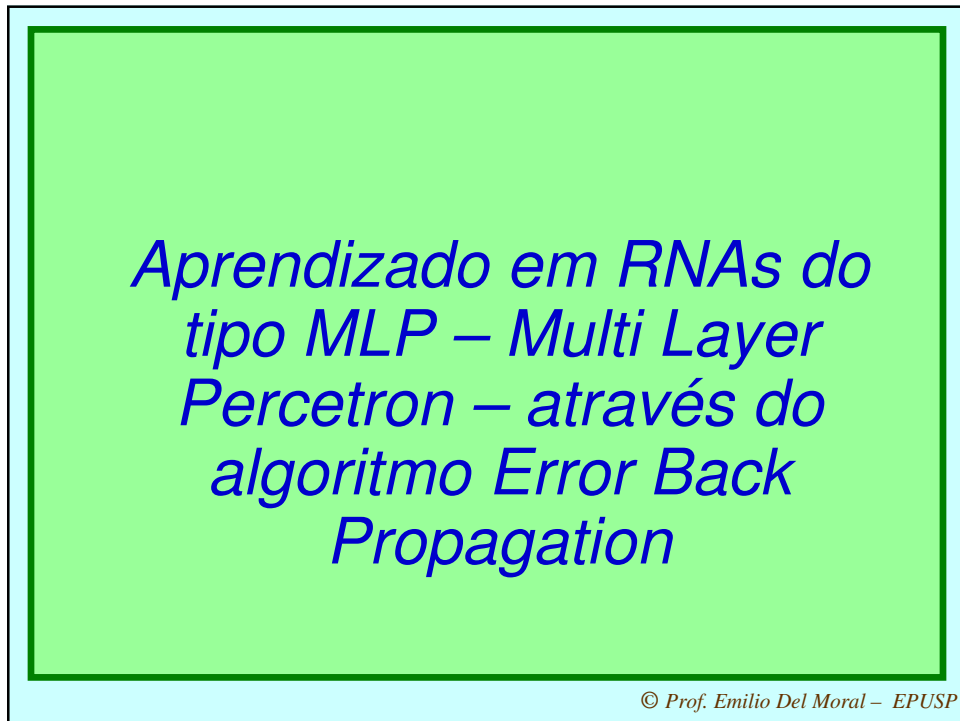


A aula de PSI3471 em  
24-abril-2017 (#07)  
continuou daqui, vinda de um conjunto de slides anterior

2

© Prof. Emilio Del Moral – EPUSP




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

© Prof. Emilio Del Moral – EPUSP

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

Devemos buscar Maximização da aderência = Mínimo  $E_{qm}$  possível

As Setas Verdes Indicam Situações que Devem ser Procuradas




4

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

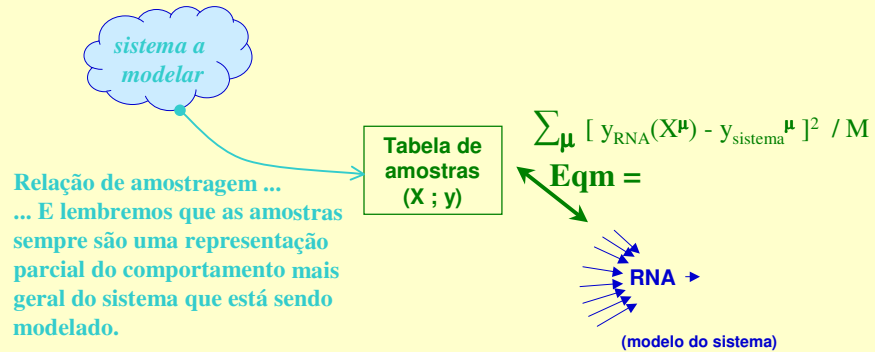
Devemos buscar Maximização da aderência = Mínimo  $E_{qm}$  possível

As Setas Verdes Indicam Situações que Devem ser Procuradas



6

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



Relação de amostragem ...  
... E lembremos que as amostras  
sempre são uma representação  
parcial do comportamento mais  
geral do sistema que está sendo  
modelado.

$$Eqm = \sum_{\mu} [y_{RNA}(X^{\mu}) - y_{sistema}^{\mu}]^2 / M$$

7

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

8

## 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. 9

© Prof. Emilio Del Moral – EPUSP

## Em termos de Excel, teríamos ...

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

10

© Prof. Emilio Del Moral – EPUSP

Em termos de Excel, teríamos ...

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*

```

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
  
```

Moral - EPUSP

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

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

*= Propagação Reversa de Erro*

*= Método do Gradiente personalizado  
ao Eqm(W) do MLP*

*Mas entendamos PRIMEIRO  
o que é o método numérico do  
gradiente ascendente /  
gradiente descendente  
genérico,  
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)*

14

© 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, 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:**

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

15

© Prof. Emilio Del Moral – EPUSP

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




**A visual model of the partial derivative**

16

© Prof. Emilio Del Moral – EPUSP

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

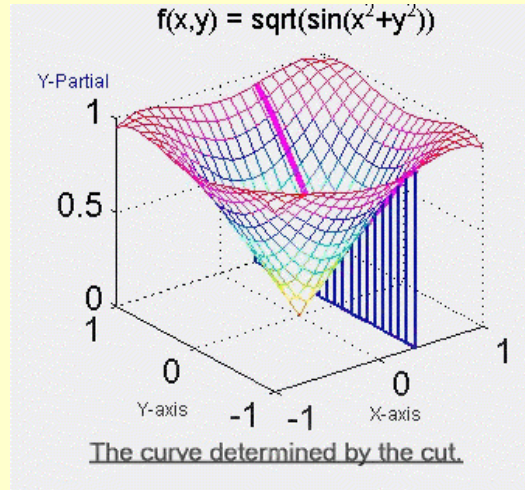


**A visual model of the partial derivative**

17

© Prof. Emilio Del Moral – EPUSP


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



A visual model of the partial derivative with respect to y. 18

© Prof. Emilio Del Moral – EPUSP

Formação do vetor gradiente a partir de duas derivadas parciais



A visual model of the partial derivative


19

© Prof. Emilio Del Moral – EPUSP



<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



20

© Prof. Emilio Del Moral – EPUSP

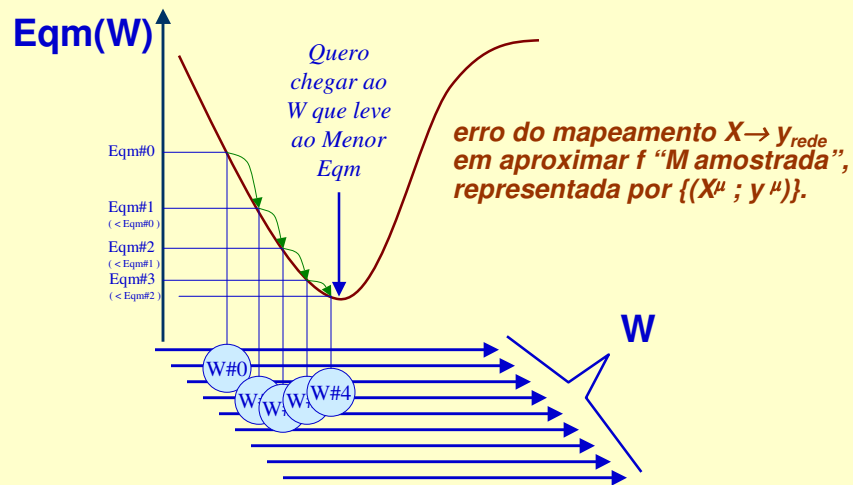
Processo de refinamentos graduais a cada iteração ...

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

21

© Prof. Emilio Del Moral – EPUSP

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




© Prof. Emilio Del Moral – EPUSP

***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 ...***

24

© Prof. Emilio Del Moral – EPUSP


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



25

© Prof. Emilio Del Moral – EPUSP

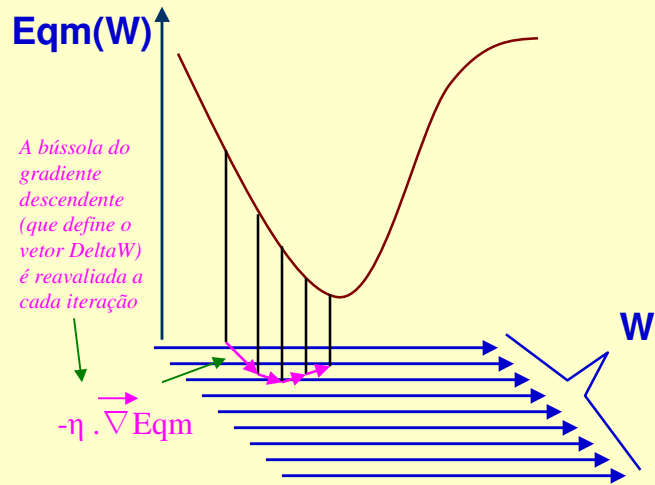
## Foco na evolução dos $w$ 's com as iterações ...



26

© Prof. Emilio Del Moral – EPUSP

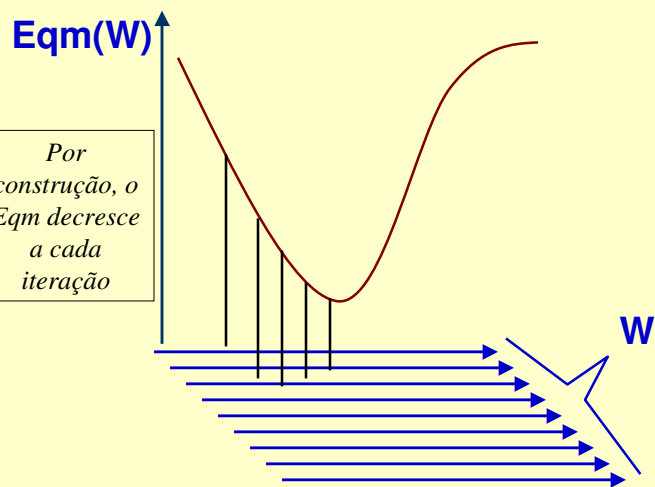
## Foco nos diferentes DeltaW de cada iteração ...



27

© Prof. Emilio Del Moral – EPUSP

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



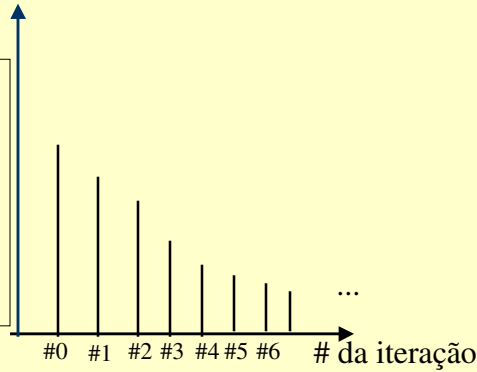
28

© Prof. Emilio Del Moral – EPUSP

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

Eqm(#)


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



29


© Prof. Emilio Del Moral – EPUSP

**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



Nota: o RMS do eixo vertical deste gráfico significa Root Mean Square, e é a raiz quadrada do nosso conhecido Eqm

*Gráfico mostrando as primeiras 47 iterações do processo de refinamentos sucessivos do modelo ...*



© Prof. Emilio Del Moral – EPUSP

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

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

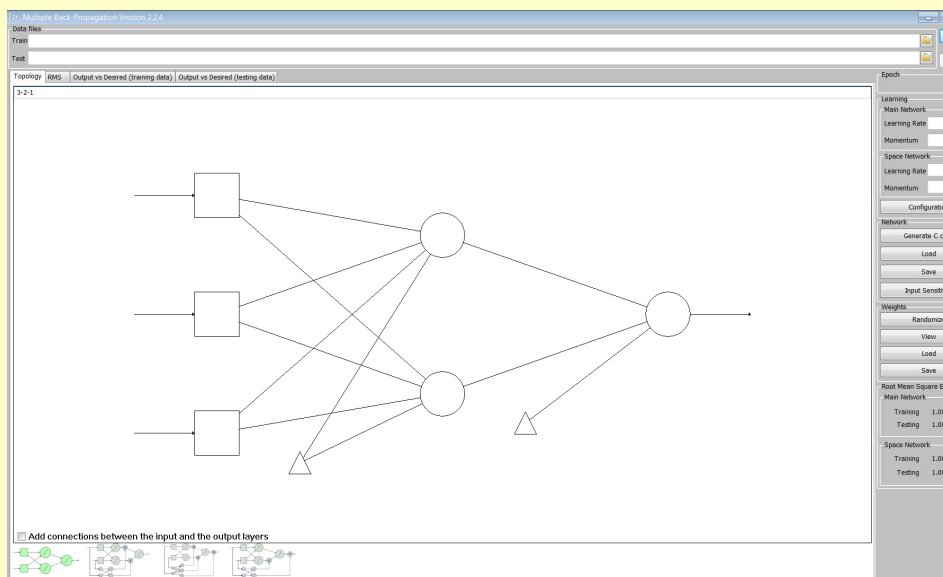
Gradiente de Eqm no espaço de pesos =  $(\partial E_{qm}(W)/\partial w_1, \partial E_{qm}(W)/\partial w_2, \partial E_{qm}(W)/\partial w_3, \dots)$

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

31

© Prof. Emilio Del Moral – EPUSP

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



32

© Prof. Emilio Del Moral – EPUSP

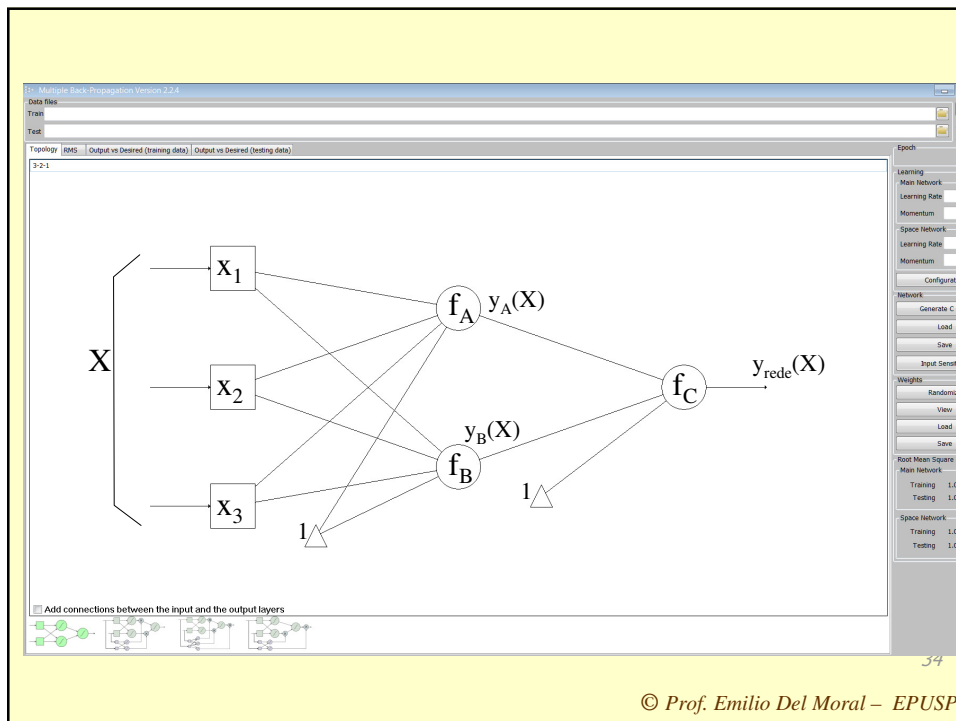
*Importante ... O que está implícito nas imagens de redes apresentadas em lousa e nas telas do MBP ... (relembrando premissas colocadas nas primeiras aulas)*

*... O fato de que cada nó neural (cada "círculo" nos diagramas da RNA) que compõe a rede gera na saída um cálculo do tipo tgh (ou sigmoïdal de sua escolha) que opera sobre a somatória ponderada (ponderação pelos seus  $w$ 's) das diversas entradas que lhe chegam (e incluindo também um viés nessa somatória)*

- Isto ocorre para todos os nós neurais da RNA: se tivermos por exemplo 2+1 (3 no total) nós neurais, como na RNA exemplo do slide anterior, cada um deles realizará um cálculo desse tipo, ou seja, tgh(soma ponderada), empregando os valores específicos de seus pesos ponderadores e seus vieses exclusivos, valores esses que podem ser distintos para cada nó
- Em particular, os nós das camadas mais adiante na RNA têm como suas entradas as variáveis de saída dos nós da camada anterior (ou seja, operam sobre as saídas de tangentes hiperbólicas das camadas anteriores)
- Isto que digo estar implícito no MBP já faz parte de qualquer rede neural (*revise os slides das primeiras aulas*), por isso não precisa ser detalhado em cada figura
- De qualquer forma, para ajudar a visualizar o que está implícito e que é premissa em RNAs, nos slides que seguem eu adiciono os significados assumidos na rede exemplo 3-2-1 do slide anterior.

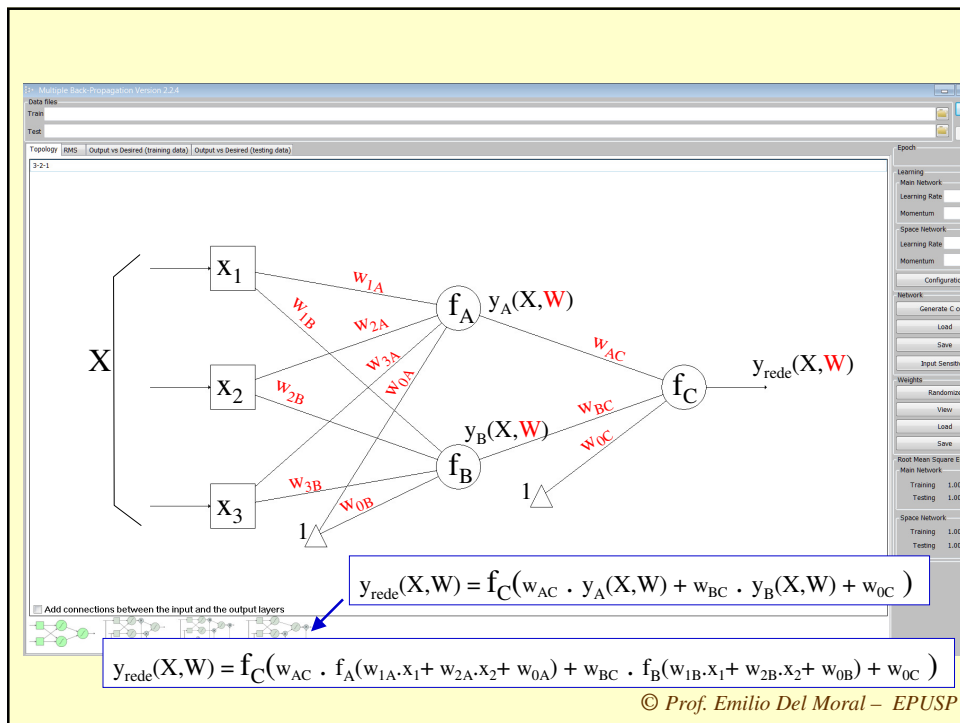
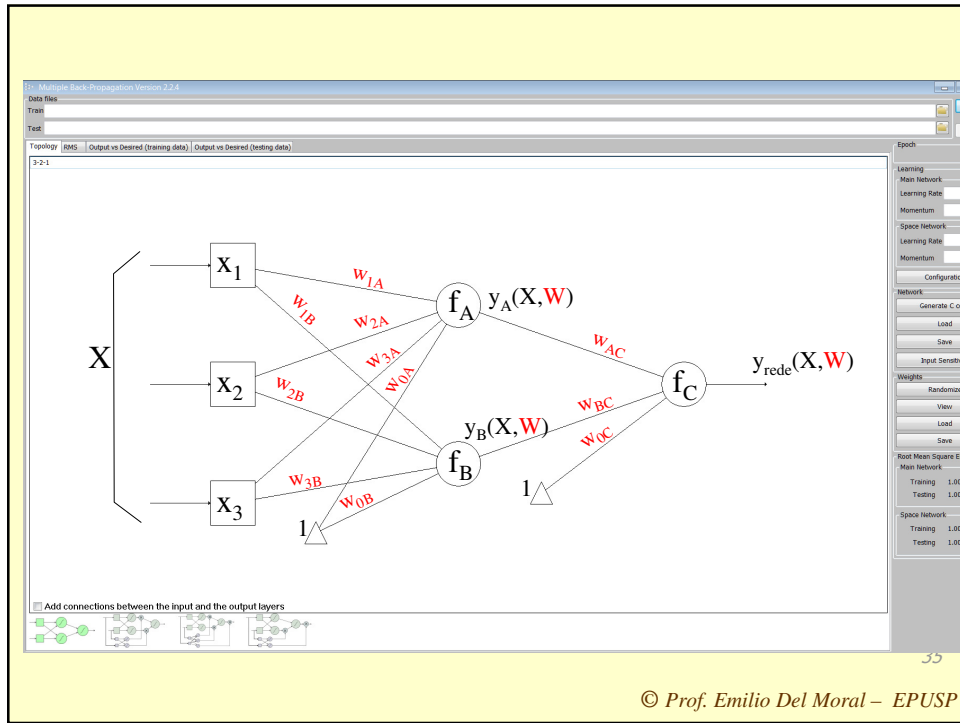
33

© Prof. Emilio Del Moral – EPUSP

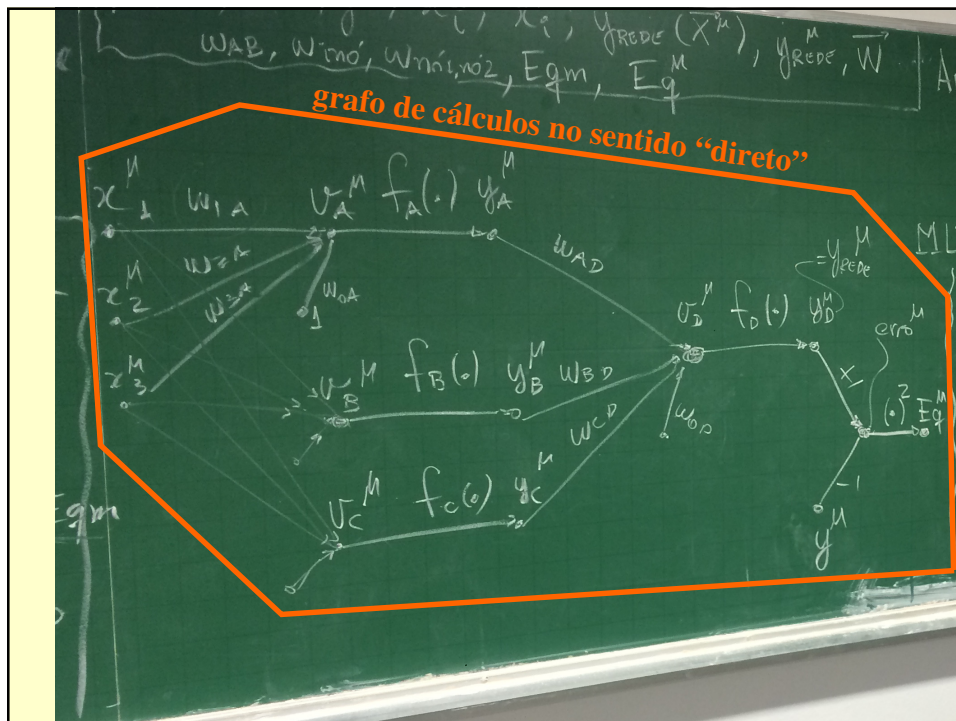
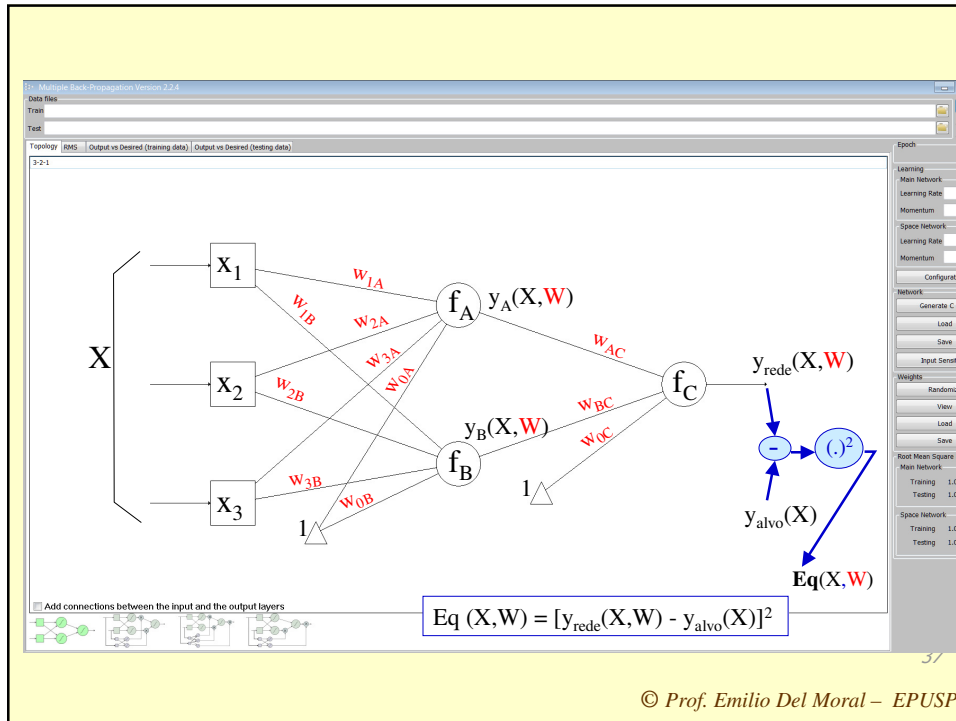


34

© 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):

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

- Vetor Gradiente, útil ao método do máximo declive:

$$(\partial Eqm(W)/\partial w_1, \partial Eqm(W)/\partial w_2, \partial Eqm(W)/\partial w_3, \dots)$$

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

39

© Prof. Emilio Del Moral – EPUSP

## *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:*

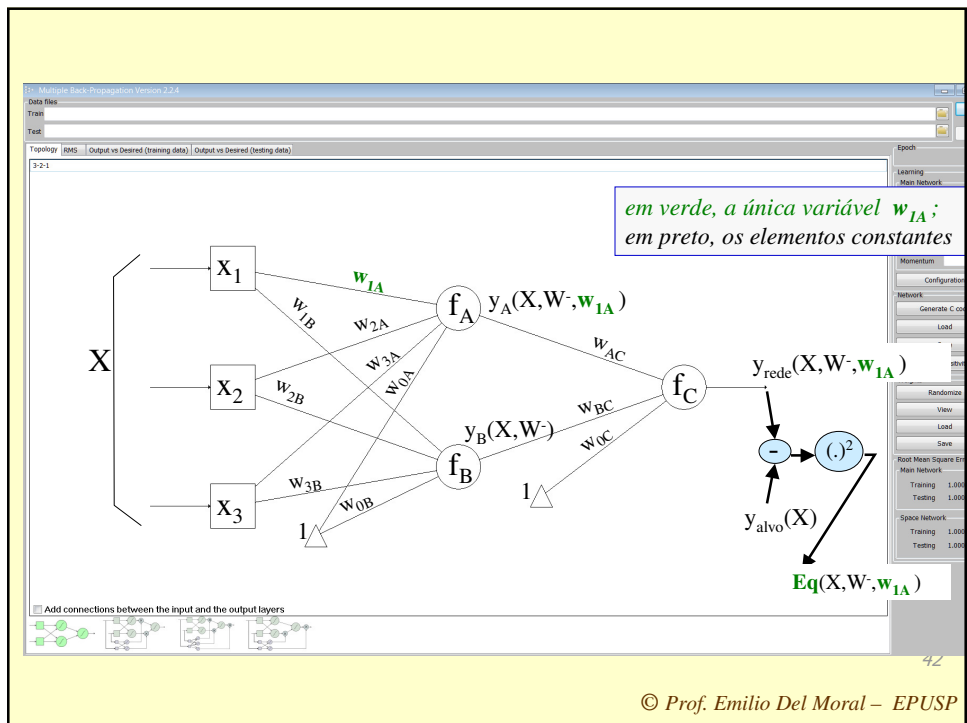
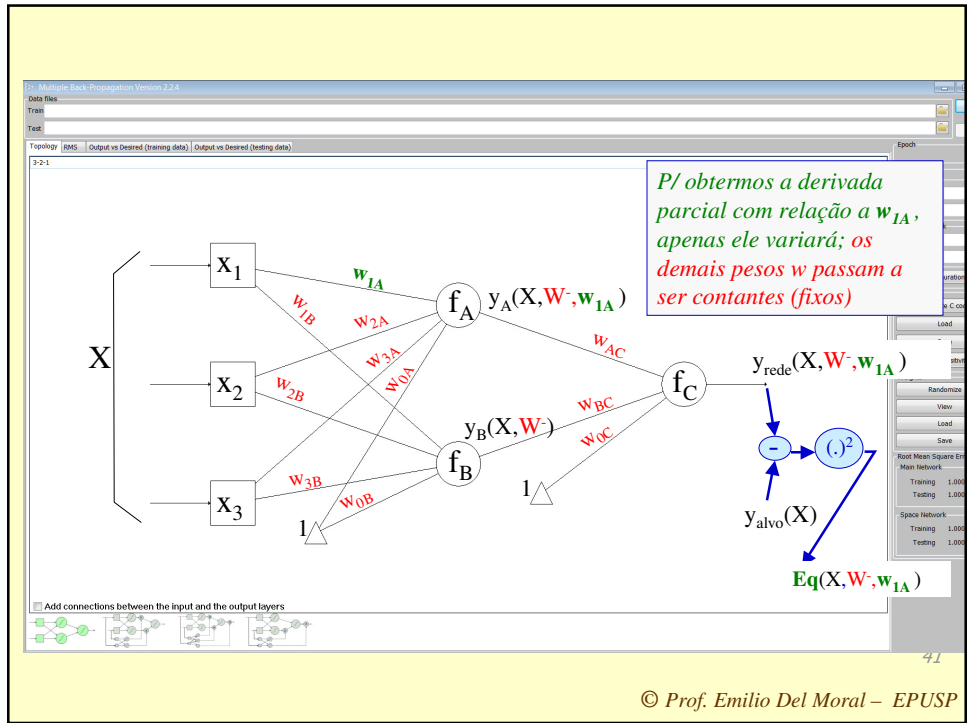
$$\mathbf{Grad}(Eqm) =$$

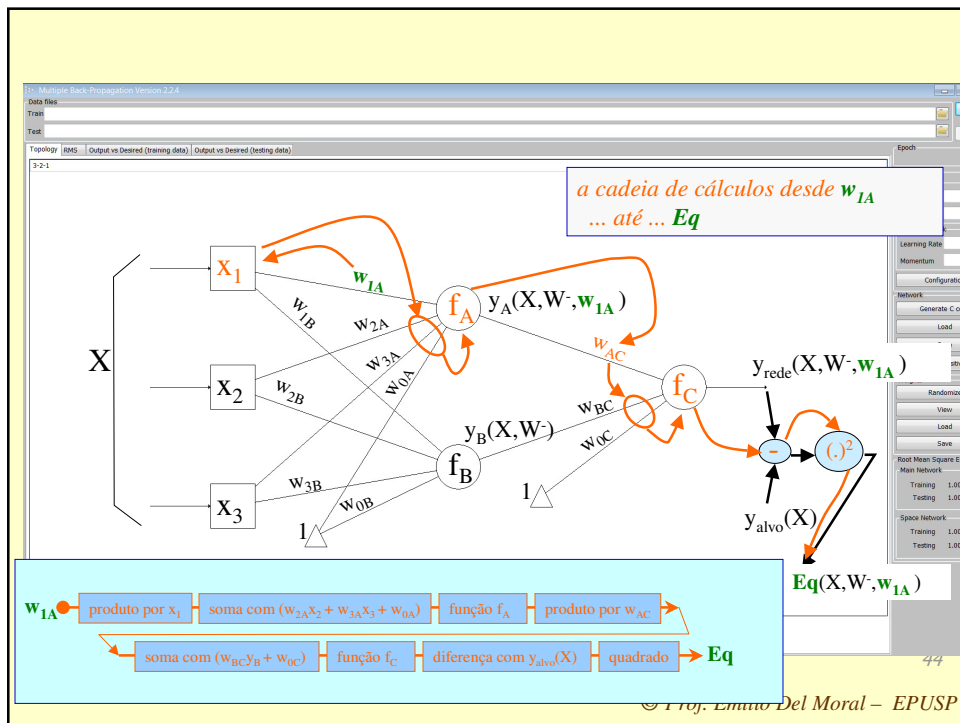
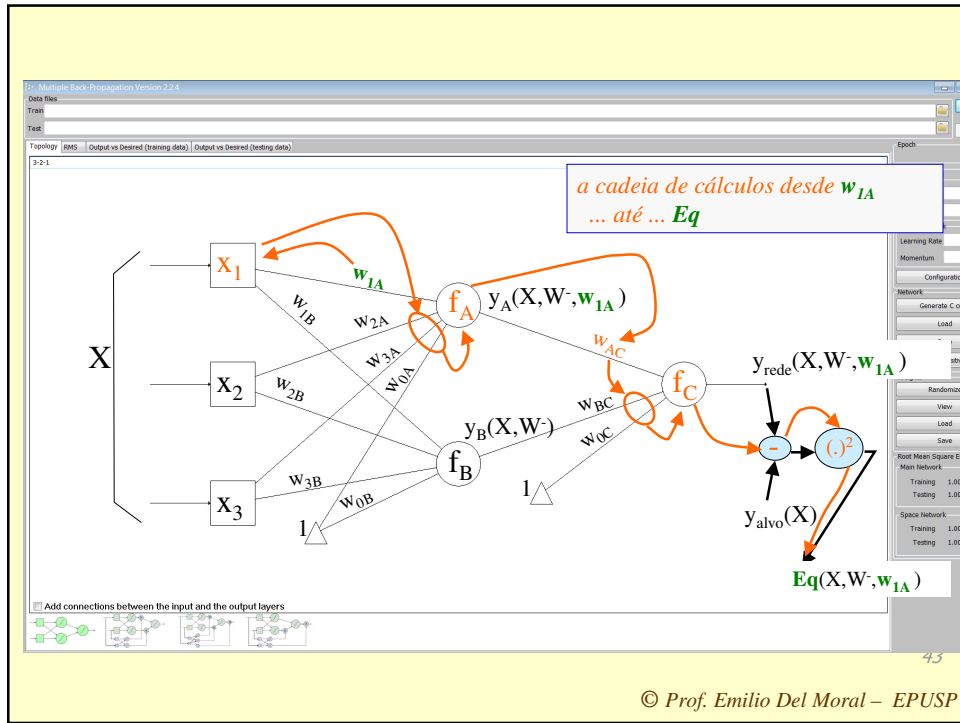
$$\mathbf{Grad}(\sum_{\mu} Eq^{\mu}) / M$$

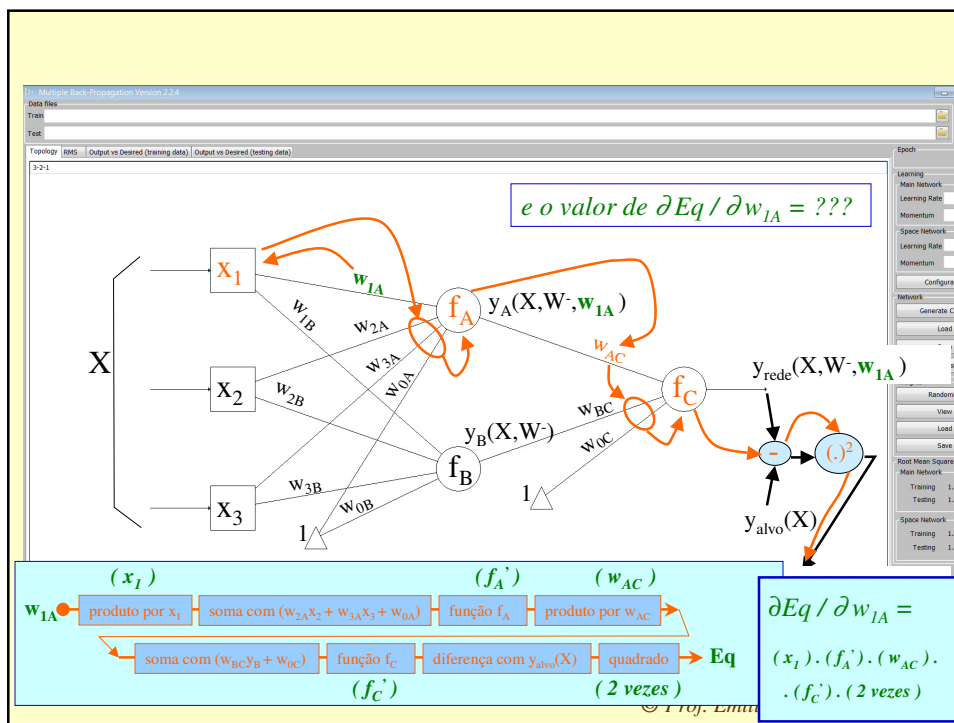
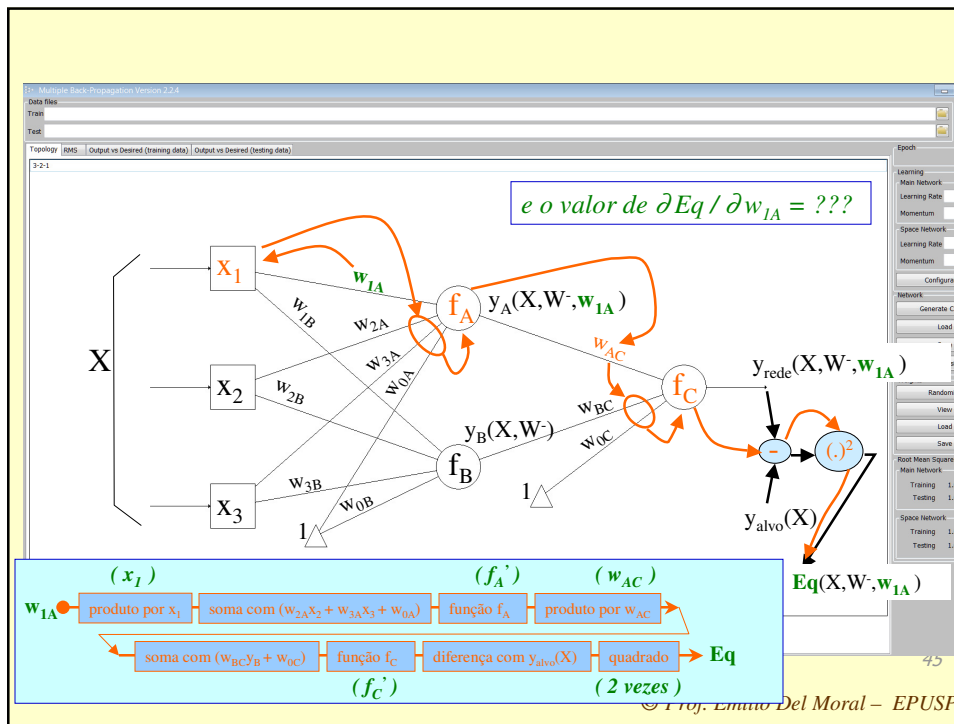
$$\sum_{\mu} \mathbf{Grad}(Eq^{\mu}) / M$$

40

© Prof. Emilio Del Moral – EPUSP







## Lembretes ....

- Na maioria dos slides anteriores, onde aparece  $X^\mu$ , 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  $f_C$ :  $f_C(w_{AC} \cdot f_A(w_{1A} \cdot x_1 + w_{2A} \cdot x_2 + w_{0A}) + w_{BC} \cdot f_B(w_{1B} \cdot x_1 + w_{2B} \cdot x_2 + w_{0B}) + w_{0C})$
  - para  $f_A$ :  $f_A(w_{1A} \cdot x_1 + w_{2A} \cdot x_2 + w_{0A})$
- Similarmente, para o bloco “quadrado”, cuja derivada é a função “2 vezes”, o argumento é  $[y_{\text{rede}}(X, W) - y_{\text{alvo}}(X)]$

47

© Prof. Emilio Del Moral – EPUSP

## 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 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:  $\text{Grad}_w(\text{Eq}_m) = [\sum_\mu \text{Grad}_w(\text{Eq}^\mu)] / M$
- Esse gradiente médio é a Bussola do Gradiente!

48

© Prof. Emilio Del Moral – EPUSP

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 “ $W$  corrente”, 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  $-\eta$ \*vetor gradiente médio para os  $M$  Exemplos  $(X^\mu; y^\mu)$  de treino

49

© Prof. Emilio Del Moral – EPUSP

## 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]*

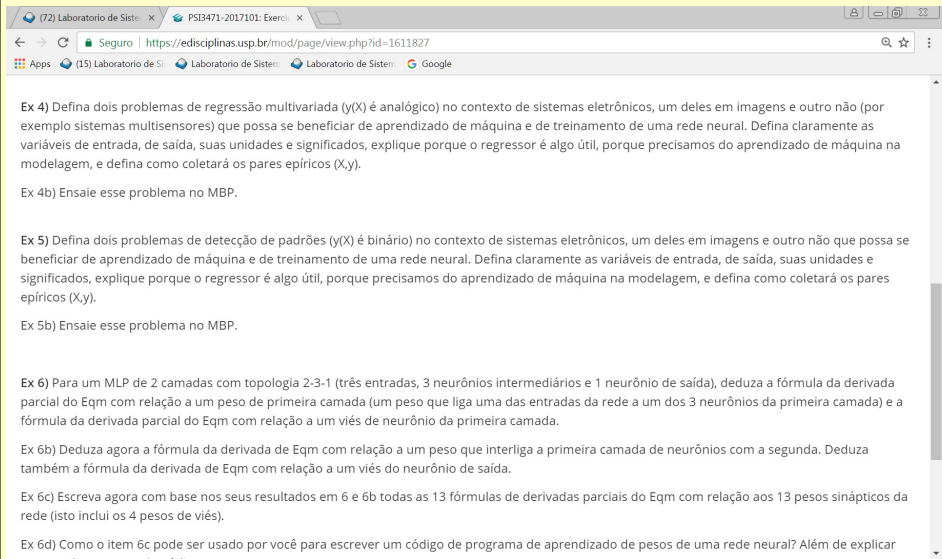
3) *Fase de USO FINAL da RNA, com  $y$  efetivamente não conhecido, e estimado com conhecimento dos  $X$  + uso do modelo calibrado.*

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

50

© Prof. Emilio Del Moral – EPUSP

## ... + exercícios de treino já disponíveis no STOA ...



The screenshot shows a web browser window with the following content:

Ex 4) Defina dois problemas de regressão multivariada ( $y(X)$  é analógico) no contexto de sistemas eletrônicos, um deles em imagens e outro não (por exemplo sistemas multisensores) que possa se beneficiar de aprendizado de máquina e de treinamento de uma rede neural. Defina claramente as variáveis de entrada, de saída, suas unidades e significados, explique porque o regressor é algo útil, porque precisamos do aprendizado de máquina na modelagem, e defina como coletará os pares epíricos  $(X,y)$ .

Ex 4b) Ensaie esse problema no MBP.

Ex 5) Defina dois problemas de detecção de padrões ( $y(X)$  é binário) no contexto de sistemas eletrônicos, um deles em imagens e outro não que possa se beneficiar de aprendizado de máquina e de treinamento de uma rede neural. Defina claramente as variáveis de entrada, de saída, suas unidades e significados, explique porque o regressor é algo útil, porque precisamos do aprendizado de máquina na modelagem, e defina como coletará os pares epíricos  $(X,y)$ .

Ex 5b) Ensaie esse problema no MBP.

Ex 6) Para um MLP de 2 camadas com topologia 2-3-1 (três entradas, 3 neurônios intermediários e 1 neurônio de saída), deduza a fórmula da derivada parcial do Eqm com relação a um peso de primeira camada (um peso que liga uma das entradas da rede a um dos 3 neurônios da primeira camada) e a fórmula da derivada parcial do Eqm com relação a um viés de neurônio da primeira camada.

Ex 6b) Deduza agora a fórmula da derivada de Eqm com relação a um peso que interliga a primeira camada de neurônios com a segunda. Deduza também a fórmula da derivada de Eqm com relação a um viés do neurônio de saída.

Ex 6c) Escreva agora com base nos seus resultados em 6 e 6b todas as 13 fórmulas de derivadas parciais do Eqm com relação aos 13 pesos sinápticos da rede (isto inclui os 4 pesos de viés).

Ex 6d) Como o item 6c pode ser usado por você para escrever um código de programa de aprendizado de pesos de uma rede neural? Além de explicar